

**ÇEVRESEL ve OPERASYONEL KOŞULLARA UYARLI MİKRO
DOPPLER VERİ İŞLEME**

BARIŞ EROL

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ**

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

AĞUSTOS 2015

ANKARA

Fen Bilimleri Enstitü onayı

Prof. Dr. Osman EROĞUL

Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

Prof. Dr. Murat ALANYALI

Anabilim Dalı Başkanı

Barış EROL tarafından hazırlanan ÇEVRESEL ve OPERASYONEL KOŞULLARA UYARLI MİKRO-DOPPLER VERİ İŞLEME adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

Yrd. Doç. Dr. Sevgi Zübeyde GÜRBÜZ

Tez Danışmanı

Tez Jüri Üyeleri

Başkan : Yrd. Doç. Dr. Sevgi Zübeyde Gürbüz

Üye : Doç. Dr. Ali Cafer GÜRBÜZ

Üye : Doç. Dr. Çağatay CANDAN

TEZ BİLDİRİMİ

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

Bariş EROL

Üniversitesi : TOBB Ekonomi ve Teknoloji Üniversitesi
Enstitüsü : Fen Bilimleri
Anabilim Dalı : Elektrik ve Elektronik Mühendisliği
Tez Danışmanı : Yrd. Doç. Dr. Sevgi Zübeyde GÜRBÜZ
Tez Türü ve Tarihi : Yüksek Lisans – Ağustos 2015

Bariş EROL

ÇEVRESEL ve OPERASYONEL KOŞULLARA UYARLI MİKRO DOPPLER VERİ İŞLEME

ÖZET

Radar gözetleme sistemlerindeki asıl zorluk insanların hayvanlardan ayrılması olduğu kadar farklı insan hareketlerinin ayrılmasını da kapsamaktadır. Bu nedenle hedef mikro-Doppler imzalarının otomatik hedef sınıflandırması için yüksek başarıma sahip olduğu gösterilse de sonuçlar operasyonel koşulların ideal olduğu durumlar ve belirli öznelik kümeleri için verilmektedir. Geçmiş yıllarda çok sayıda öznelik mikro-Doppler imzalarının sınıflandırılması için önerilmiştir. Ancak önerilen özneliklerinin tümünün kullanılması maksimum sınıflandırma başarımının verilmesini garanti etmemekte ve ideal öznelik alt kümesinin seçilmesi ise senaryoya bağımlı olarak değişmektedir. Bu çalışmada, kapsamlı olarak mikro-Doppler öznelik çıkarım yöntemleri ve çıkartılan özneliklerin radar sistem parametleri ve operasyonel koşullara – merkez frekansı, menzil ve Doppler çözünürlüğü, anten hedef geometrisi, sinyal gürültü oranı ve hedef üzerinde kalma süresi – olan bağımlılıklarını incelemektedir. İnsan mikro-Doppler imzalarına uyarlı bir öznelik dizaynı gerçekleştirilmiştir. Sınıflandırma performansını en iyileştirecek, azaltılmış sayıda olan özneliklerin çıkartılması için algoritmalar önerilmiş ve iyi seçilmiş bir öznelik alt kümesinin daha iyi başarımlar ortaya konduğu gösterilmiştir. Durum çalışması yapılarak önerilen uyarlanabilir öznelik seçim algoritmasının sınıflandırma performansını arttırılabileceği gösterilmiştir.

Anahtar Kelimeler: İnsan Mikro-Doppler, Öznelik Seçimi, Otomatik Hedef Tanıma, Mikro-Doppler Hareket Sınıflandırma

University : TOBB Economics and Technology University
Institute : Institute of Natural and Applied Sciences
Science Programme : Electrical and Electronics Engineering
Supervisor : Assist. Prof. Dr. Sevgi Zübeyde GÜRBÜZ
Degree Awarded and Date : M.Sc. – August 2015

Bariş EROL

**ADAPTIVE MICRO DOPPLER DATA PROCESSING FOR
ENVIRONMENTAL AND OPERATIONAL CONDITIONS**

ABSTRACT

A key challenge for radar surveillance systems is the discrimination of ground based targets, especially humans from animals, as well as different types of human activities. For this purpose, target micro-Doppler signatures have been shown to yield high automatic target classification rates; however, performance is typically only given for near-optimal operating conditions using a fixed set of features. Over the past decade a vast number of micro-Doppler features have been proposed for classification of radar micro-Doppler signatures. In fact utilization of all possible features does not guarantee maximum classification performance and the selection of an optimal subset of features is scenario dependent. In this work, a comprehensive survey of micro-Doppler features and their dependence upon system parameters and operational conditions – such as transmit frequency, range and Doppler resolution, antenna target geometry, signal to noise ratio, and dwell time – is given. A new feature design for human micro-Doppler signatures is proposed. Algorithms for optimizing classification performance for a reduced number of features are presented and it is shown that a well selected subset of robust features yields better results. Performance gains achievable using adaptive feature selection are assessed for a case study of interest.

Keywords: Human Micro-Doppler, Feature Selection, Automatic Target Recognition, Micro-Doppler Activity Classification

TEŞEKKÜR

Öncelikle bu günlere gelmemi sağlayan, bana her zaman destek olan, güvenen ve benimle gurur duyan değerli ve sevgili aileme şükran, sevgi ve saygılarımı sunarım. Yüksek lisans eğitimim boyunca bilgilerini benimle paylaşan, yanında çalışmaktan gurur duyduğum ve ayrıca tecrübelerinden yararlanırken göstermiş olduğu hoşgörüden dolayı sevgili danışmanım Yrd. Doç. Dr. Sevgi Zübeyde GÜRBÜZ'e, benden yardımlarını esirgemeyen ve bana yol gösteren Doç. Dr. Ali Cafer GÜRBÜZ'e, çoğu projede beraber çalıştığımız lab arkadaşlarım Bahri ÇAĞLIYAN ve Cesur KARABACAK'a, Radar Sistem Laboratuvarında çalışan diğer arkadaşlarıma ve bana burs sağlayan TOBB Ekonomi ve Teknoloji Üniversitesine teşekkürlerimi sunarım. Ayrıca lisans ve yüksek lisans eğitimim boyunca sevgisini ve desteğini benden esirgemeyen sevgili arkadaşım Dilvin ÖZKAN'a teşekkür ederim.

Bu çalışma "Radar ile İnsan Sezimi, Tanıma ve Sınıflandırma" adlı 113E105 no.lu TUBITAK projesi ve EU FP7 Project No. PIRG-GA-2010-268276 tarafından desteklenmiştir.

İÇİNDEKİLER

ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ÇİZELGE LİSTESİ.....	viii
ŞEKİL LİSTESİ.....	ix
KISALTMALAR	xi
SEMBOL LİSTESİ.....	xii
1 GİRİŞ.....	1
1.1 Problem Tanımı	1
1.2 Literatür Araştırması	2
1.3 Tez Kapsamı.....	6
1.4 Tez Organizasyonu	7
2 TEORİ	9
2.1 Mikro Doppler Etkisi	9
2.2 Zaman Frekans Gösterimi	13
2.3 Sınıflandırıcılar ve Öznitelik Seçim Yöntemleri	16
3 KİNECT TABANLI RADAR BENZETİMİ	27
3.1 Radar Benzetimi	27
3.2 Literatürde Kullanılan Benzetimler	31
3.2.1 Boulic Modeli	32
3.2.2 CMU Veri Tabanı ile Oluşturulan Model.....	34
3.3 Kinect ile İskelet Takibi Algoritması.....	36
3.4 Oluşturulan Veri Tabanı.....	38
4 ÖZİNİTELİK ÇIKARIMI ve SINIFLANDIRMA SONUÇLARI	44
4.1 Fiziksel Öznitelikler.....	44
4.1.1 İnsan Gövdesine Bağlı Olarak Çıkarılan Öznitelikler	44
4.1.2 Kol ve Bacak Salınımlarına Bağlı Olarak Çıkarılan Öznitelikler	46

4.2	Cadence Frekansı.....	48
4.3	Doğrusal Öngörülü Kodlama	51
4.4	Kepstrum Katsayıları	58
4.5	Ayrık Kosinus Katsayıları.....	62
5	İNSAN MİKRO DOPPLER İMZALARINA UYARLANMIŞ KEPSTRUM KATSAYILARI.....	64
6	RADAR SİSTEM PARAMETRELERİNE VE OPERASYONEL KOŞULLARA BAĞLI ÖZİNİTELİK SEÇİMİ.....	75
6.1	Radar Sistem Parametreleri	75
6.2	Sinyal Gürültü Oranı.....	80
6.3	Hedef Açılı Geometrisi	83
6.4	Hedef Üzerinde Kalma Süresi	86
6.5	Öznitelik Seçimi Karışıklık Matrisi.....	87
7	UYARLANABİLİR ÖZİNİTELİK SEÇİMİ	89
8	SONUÇ ve GELECEK ÇALIŞMALAR	97
	KAYNAKLAR	99
	ÖZGEÇMİŞ.....	103

ÇİZELGE LİSTESİ

Çizelge 2.1: Zaman-frekans dağılım fonksiyonlarının karşılaştırılması [38]	15
Çizelge 2.2: ID3 Karar ağacı algoritması.....	19
Çizelge 2.3: Temel Bileşen Analiz yöntemi.....	24
Çizelge 2.4: SFS algoritması	26
Çizelge 2.5: Sınıflandırma performansı için kullanılan metrik açıklamaları	26
Çizelge 3.1: Kinect mikro-Doppler veri tabanı	41
Çizelge 4.1: Fiziksel özniteliklerin sınıflandırma sonuçları.....	48
Çizelge 4.2: Cadence frekans özniteliklerinin sınıflandırma sonuçları	51
Çizelge 4.3: Doğrusal öngörülü kodlama özniteliklerinin sınıflandırma sonuçları.....	58
Çizelge 4.4: Kepstrum özniteliklerinin sınıflandırma sonuçları.....	62
Çizelge 4.5: Ayrık kosinüs dönüşümü özniteliklerinin sınıflandırma sonuçları	63
Çizelge 4.6: Tüm özniteliklerinin sınıflandırma sonuçları	63
Çizelge 5.1: Lineer aralıklık filtre öznitelikleriyle ortaya çıkan karışıklık matrisi	69
Çizelge 6.1: Radar frekans bantları.....	75
Çizelge 6.2: Tüm öznitelikler kullanıldığında ortaya çıkan karışıklık matrisi.....	88
Çizelge 6.3: Öznitelik seçimi yapıldığında ortaya çıkan karışıklık matrisi	88

ŞEKİL LİSTESİ

Şekil 2.1: Doppler etkisi örneği.....	9
Şekil 2.2: I/Q Demodulatörü	10
Şekil 2.3: Yürüme hareketi mikro-Doppler imzası.....	13
Şekil 2.4: Kısa Zamanlı Fourier Dönüşümünün bir ses sinyaline uygulanması	16
Şekil 2.5: En temel sınıflandırma sistem yapısı	17
Şekil 2.6: Sınıflandırıcılar için oluşturulan kullanıcı arayüzü.....	18
Şekil 2.7: Sınıflandırma için oluşturulan şema.....	19
Şekil 2.8: Çoklu Oylama yöntem şeması	21
Şekil 2.9: k- En Yakın Komşu sınıflandırıcısının k sayısına bağlılığı.....	22
Şekil 2.10: (a) Dışbükey Zarf ve (b) Kare Uydurma Sınıflandırıcıları.....	23
Şekil 2.11: Dışbükey Zarf yöntemi için eğitim yüzdesine olan bağımlılık.....	23
Şekil 3.1: Ara Değerlendirme ile gerçek verilerin karşılaştırılması	29
Şekil 3.2: Kinect tabanlı yürüme spektrogramı.....	30
Şekil 3.3: İnsan vücudunu temsil etmek için kullanılan 12 noktasal hedef modeli [46]	33
Şekil 3.4: Boulic tabanlı yürüme spektrogramı.....	33
Şekil 3.5: Oluşturulan insan modeli- a) 31 noktayı içeren asıl model, b) 14 nokta ...35 çıkartılarak oluşturulan model [48].....	Error! Bookmark not defined.
Şekil 3.6: Yürüme-emekleme-yürüme verisinden benzetim yapılarak oluşturulan örnek görüntü [48]	35
Şekil 3.7: CMÜ tabanlı a) yürüme b) koşma hareket spektrogramları [48].....	36
Şekil 3.8: Kinect algılayıcısının görünümü [4]	37
Şekil 3.9: Kinect iskelet takibi ve insan eklem modeli	38
Şekil 3.10: İskelet takibi için oluşturulan MATLAB tabanlı kullanıcı arayüzü	39
Şekil 3.11: İskelet takibi için oluşturulan MATLAB tabanlı kullanıcı arayüzü	39
Şekil 3.12: Kinect tabanlı insan yürüme animasyonu.....	40
Şekil 3.13: Farklı insan hareketlerine ait spektrogramlar a) Yürüme b) Koşma c) Karışık Hareketler d) Boks egzersizleri e) İleriye doğru zıplama	42
Şekil 4.1: Ana Doppler bileşenlerinin bulunması.....	45
Şekil 4.2: Kol ve bacak salınımlarına bağlı öznitelikler	47
Şekil 4.3: Cadence-Doppler frekans diyagramı.....	49
Şekil 4.4: Konuşma sinyallerinin doğrusal tahmin modeli	52
Şekil 4.5: Doğrusal öngörülü kodlama blok diyagram şeması.....	54
Şekil 4.6: KFZD ve Doğrusal Öngörülü Kodlama spektrum karşılaştırılması	55
Şekil 4.7: Sınıflandırma başarımı en iyilemesi.....	56
Şekil 4.8: Doğrusal öngörülü kodlama spektrogram örneği	57
Şekil 4.9: Kepstrum katsayıları blok şeması	60
Şekil 5.1: MFCC öznitelik blok şeması	64
Şekil 5.2: Mel ölçüsü a) bükme fonksiyonu b) Filtre bankası.....	67
Şekil 5.3: Odaklanma aralığının bulunması	68
Şekil 5.4: Lineer aralıklı filtre bankası	69

Şekil 5.5: Hiperbolik tanjant bükülme fonksiyonun a) Kaydırılma b) Bükülme derecesinin etkisi	70
Şekil 5.6: Bükülme derecesinin filtre yapıları üzerindeki etkisi a) $c=1000$ b) $c=500$	71
Şekil 5.7: Log filtre enerji karşılaştırmaları a) $M=10$ b) $M=100$	72
Şekil 5.8: Alçak filtreden geçirilmiş ayrık kosinüs katsayıları	72
Şekil 5.9: Karışık ve yürüme hareketleri için bükülme derecesine bağlı en iyileme operasyonu.....	74
Şekil 6.1: Yürüme hareketi için farklı merkez frekanslarında ortaya çıkan mikro-Doppler imzaları a) 12 GHz b) 40 GHz.....	76
Şekil 6.2: Farklı merkez frekanslarının değişik öznitelik kümeleri üzerindeki sınıflandırma etkileri.....	77
Şekil 6.3: Yürüme hareketi için farklı PRF değerlerinde ortaya çıkan mikro-Doppler imzaları a) 400 Hz b) 2400 Hz	79
Şekil 6.4: Farklı darbe tekrarlamaya sıklık değerlerinin değişik öznitelik kümeleri üzerindeki sınıflandırma etkileri.....	80
Şekil 6.5: Yürüme hareketi için farklı SGO değerlerinde ortaya çıkan mikro-Doppler imzaları a) 35 dB b) 15 dB	81
Şekil 6.6: SGO'ya bağlı olarak fiziksel öznitelik değerlerinin değişimleri	82
Şekil 6.7: SGO'ya bağlı olarak ortaya çıkan sınıflandırma sonuçları	83
Şekil 6.8: Görüş açısının Doppler kayması üzerindeki etkisi	84
Şekil 6.9: Aynı kişinin yürüme ve koşma hareketlerinden çıkartılmış iki öznitelik görüş açısına göre aldıkları değerler	85
Şekil 6.10: Görüş açısına bağlı olarak ortaya çıkan sınıflandırma sonuçları	86
Şekil 6.11: Cadence frekans özniteliklerinin hedef üzerinde kalma süresine olan bağımlılıkları	87
Şekil 7.1: Açık değerlerinin yaratılması için oluşturulan MATLAB tabanlı kullanıcı arayüzü	89
Şekil 7.2: Öznitelik seçim yöntemlerinin başarımlarının öznitelik sayısına göre değişimi	90
Şekil 7.3: Örnek olarak oluşturulan a) Hareket rotası b) Hareketin spektrogramı	91
Şekil 7.4: Segmentasyon ve örtüşmenin spektrogram üzerinde anlatılması	92
Şekil 7.5: Öznitelik seçim yöntemlerinin a) Segmentasyon b) Örtüşme zamanı için ortaya çıkan sınıflandırma sonuçları.....	94
Şekil 7.6: Uyarlanabilir öznitelik seçim yönteminin SGO'ya göre ortaya çıkan sınıflandırma başarımları	95
Şekil 7.7: Uyarlanabilir öznitelik seçim yöntemini akış şeması.....	96

KISALTMALAR

Bu çalışmada kullanılmış olan kısaltmalar açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
ACC	Accuracy
CMU	Carnegie Mellon University
F1	F-Measure
FFT	Fast Fourier Transform
IR	Infrared
kNN	k-Nearest Neighbors
KZFD	Kısa Zamanlı Fourier Dönüşümü
LFM	Linear Frequency Modulation
LPC	Linear Predictive Coding
MFCC	Mel Frequency Cepstrum Coefficients
MOCAP	Motion Capture
PCA	Principle Component Analysis
PPV	Precision
PRF	Pulse Repetition Frequency
PRI	Pulse Repetition Interval
RCS	Radar Cross Section
SFS	Sequential Forward Selection
SGO	Sinyal-Gürültü Oranı
SPC	Specificity
SVM	Support Vector Machine

SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
$H_m[k]$	Filtre parametreleri
$S_n(n, t)$	Toplam insan radar dönüş sinyali
$S_r(n, t)$	Nokta hedef dönüş sinyali
$X_a[k]$	Spektral sinyal
a_t	Genlik
f_D	Doppler frekans kayması
f_{mel}	Mel frekansı
f_t	Frekans değerleri
f_1	1. Fiziksel öznitelik
f_2	2. Fiziksel öznitelik
p_1	1. Kepstrum özniteliği
$p_{2,3}$	2. ve 3. Kepstrum öznitelikleri
$s_D(t)$	Kompleks Doppler sinyali
t_{ic}	t istatistiği
v_{maks}	Maksimum ölçülebilecek hız
x_p	Darbe sıkıştırılmış radar dönüş sinyali
k	Vücut parça uzunluğu
$s(k)$	1. Kepstrum Katsayıları
t	Zaman parametresi
v	Hedef hızı
$C(f)$	Kepstrum katsayıları
$H(z)$	Transfer Fonksiyonu
$I(t)$	In phase
$Q(t)$	Quadrature phase
$S[m]$	Log enerji çıktıları
$SP(f, t)$	Spektrogram
c	Işık hızı
$c[n]$	MFCC katsayıları
$d[n]$	Hata ölçüsü
$f[m]$	Filtre sınırları
$s[n]$	Ses üretim yolu sinyali
v	Hedef hızı
$x(t)$	Yankı bulunduran sinyal

1 GİRİŞ

1.1 Problem Tanımı

İnsan tespit ve sınıflandırma günümüzde güvenlik ve askeri uygulamalar açısından önemli bir kabiliyettir. Ülkelerin savunma alanında yaptığı harcamalar incelendiğinde en önemli başlıklardan birkaç'ı: kaçakçılık, göç ve terör saldırıları olarak ortaya çıkmaktadır. Oluşturulan sistemler ile tehlikelerin önceden sezilmesi, mümkünse engellenmesi veya minimum zararla atlatılması amaçlanmaktadır.

Günümüzde çevre, alan ve sınır koruması ile bağlantılı olan insan tespit ve sınıflandırma konusu için oluşturulan sistemlerde farklı algılayıcılar kullanılmaktadır. Bunlara örnek olarak optik [1], akustik, kızılötesi (Infrared: IR) [2] ve radyo frekansı verilebilir. Her bir algılayıcının farklı özellikleri olup uygulamaya göre kullanılan algılayıcılar değişmektedir. Ancak gelişen teknolojiyle beraber sistemlere birden fazla algılayıcı konularak tespit ve sınıflandırma performansının artırılması amaçlanmaktadır. Örnek olarak günümüzde radar ile optik kameraların beraber kullanıldığı güvenlik sistemleri bulunmaktadır. Optik kameraların avantajları: Girişimden etkilenmemesi, iyi iletim kabiliyetine sahip olması, hafifliği, ucuz olması, uzun kullanım süresi gibi sayılabilmektedir. Radarın avantajları ise: Hava şartlarından etkilenmemesi, uzun mesafede tespit kabiliyetine sahip olması, gece ve gündüz aynı şekilde çalışması, duvar arkası sezim kabiliyetine sahip olması, geniş bir alanı kapsaması ve uzaktan kontrole sahip olması gibi sıralanabilir.

Sınır güvenliği gibi önemli konularda pasif algılayıcılar olan optik ve kızılötesi sistemler çevresel koşullardan çok etkilenmektedir. Bundan dolayı aktif bir algılayıcı olan radar tercih edilmektedir. Bunun sebebi radarın avantajlarının pasif algılayıcılara göre daha fazla olmasından kaynaklanmaktadır.

Radar gözetleme sistemlerinde en önemli zorluk insanların hayvanlardan ayırt edilmesi olduğu kadar insan hareketlerinin de birbirinden ayrılmasıdır. Sınırdaki bulunan bir teröristin hayvan olarak tespit edilmesi can ve mal kaybına sebep

olabilecek, aynı şekilde bir hayvanın hedef olarak tespit edilmesi iş gücü ve zaman kaybına sebep olmaktadır. İnsan hareketlerinin tespit edilebilmesi de günümüzde önemli bir problemdir. Sınıra doğru gelen bir insanın tespit edilmesi ve hareket ayrımının yapılabilmesi önemli bir kabileyettir. Herhangi bir yanlış alarm mal ve can kaybına sebep olacaktır. Örnek olarak elinde silah tutarak yürüyen bir insanın normal olarak yürüyen bir insandan ayırt edilebilmesi gerekmektedir. Veya bir canlı bombanın diğer insanlardan ayırt edilmesiyle büyük sorunların önüne geçilebilmektedir.

Radar ile insan hareket tespit ve sınıflandırma konusu günümüzde biyomedikal uygulamalarda da kullanılmaya başlanmıştır. Amerikada yaşlı ölümlerinin büyük bir çoğunluğu düşmelerden ve gerekli sürede yardım ulaşamamasından kaynaklanmaktadır. Bundan dolayı radar tabanlı sistemler ile yaşlı insanların yaptıkları hareketlerin tespiti üzerine birçok çalışma bulunmaktadır [3]. Herhangi bir düşme veya sakatlanma olduğunda sistem gerekli yetkililere haber vermekte ve yardım ulaşmasını sağlamaktadır. Sistemlerin yanlış alarm vermesi durumunda ise iş gücü ve zaman boşa harcanacaktır. Bundan dolayı oluşturulan sistemlerde yanlış alarm oranının en aza çekilmesi istenmektedir.

İnsan hareket tespiti için mikro-Doppler analiz yöntemi kullanılmaktadır. Mikro-Doppler etkileri periyodik ve titreşimli hareketlerden kaynaklanmakta ve radar tarafından ölçülen ana Doppler kayması üzerine kiplmeler oluşturmaktadır. İnsan hareketleri için farklı mikro-Doppler imzaları ortaya çıkmaktadır. Bunun sebebi hareketin hızı ve periyodikliğinden kaynaklanmaktadır. Örneğin koşma hareketi yürüme hareketine göre daha hızlı olduğundan ana Doppler kayması daha fazla olmakta, kolların ve bacakların periyodikliği arttığı için kiplmelerin sıklığı ve genliği de artmaktadır. Böylelikle mikro-Doppler imzaları kullanılarak insan hareket ayrımı yapılabilmektedir.

1.2 Literatür Araştırması

Literatürde radar mikro-Doppler sinyallerinin kullanılarak insan hareket sınıflandırma konusu üzerine bir çok çalışma bulunmaktadır [4]–[12]. Mikro-Doppler imzalarının

zamanın bir fonksiyonu olması nedeniyle zaman-frekans analiz yöntemlerine başvurulmuştur [13]. Çalışmalara bakıldığında Kısa Zamanlı Fourier Dönüşüm (KZFD) yönteminin sıklıkla kullanıldığı görülmektedir. Ancak çözünürlük, hesaplama gücü, karşı terim gibi kısıtlar incelendiğinde diğer zaman-frekans analiz yöntemlerinde güçlü taraflarının olduğu görülmektedir. Literatürde bir KZFD yöntemi olan Gabor Dönüşümü [14], Wigner-Wille Dönüşümü gibi yöntemlerde kullanılmaktadır. Diğer bir yöntem ise Dalgacık Dönüşümü kullanılarak insan hareket sınıflandırması yapılmıştır [15]. Direk olarak radardan alınan ham veriyi kullanarak sınıflandırma yapılan çalışmalar bulunsada bunların sayısı diğer yöntemlere göre daha azdır [16].

2002-2003 yılları arasında literatürdeki çalışmalar ölçülen insan mikro-Doppler imzasını modellemek üzerine odaklanmıştır. Önce, toplam insan yanıtının birleşik zaman frekans analizinin, ayrı ayrı olarak hesaplanan vücut parçalarının birleşik zaman frekans analizlerinin toplamı olarak bulunabileceği deneysel olarak gösterilmiştir [17]. Bu sonuca dayanarak [18]'de gösterilen çalışmada Boulic yürüme modeli insandan alınan radar yanıtını hesaplamak için kullanılmış ve oluşturulan 12 nokta insan modelinin radar yanıtının oluşturulması için kullanılabilen deneysel verilerle de kanıtlanmıştır. Yakın zamanda insan vücuduna yerleştirilen sensörler sayesinde oluşturulan hareket yakalama (Motion capture : MOCAP) verileri kullanılarak da insan mikro-Doppler hareket benzetimleri yapılmaktadır [19]. Bu çalışmada farklı insan hareketleri kullanılarak benzetimler yapılmış ve bir veritabanı oluşturulmuştur. Kullanılan 5 farklı hareket için sınıflandırma sonuçları verilerek benzetim verilerinin algoritma geliştirme için kullanılabilen gösterilmiştir. Bunun dışında [4]'de gösterilen çalışmada Kinect tabanlı bir mikro-Doppler benzetim sistemi oluşturularak literatüre yeni bir benzetim sistemi kazandırılmıştır.

Diğer çalışmalarda ise insan hareketlerinin zaman frekans analizi ile sınıflandırılması için çeşitli yöntemler önerilmiştir. Boulic tabanlı bir benzetim sistemi oluşturularak geliştirilen algoritmalar ile iki insan ve araç sınıflandırılması üzerine çalışılmıştır [20]. Ancak otomobil gibi hedeflerin mikro-Doppler imzalarının bileşenleri az olduğundan ve bu hedeflerin insan hareketinden daha hızlı olmasından dolayı basit bir

sınıflandırma senaryosu olarak kalmaktadır. İnsan tanıma problemini asıl zorlaştıran durum, insan hareketlerinin benzer mikro-Doppler imzalarına sahip hedeflerden ayırt edilebilmesidir. İnsan gruplarını ayırabilme önemi bir konu olup [21]'de gösterilen çalışmada anlatılmaktadır. Yerde ilerleyen hedeflerin tespiti için diğer önerilen bir çalışma [22]'de gösterilmektedir. Bu çalışmada KZFD ile çıkartılmış mikro-Doppler imzaları üzerine birkaç farklı yöntem uygulanarak faz etkisinin kaybedilmesi hedeflenmektedir. Bu çalışmada 8 farklı sınıf tanımlanmıştır. Bunlardan bazıları insan hareketleri, grup insan yürümesi, kamyon, araç olarak sıralanabilmektedir. Ortaya çıkan performans yaklaşık olarak %90 olarak bulunmuştur.

İnsan hareketlerinin hayvanlardan ayrılmasında önemli bir problem ve araştırma konusudur. [23]'daki çalışmada insanları hayvanlardan ayırt etmek için zaman frekans analizinin kullanılabileceği belirtilerek insan tanıma alanındaki ilk çalışmalardan birine imza atılmıştır. Bir köpek ile insan mikro-Doppler imzalarının arasındaki gözle görülebilir değişikliklerin farklı yöntemlerle ölçülebildiği kanıtlanmıştır. Hatta, bu imzaların bir ata ait olan imzadan da farklı olduğunu gösterilmiştir. Kullanılan yöntem Cadence frekans öznelikleri olarak literatüre geçmiştir. Ancak bu çalışmada çok basit bir sınıflandırıcı kullanılmış olup gerçek bir sistem üzerinde herhangi bir deneme yapılmamıştır. Bu çalışmadan sonra hayvan insan ayırımı için somut bir sınıflandırma sonucu içeren çalışma bulunmamaktadır. Çalışmaların çoğu niteliktir. Örneğin [24]'de gösterilen kitapta farklı hayvanların mikro-Doppler imzalarına yer verilmiş ancak herhangi bir sınıflandırma sonucu konmamıştır. [25]'de gösterilen çalışmada insanları atlardan ayırt etmek için gerçek radar verileri toplanıp hedefleri ayırt etmek için 8 farklı öznelik önerilmiştir. Ancak çalışmada herhangi bir sınıflandırma sonucu verilmemiştir. Bir diğer çalışma ise çeşitli köpeklerden ve atlardan alınan akustik mikro-Doppler imzalarının arasında gözle görülebilir farkın bulunduğu göstermekle yetinmiştir [26].

İnsanların farklı hareketlerini sınıflandırmak üzere çok sayıda çalışma bulunmaktadır. Sınıflandırma kapsamında ele alınan çeşitli hareketlerin arasında koşma, yürüme, tek ve iki kol sallanıyorken yürüme, emekleme, boks hareketleri, ilerlerken boks ve

oturma hareketleri bulunmaktadır. Ancak çoğu çalışma genellikle sadece bu hareketlerin ikisini veya üçünü birbirinden ayırt etmeye çalışmaktadır [8].

İnsan hareket sınıflandırma konusunda öznitelik çıkarımı büyük bir önem taşımaktadır. Literatürde insan sınıflandırma için birçok öznitelik önerilmektedir. [8]'da gösterilen çalışmada KZFD alındıktan sonra ortaya çıkan mikro-Doppler imzasından fiziksel öznitelikler çıkartılmaktadır. Bu tanımlanan öznitelikler gövdenin ortalama Doppler frekansı, Doppler sinyalinin toplam bant genişliği, ayak ve kol hareketlerinin önemliliği vb. olarak sıralanmaktadır. Cadence frekans öznitelikleri ve türevleri de bir çok çalışmada kullanılmaktadır [22], [23], [27], [28]. Bu çalışmalardan bazıları sınıflandırma sonuçları verirken bazıları sadece çıkartılan öznitelikleri istatistiksel olarak incelemektedir. Görüntü işlemede oldukça kullanılan bir yöntem olan Sözde-Zernike momentleri de [29]'da gösterilen çalışmada incelenmektedir. Yöntemin açıdan bağımsız olarak çalıştığı iddaa edilmekte ve yaklaşık olarak başarımlar %85 olarak verilmektedir. Ayrık kosinüs dönüşüm tabanlı özniteliklerde [21]'da gösterilen çalışmada kullanılmaktadır. Bu çalışmada insan grupları ayırt edilmektedir. Mel Frekansı Cepstrum Katsayıları (Mel Frequency Cepstrum Coefficient: MFCC) öznitelikleride ses tanımada yoğun olarak kullanılmakta, mikro-Doppler insan hareket sınıflandırma literatürüne yavaş yavaş girmektedir. [30] 'da gösterilen çalışmada MFCC öznitelikleri düşme tespiti için kullanılmıştır. Doğrusal Öngörülü Kodlama (Linear Predictive Coding: LPC) katsayıları da ses tanımada kullanılan bir öznitelik olmasına rağmen birçok mikro-Doppler çalışmasında kullanılmaktadır [31]. Ancak çalışmalar genel olarak incelendiğinde tanımlanan özniteliklerin sadece bir kaç tanesi kullanılıp bunlara göre sınıflandırma sonuçları verilmektedir.

Literatürde bulunan çalışmalarda birçok farklı sınıflandırıcı kullanılmaktadır. Bunlara örnek olarak yapay sinir ağları [7], destek vektör makineleri (Support Vector Machine: SVM) [8], temel bileşen analizi (Principal Component Analysis: PCA) [32], doğrusal ayırıcı analiz [33], uzaklık ölçütleri [34], k- ortalama öbekleme [35] verilebilir. Sayısı az da olsa birden fazla sınıflandırma yöntemini karşılaştıran çalışmalarda mevcuttur [25], [30], [33].

Sınıflandırma başarımı açısından literatürdeki çoğu çalışma %80 üzerinde başarıma ulaştığını öne sürmektedir. Hatta, %90 üzerine başarımları bildiren çalışmalar da bulunmaktadır. Ancak, bu çalışmalarda çevresel ve operasyonel koşullar dikkate alınmadığından dolayı kolay senaryolar oluşmaktadır. Zorlayıcı koşullar oluşturulursa başarımların düşeceği birkaç çalışmada gösterilmektedir.

1.3 Tez Kapsamı

Bu çalışmada ilk olarak Kinect tabanlı bir mikro-Doppler benzetim sistemi geliştirilmiştir. Kinect tabanlı benzetim sistemi kullanılarak bir veritabanı oluşturulmuş, veritabanından değişik öznelik çıkarma yöntemleri kullanılarak 28 farklı öznelik çıkartılmıştır. Öznelik kümelerinin performansları 7 farklı sınıflandırıcı kullanılarak 5 farklı metrik cinsinden karşılaştırılmıştır.

İnsan hareketleri için uyarlanmış yeni bir öznelik oluşturulmuş ve sınıflandırma performansı değişik parametreler için ölçülmüştür. Oluşturulan özneliğin ayırıcı özelliğe sahip olabilmesi için kaba kuvvet yöntemiyle sınıflandırma performansı maksimum yapılmaya çalışılmıştır.

Literatürdeki pek çok çalışmada bulunmayan çevresel ve operasyonel koşulların öznelik kümeleri üzerindeki sınıflandırma başarımları incelenmiştir. Öznelik seçim yöntemleri kullanılarak sınıflandırma başarımları incelenmiş ve öznelik seçim yöntemleri kendi aralarında karşılaştırılmıştır.

Dinamik ve sürekli değişen hedef rotalarını daha iyi sınıflandırabilmek için bir uyarlanabilir öznelik seçim yöntemi önerilmiştir. Açının dinamik olarak değiştiği rotalarda sınıflandırma başarımı iyileştirilmeye çalışılmıştır. Farklı Sinyal-Gürültü Oranı (SGO) için simülasyonlar yapılmıştır.

1.4 Tez Organizasyonu

Bu çalışma toplam sekiz bölümden oluşmaktadır. Bölüm 2, tez kapsamında uygulanan yöntemlerin arkasındaki teorik tabanın açıklandığı bölümdür. İlk olarak mikro-Doppler analizinin matematiksel tabanı ve nasıl bir yapıya sahip olduğu anlatılmıştır. Diğer kısımlarda zaman frekans analiz yöntemlerine örnekler verilmiştir. Son kısımda ise çalışmada kullanılan sınıflandırıcıların, öznelik yöntemlerinin ve metriklerin açıklamalarına yer verilmiştir.

Bölüm 3, literatürde bulunan benzetim modellerinden bahsetmekte ve farklı hareketler ile oluşturulan mikro-Doppler imzaları için örnekler vermektedir. İkinci kısımda ise çalışmada kullanılan verilerin oluşturulduğu Kinect tabanlı mikro-Doppler benzetim sistemi anlatılmakta ve veritabanının özelliklerinden bahsedilmektedir.

Bölüm 4, insan hareket tanıma konusu için çıkartılan farklı öznelik kümelerinin matematiksel olarak anlatılmasını ve sınıflandırma başarımlarının karşılaştırılmasını incelemektedir.

Bölüm 5, mikro-Doppler insan hareket sınıflandırma konusu için ses tanımadan uyarlanmış yeni bir öznelik kümesinin teorik ve pratik olarak adımlarını anlatmaktadır. Ortaya çıkan sınıflandırma sonuçları ve iyileştirmeler ortaya konmaktadır.

Bölüm 6, literatürde çok önem verilmeyen çevresel ve operasyonel koşulların - merkez frekansı, darbe tekrarlama sıklığı (Pulse Repetition Frequency: PRF), SGO, hedef üzerinde kalma süresi, görüş açısı - öznelik kümelerinin sınıflandırma başarımları üzerindeki etkisini anlatmaktadır. Gerekli incelemeler yapıldıktan sonra oluşturulan zorlu bir senaryo için öznelik seçimi yapılmayan ve yapılandıktan sonra ortaya çıkan sınıflandırma başarımları karşılaştırılmıştır.

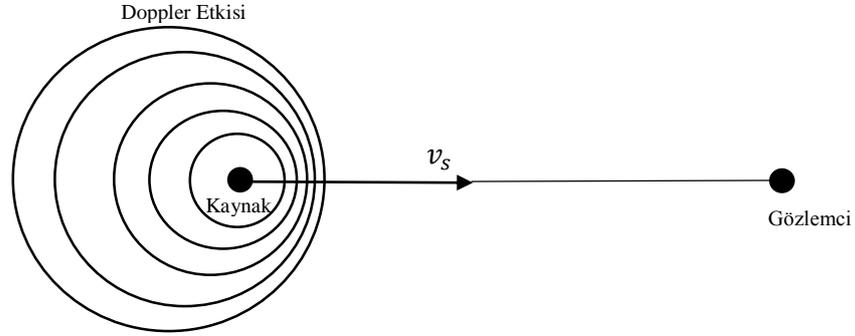
Bölüm 7’de, dinamik olarak açısı deęişen insan rotaların için sınıflandırma başarımını yükseltecek bir uyarlanabilir öznitelik seçim yöntemi önerilmiştir. Benzetim sonuçları farklı SGO’lar için çıkartılarak, önerilen yöntemin başarılı olduęu gösterilmiştir.

Bölüm 8, çalışma kapsamında elde edilen sonuçların yorumlandığı ve çalışmaya ileri taşımak için gelecekte yapılabilecek faaliyetlerin belirtildięi bölümdür.

2 TEORİ

2.1 Mikro Doppler Etkisi

Doppler etkisi ilk olarak 1842 yılında Avusturyalı matematikçi Christian Doppler tarafından yıldızlarda meydana gelen renkli ışık etkisi ile ortaya çıkartılmıştır [36]. Işık kaynağının görülen rengi kendi hareketine göre değişmektedir. Gözlemciye doğru ilerleyen ışık kaynağı için, ışığın rengi daha da mavileşirken, eğer ışık kaynağı gözlemciden uzaklaşıyor ise renk kırmızılaşmaktadır. Doppler etkisi, ışık kaynağındaki gözlemlenen frekansın, kaynak ile gözlemci arasındaki göreceli hıza bağlı olduğunu belirtmektedir. Kaynağın hareket etkisi, kaynağın önündeki dalgaların sıkışmasına; kaynağın arkasındaki dalgaların ise açılmasına sebep olmaktadır [37]. Doppler kayması örneği Şekil 2.1’ de gösterilmektedir. Deneysel olarak ilk Doppler etkisi 1843 yılında ses dalgaları üzerinde kanıtlanmıştır.



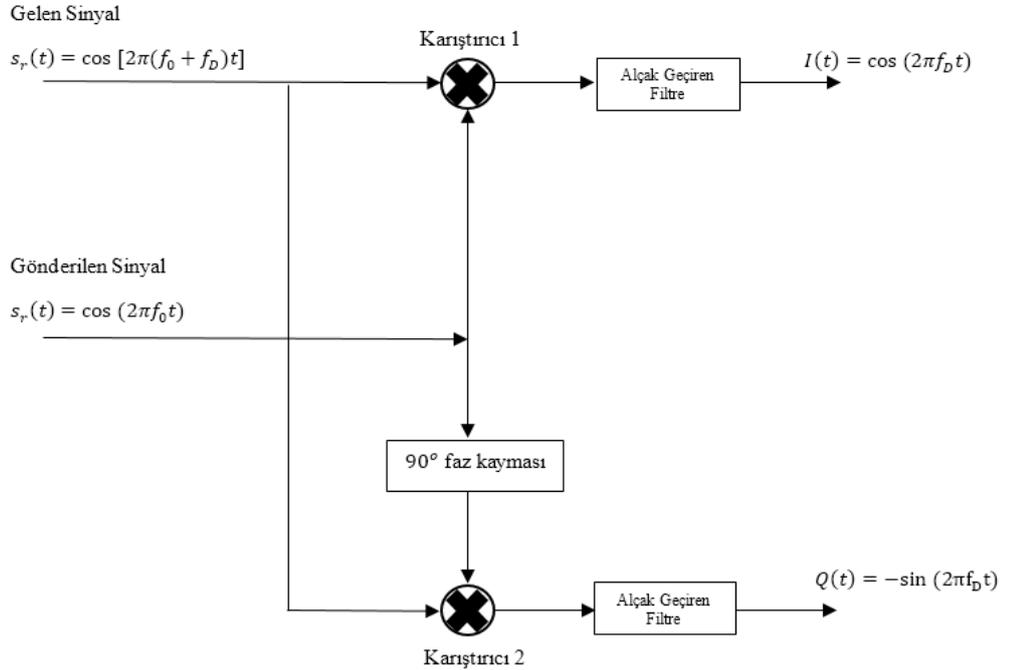
Şekil 2.1: Doppler etkisi örneği

Radarda ise hedefin hızı - v - genellikle Elektromanyetik dalga'nın yayılma hızından - c - çok daha küçüktür. Monostatik radar sistemleri için (verici ve alıcının aynı lokasyonda bulunması) EM dalga tarafından katedilen yol verici ile hedef arasındaki uzaklığın iki katıdır. Bu durumda, dalga hareketi iki segmentten oluşmaktadır: Vericiden hedefe doğru ilerlemeden kaynaklı Doppler kayması ve hedeften alıcıya doğru olan ilerlemeden kaynaklı diğer Doppler kayması. Bundan dolayı toplam Doppler kayması

$$f_D = -f \frac{2v}{c} \quad (2.1)$$

Burada f taşıyıcı frekans, v hedefin hızı ve c ışık hızı olarak tanımlanmaktadır. Eğer hedef radardan uzaklaşıyorsa hız pozitif olarak tanımlanmaktadır ve Doppler kayması negatif olmaktadır. Tam tersi durumunda, hedef radara doğru yaklaşıyorsa, hız negatif olarak tanımlanmakta ve Doppler kayması pozitif olmaktadır.

Kullanılan Doppler radarlar, radyal hızın ölçülmesi için Doppler etkisini incelemektedir. Doppler frekansının bulunması dört köşeli (I/Q Demodulator) detektör tarafından yapılabilmektedir. Bu detektör giriş sinyalindeki faz bileşenleri olan I ve Q elemanlarını çıkartmaktadır. Örnek bir dört köşeli detektör yapısı Şekil 2.2' de gösterilmiştir.



Şekil 2.2: I/Q Demodulatörü

Dört köşeli detektör, gelen sinyali iki karıştırıcı kullanarak ayırır. İlk detektör I, gelen sinyali gönderilen sinyal ile karıştırır. Eğer alınan gelen sinyal aşağıdaki gibi ifade edilirse

$$s_r(t) = a \cos[2\pi(f_0 + f_D)t] = a \cos[2\pi f_0 t + \varphi(t)] \quad (2.2)$$

Burada a gelen sinyalin genliđi, f_0 gönderilen sinyalin taşıyıcı frekansı, ve $\varphi(t) = 2\pi f_D t$ gelen sinyaldeki hedefin hareketinden kaynaklı faz kayması olarak temsil edilmektedir. Gelen sinyali gönderilen sinyal ile karıştıırarak

$$s_t(t) = \cos(2\pi f_0 t) \quad (2.3)$$

Eş zamanlı detektör I çıktısı

$$s_r(t)s_t(t) = \frac{a}{2} \cos[4\pi f_0 t + \varphi(t)] + \frac{a}{2} \cos(\varphi(t)) \quad (2.4)$$

Alçak geçiren filtreden sonra I-kanalın çıktısı

$$I(t) = \frac{a}{2} \cos(\varphi(t)) \quad (2.5)$$

İkinci eş zamanlı detektör çıktı ise gelen sinyal ile gönderilen sinyalin fazının 90° kaydırılmış halinin karışırılmasıyla oluşur. Fazı kaydırılmış gönderilen sinyal

$$s_t^{90^\circ}(t) = \sin(2\pi f_0 t) \quad (2.6)$$

İkinci eş zamanlı detektörün çıktısı

$$s_r(t)s_t^{90^\circ}(t) = \frac{a}{2} \sin[4\pi f_0 t + \varphi(t)] - \frac{a}{2} \sin(\varphi(t)) \quad (2.7)$$

Alçak geçiren filtreden sonra Q-kanal çıktısı

$$Q(t) = -\frac{a}{2} \sin(\varphi(t)) \quad (2.8)$$

İki kanalın, çıktısı birleştirildiğinde kompleks Doppler sinyali oluşmaktadır.

$$s_D(t) = I(t) + j Q(t) = \frac{a}{2} \exp[-j\varphi(t)] = \frac{a}{2} \exp[-j2\pi f_D t] \quad (2.9)$$

Kompleks Doppler sinyalinin - $s_D(t)$ - frekans ölçüm teknikleri ile çözülerek Doppler frekansı - f_D - çıkartılabilmektedir. Örnek olarak kompleks Doppler sinyalinin spektral yoğunluğuna bakılarak Doppler frekansı bulunabilmektedir.

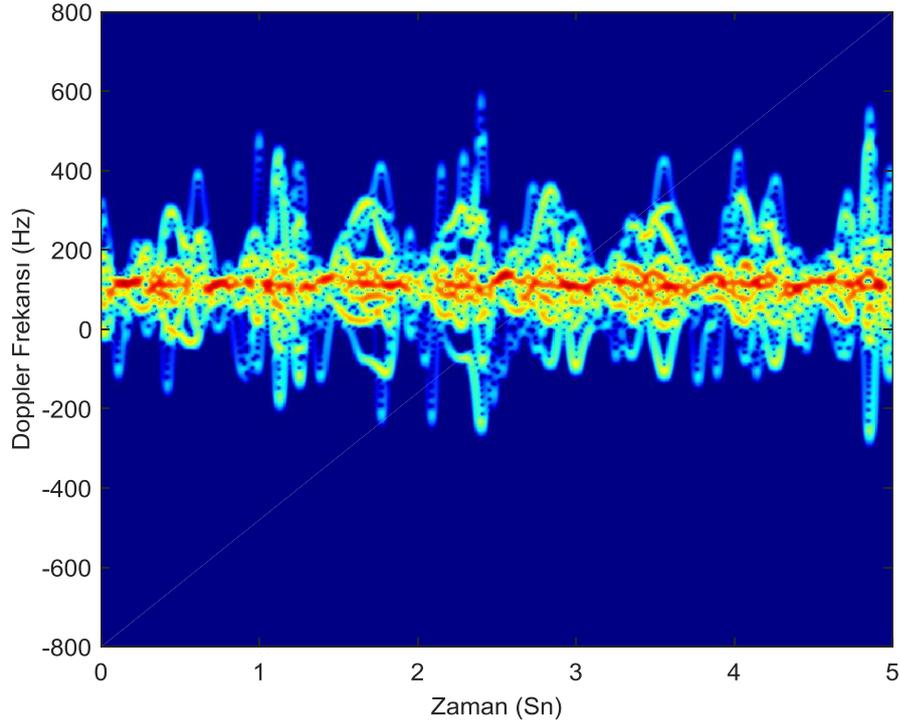
Mikro-Doppler etkisi ilk olarak uyumlu lazer radar sistemlerinde ortaya çıkmıştır [37]. Birçok durumda hedef veya hedefin yapısal parçaları salınımsal hareketlere sahiptir. Bunlar mikro-hareketler olarak adlandırılmaktadır [37]. Bu hareketlere örnek olarak helikopterlerin pervane hareketi, insan yürümesinde kol ve bacak salınımları verilebilmektedir.

Mikro-hareketler gönderilen sinyalin taşıyıcı frekansı üzerinde frekans kiplemelerine neden olmaktadır. Periyodik veya titreşimli mikro-hareketler ana Doppler kayması üzerine kiplemeler oluşturarak kendilerini göstermektedir. Bu kiplemeler taşıyıcı frekans, titreşim sıklığı veya periyodikliği ve titreşimin yönü ile dalganın yönü arasındaki açığa bağlı olarak değişmektedir.

Mikro-Doppler etkisi sinyalin frekans bandına duyarlıdır. Mikrodalga frekans bantlarında çalışan bir radar sistemi için eğer hedefin periyodikliği ve titreşim sıklığı yeterli ise mikro-Doppler etkisi görülmektedir. Düşük frekans bantlarında çalışan radar sistemlerinde titreşimlerden kaynaklı mikro-Doppler kaymaları büyük ihtimalle tespit edilemeyebilir. Rotasyondan veya yüksek tekrarlanma sıklığına sahip hareketlerden kaynaklı mikro-Doppler kaymaları düşük frekans bandında çalışan radar sistemleri tarafından gözlenebilmektedir.

Mikro-Doppler kaymaları zaman ile değişen frekans kaymaları olarak tanımlanmaktadır. Bundan dolayı kompleks Doppler sinyali kullanılarak mikro-Doppler kaymaları bulunabilmektedir. Mikro-Doppler imzalarının zamanla

değişmesinden dolayı geleneksel Fourier dönüştürmeleri yerine zaman-frekans analiz yöntemleri kullanılmaktadır. Yürüme hareketi için ortaya çıkan mikro-Doppler imzası Şekil 2.3'te gösterilmektedir. Hareket bileşenleri incelendiğinde ana Doppler kayması üzerine kol ve bacakların periyodik hareketlerinden kaynaklanan frekans kiplemeleri oluşmaktadır.



Şekil 2.3: Yürüme hareketi mikro-Doppler imzası

2.2 Zaman Frekans Gösterimi

Sinyallerin spektral bileşenleri, zamanın bir fonksiyonu olduğu durumda geleneksel Fourier dönüşümü zamana bağlı spektral bilgileri tam olarak veremez. Fourier analizi sinyallerin sonsuz zaman ve periyodikliğe sahip olduğunu varsaymaktadır. Ancak pratikte çoğu sinyal kısa zaman aralıklarına sahiptir ve aralıklarla değişmektedir. Örnek olarak, müzik enstrümanları sonsuz uzunlukta sinüsoidler üretmezler; bunun yerine başta yüksek bir girişe, sonra düşüşe sahip olurlar. Bu sinyalleri geleneksel metodlarla incelemek sinyalin kötü bir şekilde temsil edilmesine neden olacaktır.

Bundan dolayı, zaman frekans analizi, zamanla deęişen sinyalleri daha iyi anlamak için kullanılmaktadır.

Zaman frekans analizi, sinyalin zamanla deęişmesine baęlı olarak Fourier analizinin genelleşmesine ve gelişmesine neden olmaktadır. Kullanılan çoęu sinyalin - konuşma, müzik, görüntü, medikal - zamanla frekans karakteristięi deęiştiiğinden dolayı zaman frekans analizinin çok geniş bir kullanım alanı bulunmaktadır.

Zaman frekans dağılım fonksiyonunun oluşturulması için birçok yöntem önerilmektedir. Bunlardan birkaçına örnek vermek gerekirse

- Kısa zamanlı Fourier Dönüşümü (STFT)
- Dalgacık Dönüşümü (Wavelet)
- Bilinear Zaman-Frekans Dağılım Fonksiyonu ('Wigner dağılım fonksiyonu')
- Geliştirilmiş Wigner Dağılım Fonksiyonu, Gabor Wigner dağılımı

Zaman frekans dağılımlarının belirli özelliklere sahip olması gerekmektedir. Bunlardan bazıları, analizi ve yorumlamayı kolaylaştıracak yüksek çözünürlük, gerçek elemanların gürültüyle karışmasını engelleyecek karşı terim olmaması, gerçek hayata uygulanabilmesi için matematiksel olarak mantıklı olması ve zamansal kısıtların düşürülebilmesi için düşük hesaplama gücü. Bazı zaman frekans dağılım fonksiyonlarının yukarıda tanımlanan özelliklere göre karşılaştırmaları Çizelge 2.1' de verilmektedir.

Çizelge 2.1: Zaman-frekans dağılım fonksiyonlarının karşılaştırılması [38]

	Anlaşılrlık	Karşı Terim	Matematiksel Özelliler	Hesaplama Gücü
Gabor Dönüşümü	Kötü	Yok	Kötü	Düşük
Wigner Dağılım Fonksiyonu	En İyi	Neredeyse elenmiş	En İyi	Yüksek
Gabor-Wigner Dağılım Fonksiyonu	İyi	Yok	İyi	Orta

Sinyalleri iyi bir şekilde temsil etmek ve incelemek için, uygun zaman frekans analiz yönteminin seçilmesi kritik bir önem taşımaktadır. Hangi zaman frekans analiz yönteminin kullanılması gerektiği kullanılacak uygulamaya göre değişmektedir. Bu çalışmada en çok kullanılan ve kolay bir yöntem olan KZFD yöntemi kullanılmaktadır. KZFD aşağıda verilen denklem ile temsil edilmektedir.

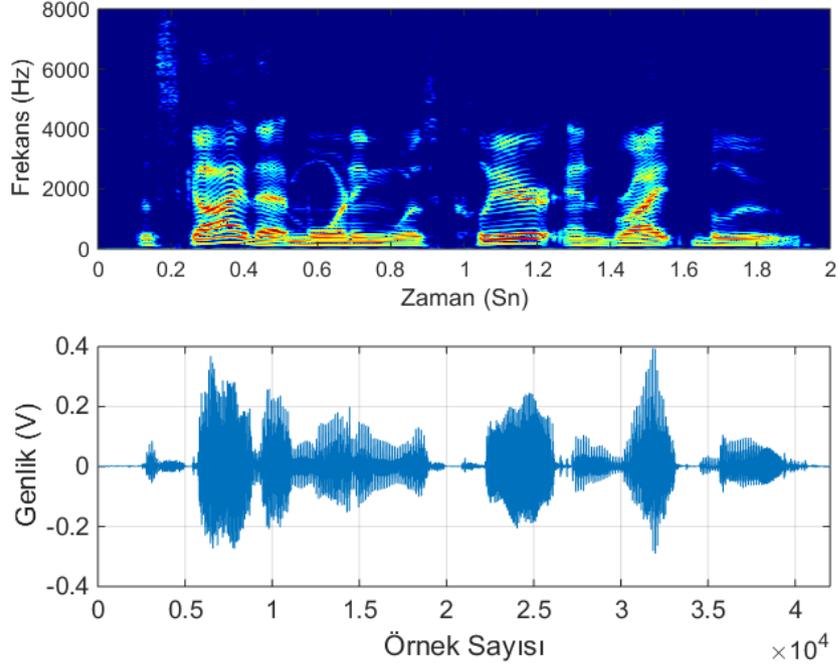
$$KZFD(n, w) = \sum_{-\infty}^{\infty} x[n + m]w[m]e^{-jwm} \quad (2.10)$$

Burada, $x[n]$ sinyal ve $w[m]$ pencere fonksiyonu olarak tanımlanmaktadır. Pencere fonksiyonun uzunluğu zaman ve frekans çözünürlüğünü etkilemektedir. KZFD’de en çok kullanılan yöntem Hızlı Fourier dönüşümüdür (Fast Fourier Transform: FFT). Bundan dolayı m ve w ayrık ve nicelenmiştir. Oluşturulan spektrogramlar ise KZFD’nin genliğinin karesidir.

$$Spektrogram\{x(t)\}(\tau, w) = |X(\tau, w)|^2 \quad (2.10)$$

Ses sinyalleri de zamana bağlı olarak değişen bir yapıya sahiptir. Bundan dolayı ses sinyallerinin özelliklerini yakalayabilmek için bir zaman frekans analiz yöntemi olan KZFD kullanılmaktadır. Örnek bir ses sinyali ve buna karşılık gelen KZFD

spektrogramı Şekil 2.4’de verilmektedir. Şekilde sesin periyodik olan bölmelerindeki frekans bileşenleri kolaylıkla görülebilmektedir.



Şekil 2.4: Kısa Zamanlı Fourier Dönüşümünün bir ses sinyaline uygulanması

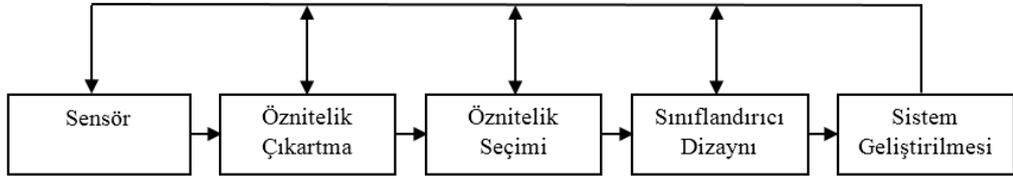
2.3 Sınıflandırıcılar ve Öznitelik Seçim Yöntemleri

Radar ile insan hareket sınıflandırması günümüzde çok önemli bir problemdir. Bu problemin çözülebilmesi, birden çok araştırma konusunun ortak ilgi alanı olmaktadır. Bu alanlara örnek olarak radar sinyal işleme, anten tasarımı, dijital sinyal işleme, makine öğrenmesi verilebilir. Sinyal işleme algoritmaları başarıyla uygulansa bile kurulan sistemin başarımını ölçmek için makine öğrenmesi yöntemlerine ihtiyaç duyulmaktadır. Özellikle sınıflandırma teknikleri, radar ile insan hareketlerinin ayırt edilebilmesi için önemli bir araştırma konusudur.

Makine öğrenmesi ve örüntü tanımanın asıl amacı, farklı kategorilere ait objelerin sınıflandırılması üzerinedir. Araştırma konusuna bağlı olarak bu objeler resimler veya sinyaller olabilmektedir. Bu çalışmada objeler farklı hareketlere ait mikro-Doppler imzaları olarak tanımlanmaktadır. Örüntü tanıma ve makine öğrenmesi; konuşma

tanıma, bilgisayarlı görü, biyomedikal uygulamalar, robotik gibi birçok aktif araştırma alanında kullanılmaktadır.

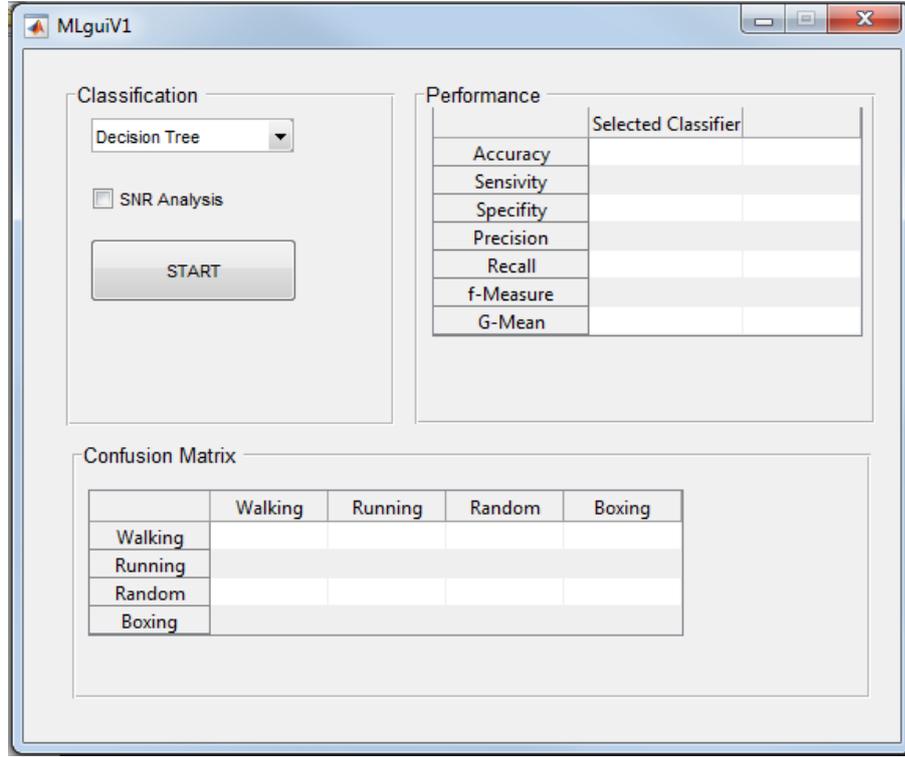
Örüntü tanıma kendi içinde birçok dala ayrılmaktadır. Alt dallardan bazılarını gerçekleştirmek için özel konularda bilgi deneyimin olması gerekmektedir. Sınıflandırma sisteminin evrelerini anlatan bir grafik Şekil 2.5’de verilmektedir.



Şekil 2.5: En temel sınıflandırma sistem yapısı

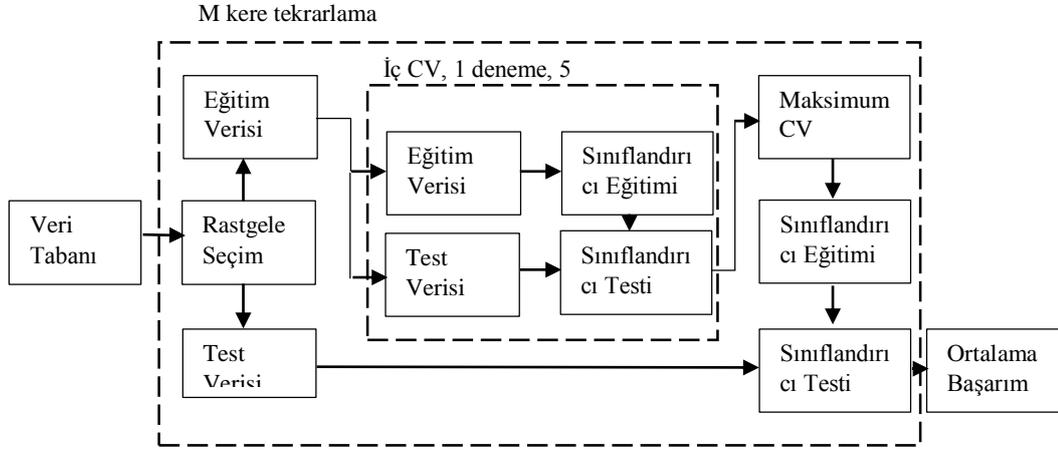
Bu çalışmada toplam olarak 7 temel sınıflandırıcı kullanılmıştır. Bu sınıflandırıcılardan 5 tanesi literatürde çok kullanılmakta olup 2 tanesi diğerlerine göre daha kolay olarak tanımlanan sınıflandırıcılardır. Bu sınıflandırıcılar sırasıyla Karar Ağaçları (Decision Tree), Biçimsel Regresyon (Logistic Regression), SVM, k En Yakın Komşu (k-Nearest Neighbors: kNN), Saf Bayes (Naive Bayes), Dışbükey Zarf ve Kare Uydurmadır.

Sınıflandırıcıların daha düzenli bir biçimde çalışabilmesi için Şekil 2.6’da gösterilen MATLAB tabanlı kullanıcı arayüzü oluşturulmuştur. Bu arayüzde kullanıcı veritabanını sisteme girmekte ve istenen sınıflandırıcıyı seçerek belirlenen metriklere göre oluşan sonuçlara ve karışıklık matrislerine ulaşmaktadır.



Şekil 2.6: Sınıflandırıcılar için oluşturulan kullanıcı arayüzü

Sınıflandırıcılarda kullanılan eğitim ve test yöntemi Şekil 2.7’de gösterilmektedir. Veritabanı oluşturulduktan sonra öznelilik çıkarma işlemi gerçekleştirilmekte, gözlemler ve öznelilikler bir matris durumuna getirilmektedir. Rastgele seçim ile verilerin %60’ı eğitim verisi, %40’ı ise test verisi olarak ayrılır. Rastgele seçim uygulanmasının sebebi verinin ezberlenmesini engellemektir. Eğitim verilerinin %15’i ile yeni bir test ve eğitim seti tekrardan ayrılarak sınıflandırıcı eğitimi ve testi yapılmaktadır. Bu işlem 5 kez tekrar etmektedir. En yüksek başarıyı sağlayan eğitim seti alınmakta ve sınıflandırıcı eğitimi gerçekleştirilmektedir. İlk başta ayrılan test verisi kullanılarak sınıflandırıcı testi yapılmaktadır. Bu prosedür M kere tekrarlanmakta ve ortalama başarımlar hesaplanmaktadır. Uygulanan bu şemayla sınıflandırıcının verileri ezberlemesinin önüne geçilmektedir.



Şekil 2.7: Sınıflandırma için oluşturulan şema

Karar ağaçları örüntü tanıma, veri madenciliği ve makine öğrenmesi konularında sıkça kullanılan bir sınıflandırma yöntemidir. Daha kompleks birçok sınıflandırma yönteminin literatürde bulunmasına rağmen, karar ağaçları, kolay yorumu ve rahatça anlaşılabilmesi nedeniyle diğer sınıflandırıcılara göre avantaj sağlamaktadır [38]. Karar ağaçları düşük maliyetli olması, anlaşılmasının, yorumlanmasının ve veri tabanları ile entegrasyonunu kolaylığı, güvenilirliklerinin iyi olması gibi nedenlerden ötürü en yaygın kullanılan sınıflandırma tekniklerinden biridir [39]. Örnek bir karar ağacı algoritması Çizelge 2.2’de gösterilmektedir.

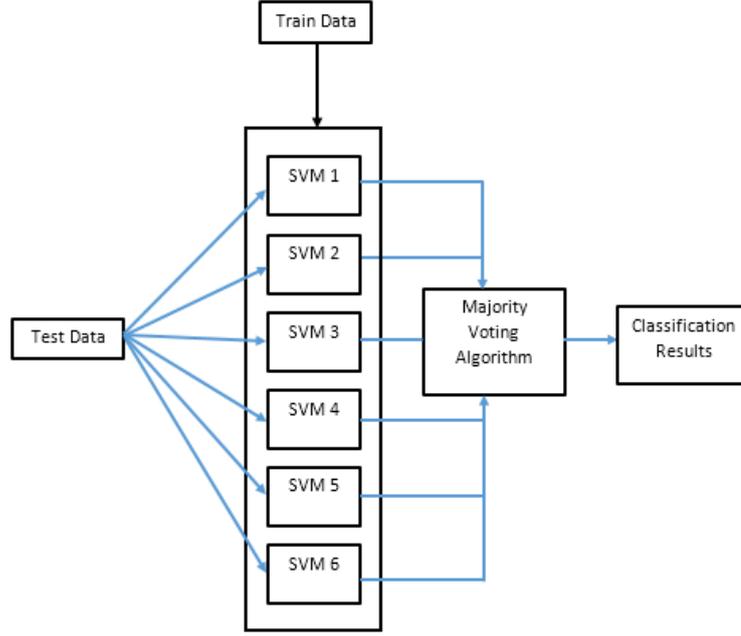
Çizelge 2.2: ID3 Karar ağacı algoritması

<p>ID3(S, Hedef, Öznitelikler)</p> <ol style="list-style-type: none"> 1. A: Örnekleri en iyi ayıran öznitelik 2. Bu düğüm için test özniteliği --- A 3. Her A değeri v için: <ul style="list-style-type: none"> - Her v_i için bir dal ekle - Eğer $S_{v_i} = \emptyset$ <ul style="list-style-type: none"> “S’deki en genel değer” etiketiyle bir yaprak düğüm ekle. - Else <ul style="list-style-type: none"> Bir alt ağaç ekle ID3(S_{v_i}, Hedef, Öznitelikler –{A}) 4. Köke geri dön

Biçimsel regresyon istatistik ve makine öğrenmesi gibi konularda oldukça kullanılan bir yöntemdir. Bu sınıflandırma yönteminde öğrenme fonksiyonu $f: X \rightarrow Y$, veya $P(Y|X)$, olduğu durumda Y ayrık değerlere sahip olur ve $X = \langle X_1 \dots X_n \rangle$ ayrık veya devamlı değerler içeren bir vektör haline gelir. Lojistik regresyon $P(Y|X)$ dağılımı için bir parametrik form oluşturur ve parametreleri eğitim setinden direk olarak tahmin etmeye çalışır.

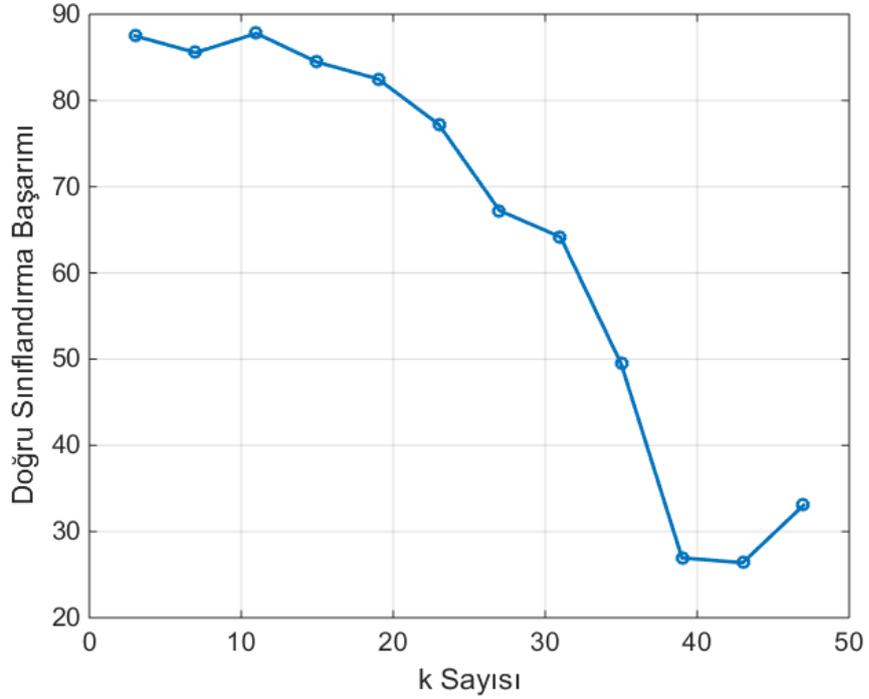
SVM örüntü tanıma ve makine öğrenmesi gibi konularda oldukça kullanılan başarılı bir yöntemdir. SVM denetlenen bir öğrenim algoritması olarak tanımlanmaktadır. İki kategoriye ait eğitim örneklerine bakarak SVM algoritması bir model oluşturur ve yeni örnekleri doğru olarak kategorize etmeye çalışır. SVM olasılıksal olmayan ikili lineer sınıflandırıcıdır. SVM sadece iki sınıflı verilerin ayrılmasında kullanılmaktadır. Literatürde bu durumu çözmek için birçok yöntem önerilmektedir. Bu çalışmada SVM'in çoklu sınıf problemine adapte edilebilmesi için çoklu oylama yöntemi kullanılmıştır. Bu yöntemin şeması Şekil 2.8'de gösterilmektedir. Çoklu oylama yönteminde tüm sınıflar ikili sınıflara bölünmekte ve bir sınıflandırıcı oluşturulup yeni veriler test edilmektedir. İkili sınıflardan oluşmuş sınıflandırıcılar en fazla hangi sınıfı seçmiş ise genel karar o seçilmektedir. Bu yöntem çok sınıflı yapılar için yavaş çalışmaktadır. Bunun sebebi ikili kombinasyonların oluşturulması ve bunun her test örneği için tekrarlanmasıdır. Aynı zamanda tüm sınıflara aynı uzayda bakılmadığından dolayı uzayda bazı bölgeler taranamakta ve o bölgelerde olan test verileri yanlış sınıflandırılmaktadır.

Çok boyutlu ve iki sınıflı uzay düşünüldüğünde iki sınıfı ayırabilecek birçok yöntem olduğu görülmektedir. Bunlardan bir tanesi uzayda iki sınıf ayırarak şekilde hiperdüzlem çizilmesidir. Bu yöntem lineer sınıflandırıcı olarak adlandırılmaktadır. Ancak uzayda birçok hiperdüzlem iki sınıfı ayırabilecek yapıya sahip olabilmektedir. Bundan dolayı sınıflandırma başarımını maksimum yapabilmek için uzayda iki sınıf arasındaki en fazla uzaklığı sağlayan hiperdüzlemi seçilmelidir. Yani seçilecek olan hiperdüzlemin sınıflar arasındaki uzaklığı maksimize etmesi gerekmektedir. SVM en basit şekilde bu yapıyı kurmaya çalışmaktadır.



Şekil 2.8: Çoklu Oylama yöntem şeması

kNN yöntemi, sınıflandırma problemi üzerine yoğunlaşan bir yarı denetimli makine öğrenme tekniğidir. Yöntem, veri tabanında bulunan verileri çok boyutlu uzaya yerleştirir. Yeni gelen test verisi için uzayda temsil edilen tüm eğitim verileri ile aralarında bir uzaklık ölçümü yapar. Uzaklık ölçümleri kullanılacak uygulamaya göre değişiklik göstermektedir. En çok kullanılan uzaklık metriği Öklid uzaklığıdır. Uzaklık ölçümü yapıldıktan sonra en yakın k nokta seçilir ve bu noktaların sınıflarına bakılır. Yeni gelen test verisinin sınıfı bu noktaların en fazla bulunduğu sınıf olarak atanır. kNN yöntemi diğer yöntemlere göre daha yavaş çalışmaktadır. Bunun sebebi tüm örnek sayısı kadar bir uzaklık ölçümünün yapılmasından kaynaklanmaktadır. Aynı zaman k sayısına göre sınıflandırma başarımları değişmektedir. Radar ile insan hareket sınıflandırma problemi için Şekil 2.9’da verilen grafik bu duruma örnek olarak gösterilebilir. K sayısı arttığı durumda sınıflandırma başarımında gözle görülür bir düşüş meydana gelmektedir. Bunun sebebi uzayda bakılan bölgenin yarıçapının büyümesi olarak görülebilmektedir.



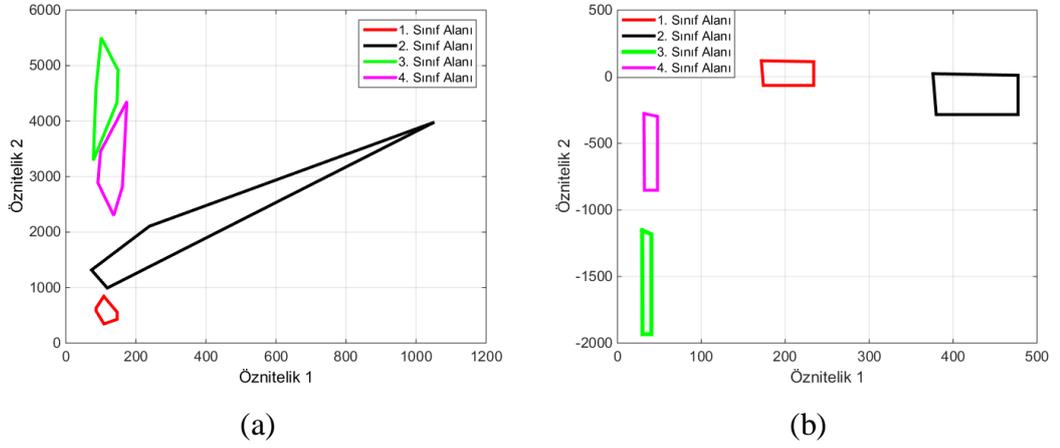
Şekil 2.9: *k- En Yakın Komşu sınıflandırıcısının k sayısına bağlılığı*

Saf Bayes sınıflandırıcısı makine öğrenmesi alanında kullanılan olasılıksal bir modeldir. Bu yöntem oldukça ölçeklenebilir bir yapıya sahiptir. Saf Bayes sınıflandırıcısı her bir özneliği bağımsız olarak düşünür ve birbirlerini etkilemediklerini varsayar. Bu sınıflandırıcı denetimli öğrenim metodu olarak verimli bir şekilde eğitilebilmektedir. Çoğu saf Bayes sınıflandırıcısı parametre tespiti için Maksimum Olabilirlik yöntemini kullanmaktadır.

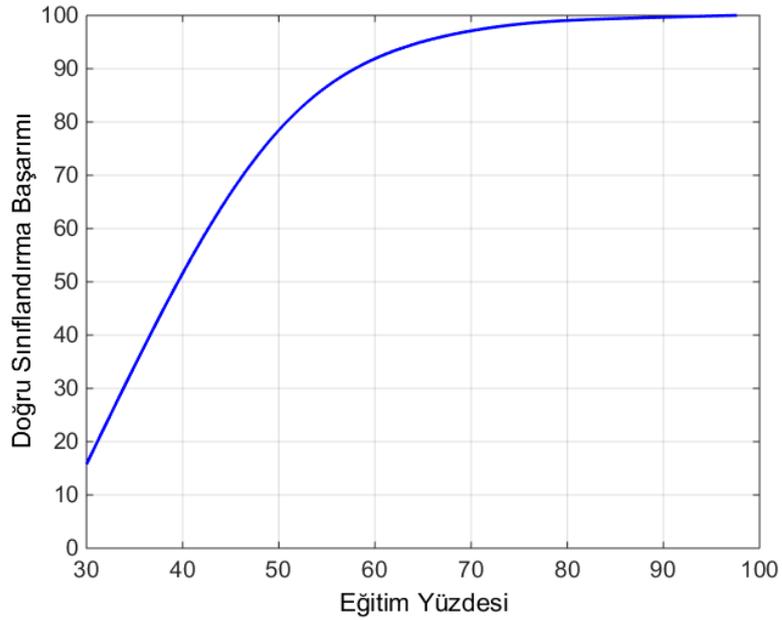
Dışbükey Zarf sınıflandırıcısı diğer sınıflandırıcılara göre daha basit ve kolay bir yöntemdir. İlk olarak veri tabanı eğitim ve test olmak üzere ikiye ayrılmaktadır. Eğitim setindeki özneliklerin ikili kombinasyonlarına bakılarak her bir sınıf için ayrı bir dış bükey zarf tanımlanmaktadır. Dışbükey zarfların tanımlanması Şekil 2.10.a'da gösterilmektedir. Tüm öznelik ikili kombinasyonları için bu zarflar tanımlandıktan sonra test verilerinin bu dışbükey zarfların içine düşüp düşmediği kontrol edilmekte ve başarımlar buna göre hesaplanmaktadır. Dışbükeyler öznelik dağılımının köşeleri olarak belirlenmektedir. Bu yöntem için eğitim yüzdesinin etkisi Şekil 2.11'de radar ile insan hareket sınıflandırma problemi için gösterilmektedir. Şekil 2.11'den de

kolaylıkla anlaşılacağı gibi eğitim yüzdesi arttıkça sınıflandırma başarımı artmaktadır. Tüm sınıflandırıcılar için sonucun bu şekilde olması beklenmektedir.

Kare uydurma yöntemi de Dışbükey Zarf yöntemine benzer bir şekilde çalışmaktadır. Özniteliklerin ikili kombinasyonlarına bakarak eğitim seti üzerinde sınıflar için ayrı kare-dikdörtgen alanlar oluşturmakta ve test setlerinin bu alanların içine düşüp düşmediğine bakmaktadır. Kare uydurma yöntemi örnek olarak Şekil 2.10.b' de verilmektedir.



Şekil 2.10: (a) Dışbükey Zarf ve (b) Kare Uydurma Sınıflandırıcıları



Şekil 2.11: Dışbükey Zarf yöntemi için eğitim yüzdesine olan bağımlılık

Öznitelik çıkartma ve oluşturma işlemi tamamlandıktan sonra diğer önemli bir kısım ise öznitelik seçimi ile alakalıdır. Çoğu uygulamada öznitelik sayıları fazla olmakta ve sınıflandırma işleminin yapılmasını zorlaştırmaktadır. Bu durum makine öğrenmesinde çok boyutluluğun laneti olarak tanımlanmaktadır. Öznitelik sayısı doğrudan uzay boyutunu arttıracak ve boyut artmasından dolayı sınıflandırıcılar kompleks bir yapıya sahip olacak ve hesaplama gücü de buna oranla artacaktır. Aynı zamanda çok boyutlu durumlarda öznitelikler birbirlerine benzemekte ve sınıflandırıcılar yanlış kararlar vermektedir. Bu durumun aşılabilmesi için literatürde birçok öznitelik seçim algoritması bulunmaktadır. Bu çalışmada kullanılan öznitelik seçim ve boyut indirgeme algoritmaları, PCA, ileri sarmalı öznitelik seçimi (Sequential Feature Selection : SFS), t-test filtre ve korelasyon yöntemi olarak sıralanmaktadır.

PCA bir boyut indirgeme algoritması olup, ortogonal dönüşüm kullanarak birbiriyle aralarında korelasyon bulunan gözlemlerin lineer olarak aralarında korelasyon olmayan bir yapıya dönüştürülmesi işlemine denmektedir [40]. PCA yönteminin uygulanması için literatürde birçok yöntem bulunmaktadır. Bu çalışmada uygulanan yöntem Çizelge 2.3'de verilmektedir.

Çizelge 2.3: Temel Bileşen Analiz yöntemi

1. n boyutlu veritabanından ortalama değerleri bul.
2. Hesaplanan ortalama değerleri veritabanından çıkart.
3. Ortalama çıkartılmış veritabanından kovaryans matrisi hesapla.
4. 3. Adımda bulunan kovaryans matris için özdeğer ve özvektörleri hesapla.
5. En yüksek özdeğere sahip olan özvektörleri sırala.
6. Bu özvektörler veritabanının temel bileşenleridir.

Öznitelik seçimi için iki ana yaklaşım bulunmaktadır: filtre yöntemleri ve ileri-geri sarmalı öznitelik seçim yöntemleri [41]. Filtre yöntemleri özniteliklerin arasında bulunan ayırıcı farklılıkları bulabilmek için bazı metrikler kullanmaktadır. Bu metrik incelemesinde yüksek skora sahip olan öznitelikler seçilmek de düşükler çıkartılmaktadır. Filtre yöntemlerinin en büyük avantajı sınıflandırma sonuçlarından bağımsız olarak bir seçim yapmalarıdır. Bu çalışmada t-test filtre yöntemi

kullanılmıştır. T-test istatistiksel bir yöntem olması sebebiyle iki sınıf arasındaki ortalamaya bakmaktadır. c . sınıfta bulunan i . öznitelik için t istatistiği:

$$t_{ic} = \frac{\bar{x}_{ic} - \bar{x}_i}{M_c(S_i - S_0)} \quad (2.11)$$

Burada \bar{x}_{ic} c . sınıfta bulunan i . özniteliğin ortalaması ve \bar{x}_i ise i . özniteliğin tüm sınıflar için ortalama değeridir. S_i i . özniteliğin standart sapması, S_0 ise medyan olarak tanımlanmaktadır. Standart sapma

$$S_i^2 = \frac{1}{N - C} \sum_{c=1}^C \sum_{j \in c} (x_{ij} - \bar{x}_{ic})^2 \quad (2.12)$$

Burada $N - C$ sınıfta bulunan tüm örneklerin sayısı ve x_{ij} j . örneğin i . özniteliğidir. Sabit olarak tanımlanan M_c c . sınıftaki örnek sayısı cinsinden tanımlanmaktadır

$$M_c = \sqrt{\frac{1}{n_c} + \frac{1}{N}} \quad (2.13)$$

İleri ve geri sarmalı öznitelik seçim yöntemleri, kaba kuvvet yaklaşımı kullanarak öznitelik kümesindeki en iyi başarıyı sağlayan öznitelik alt kümesini bulmaya çalışmaktadır. Bu yöntemler metrik kullanmak yerine, seçilen sınıflandırıcıyı kullanarak sınıflandırma başarımını hesaplamakta ve buna iteratif olarak devam etmektedir. Kullanılan arama uzayı öznitelik sayısına bağlı olarak artmakta ve her adımda hesaplama gücü filtre yöntemlerine göre fazla olmaktadır. Bu çalışmada SFS yöntemi kullanılmıştır. SFS önceden belirlenmiş obje fonksiyonunu maksimize etmeye çalışmaktadır. Bu fonksiyon sınıflandırma başarımı olarak tanımlanmıştır. SFS algoritması Çizelge 2.4'de verilmektedir.

Çizelge 2.4: SFS algoritması

1. Boş bir fonksiyon ile başla $F(\emptyset)$
2. Bir önceki seçilen öznelik ile en yüksek başarımlı performansı veren öznelik, x seç.
3. Öznelik kümesini güncelle ve $F_{k+1} = F_k + x$ ve k 'yi artır.
4. 2. basamağı tekrarla.

Sınıflandırma başarımlarının test edilebilmesi için literatürde çeşitli metrikler kullanılmaktadır. Bu çalışmada kullanılan metrikler ve tanımları Çizelge 2.5' de verilmektedir. Burada TP gerçek pozitif, TN gerçek negatif, FN yanlış negatif, FP yanlış pozitif, P pozitif, N negatif olarak tanımlanmaktadır.

Çizelge 2.5: Sınıflandırma performansı için kullanılan metrik açıklamaları

İsim	Simge	Açıklama
Doğruluk	ACC	$(TP + TN)/(P + N)$
Hassaslık	TPR	$TP / P = TP/(TP + FN)$
Spesifiklik	SPC	$TN / N = TN/(TN + FP)$
Kesinlik	PPV	$TP/(TP + FN)$
F skoru	F1	$2TP/(2TP + FP + FN)$

3 KİNET TABANLI RADAR BENZETİMİ

3.1 Radar Benzetimi

Gelen radar sinyali gönderilen sinyalin zamanda geçikmiş halidir. Gidiş geliş zaman kayması t_d , hedef menzili R 'ye bağlıdır ($t_d = \frac{2R}{c}$). Bundan dolayı, lineer frekans kiplenmiş (Linear Frequency Modulation: LFM) darbe-Doppler radarının nokta hedef için dönüş sinyali

$$s_r(n, t) = a_t \text{rect} \left(\frac{\hat{t} - t_d}{\tau} \right) e^{j[-2\pi f_c t_d + \pi \gamma (\hat{t} - t_d)^2]} \quad (3.1)$$

Burada zaman t , PRF cinsinden $t = T(n - 1) + \hat{t}$ olarak tanımlanmıştır. Darbe sayısı n , her bir darbe tekrarlama aralığı (Pulse Repetition Interval: PRI) başlangıcındaki zaman kayması \hat{t} , a_t radar menzil denklemi tarafından belirlenen genlik, τ darbe genişliği, c ışık hızı, γ ötüş oranı (Chirp Rate) ve f_c gönderilen merkez frekansını temsil etmektedir.

Hedef dönüşüyle beraber, radar ayrıca aydınlatılan ancak hedef olmayan yüzeylerden de dönüş almaktadır. Bu dönüşler kargaşa olarak isimlendirmektedir. Kargaşa, diğer gürültü kaynaklarının etkileri ve girişimler simülasyona eklenmek istenirse, gerekli matematiksel modellemeler yapıldıktan sonra (3.1) denklemine eklenebilir. Buradaki asıl amaç insan mikro-Doppler imzalarının çıkartılması olduğundan dolayı bu etkiler incelenmemektedir. Ancak ilerdeki bölümlerde değişik operasyonel koşulların başarımlar üzerindeki etkileri detaylı olarak incelenecektir.

İnsanlar nokta hedeflerden çok daha kompleks bir yapıya sahiptirler. Geisheimer [17] ve Van Dorp [18] tarafından yapılan çalışmalarda gösterdiği gibi toplam insan radar dönüşü insan vücudunda bulunan sonlu sayıdaki hedef noktalara üstdüşüm ilkesi uygulanarak bulunabilir. Çalışmalarda da gösterildiği gibi oluşan spektrogramlar

gerçek radar dönüşleriyle benzerlik göstermektedir. Bundan dolayı insan vücudu K parçaya ayrılırsa toplam insan radar dönüşü

$$s_h(n, t) = \sum_{i=1}^K a_{t,i} \text{rect} \left(\frac{\hat{t} - t_{d,i}}{\tau} \right) e^{j[-2\pi f_c t_{d,i} + \pi \gamma (\hat{t} - t_{d,i})^2]} \quad (3.2)$$

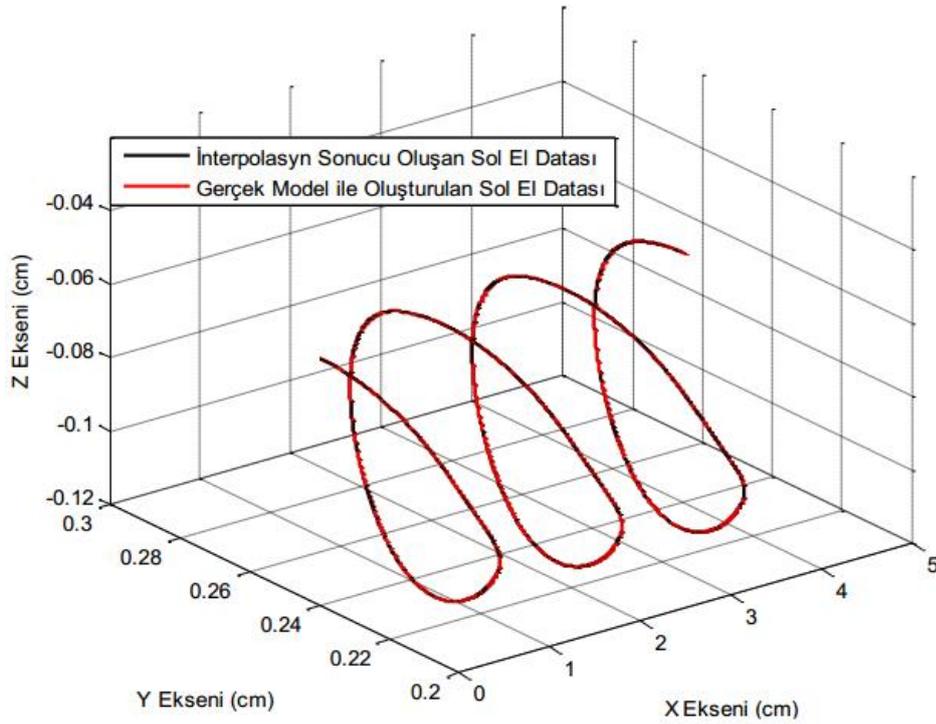
Burada $a_{t,i}$ genlik ve her bir parçanın zamanda kaymış halini temsil etmektedir. Genlik $a_{t,i}$ radar menzil denkleminde

$$a_{t,i} = \frac{G \lambda \sqrt{P_t \sigma_i}}{(4\pi)^{1/5} R_i^2 \sqrt{L_s} \sqrt{L_a}} \quad (3.3)$$

Görüldüğü gibi genlik, hedef menzili R_i ve geometri ile değişmektedir. Anten kazancı - G - geliş açısıyla, atmosferik kayıplar hedef menzili ile değişmektedir. İnsan mikro-Doppler imzaları hedef faz bilgisinden çıkartıldığından ve genliğin etkisi az olduğundan dolayı (3.2)'de tanımlanan parametreler ve gönderilen sinyal gücü P_t , dalgaboyu λ , ve sistem kayıpları L_s sabit kabul olarak kabul edilmiştir. Radar kesit alanı (Radar Cross Section: RCS), σ_i insan vücut parçalarının şekillerine göre modellenmiştir. Bundan dolayı insan kafasının RCS'ı küre şeklinde, diğer vücut parçaları ise elipsoid şeklinde modellenmiştir.

Denklem (3.2)'nin hesaplanabilmesi için insan vücudunun zamanla değişen pozisyon bilgilerine ihtiyaç duyulmaktadır. Bu çalışmada, insan vücut parçalarının zamanla değişen pozisyon bilgilerini bulabilmek için Kinect sensörü kullanılmıştır. Geliştirilen MATLAB tabanlı program insan iskeletini oluşturarak, her bir çerçevedeki insan iskelet eklemleri için 3 boyutlu koordinat bilgilerini vermektedir. Kinect'den alınan örnekleme hızı yaklaşık olarak 18 Hz olarak bulunmuştur. Ancak bu örnekleme hızı mantıklı bir mikro-Doppler imzasının çıkartılması için yeterli değildir. Bundan dolayı Kinect'den alınan menzil verisi kübik şeritleme ara değerlendirme yöntemi ile 2400

Hz'e yükseltilmiştir. Kullanılan kübik şeritleme ara değerlendirme yönteminin başarıyla çalıştığını göstermek için Boulic modeli kullanılarak örnekleme frekansı 2400 Hz ve 200 Hz olan iki farklı yürüme verisi oluşturulmuştur. Karşılaştırılma yapılabilmesi için iki verininde sol el 3 boyut pozisyon bilgileri saklanmıştır. Örnekleme frekansı 200 Hz olan sol el verisi alınarak Kinect verilerinin interpolasyonu için kullanılan ara değerlendirme yöntemine konulmuş ve örnekleme frekansı 2400 Hz değerine çıkartılmıştır. İnterpolasyon sonucu ortaya çıkan veri ile gerçek veri Şekil 3.1'de gösterilmektedir. Grafikte eksenler cm cinsindedir. Grafikte anlaşılacağı gibi ara değerlendirme sonucu oluşan veriler ile gerçek veriler arasında büyük bir fark gözlemlenmemektedir.



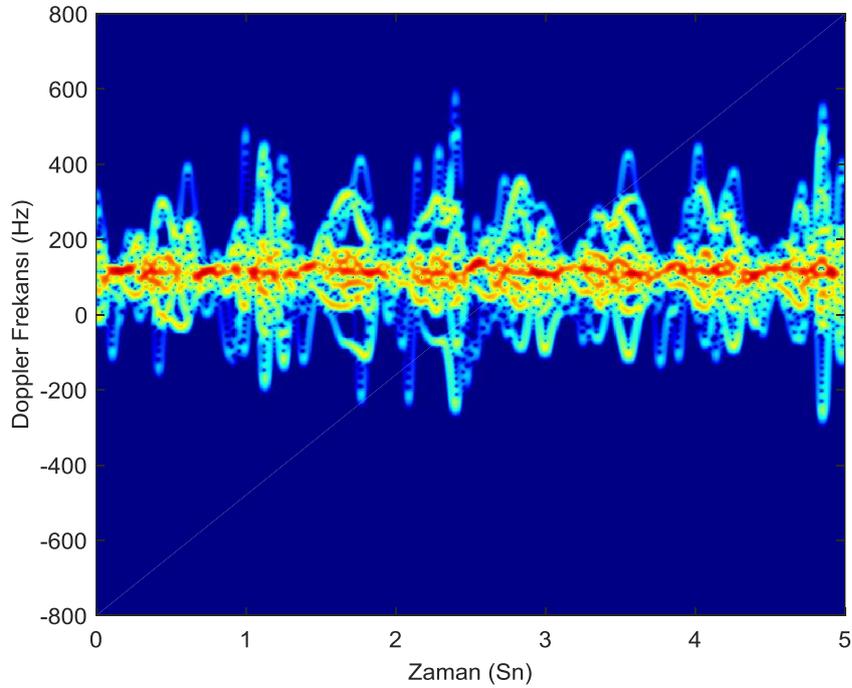
Şekil 3.1: Ara Değerlendirme ile gerçek verilerin karşılaştırılması

Sonrasında radarın pozisyonu, insan hedef pozisyonu ve hareket açısına bağlı olarak zamanla değişen nokta hedef menzilleri hesaplanmaktadır. Kinect ölçümleri kalça merkezi tarafından belirlendiğinden istenen hedef yolları; radar ile vücut nokta hedefleri arasındaki 3 boyutlu pozisyon bilgilerinden hesaplanabilmektedir. Yükseliş ve yönelim etkileri mikro-Doppler simülasyonuna eklenmiştir.

Kinect'den alınan veriler ile menzil bilgisi hesaplandıktan sonra, denklem (3.2) kullanılarak istenilen insan aktivitesi radar parametrelerine bağlı olarak - merkez frekansı, PRI - hesaplanabilmektedir. Literatürde birçok zaman frekans analiz yöntemi bulunmasına rağmen Bölüm 2.2'de bahsedildiği gibi KZFD spektrogramların oluşturulması için kullanılmaktadır. İnsan mikro-Doppler imzasının ortaya çıkartılabilmesi için ilk olarak veriye darbe sıkıştırma uygulanması gerekmektedir. Bu işlemden sonra hedefin olduğu noktada bir tepe ortaya çıkmaktadır. Oluşturulan verilerin sadece hedef konumunda olduğu varsayılırsa darbe sıkıştırılmış radar dönüşü

$$x_p[n] = \sum_{i=1}^K a_{t,i} \tau e^{-\frac{j(4\pi f_c)}{c} R_{d,i}} \quad (3.4)$$

Burada $R_{d,i}$ vücut merkezinden radara olan uzaklık olarak tanımlanmaktadır. Bundan sonra KZFD alınarak spektrogramlar oluşturulmaktadır. Örnek bir spektrogram Şekil 3.2'de gösterilmektedir.



Şekil 3.2: Kinect tabanlı yürüme spektrogramı

3.2 Literatürde Kullanılan Benzetimler

Geliştirilen algoritmaların değerlendirilmesi için benzetim kullanılması kritik önem taşımaktadır. Benzetim verilerinin varlığı, deneysel radar verilerine ulaşma imkanının olmadığı akademik veya sistem henüz geliştirme aşamasında olduğu için veri toplamanın mümkün olmadığı endüstriyel ortamlarda çalışmayı mümkün kıldığı için son derece önemlidir. Aynı zamanda benzetim sayesinde çoğu gerçek radarın sahip olmadığı radar parametrelerin değiştirilmesi olanağını sunulmaktadır. Böylelikle farklı radarlar için benzetimler yapılabilen ve oluşturulan mikro-Doppler imzaları ile radar parametrelerinin sınıflandırma başarımı üzerindeki etkisi gösterilebilmektedir.

Literatürde bulunan çalışmalar incelendiğinde değişik senaryolar ve durumlar için benzetimler yapılmaktadır. Mekan içi insan takibi [42], hesaplanan ağırlık merkezlerine göre oluşturulan benzetim yapısı [18], multistatik radar için gerçek veriler ile benzetim verilerinin karşılaştırılması [43] gibi birçok araştırma literatürde bulunmaktadır.

Genelde insan verisi iki farklı yöntemle üretilmektedir: 1) Kinematik modeller, veya 2) MOCAP verileri kullanılarak. Her iki yöntem vücutta bulunan nokta hedefleri elipsoid veya küre olarak modelleyip, RCS ve sonrasında dönen radar sinyalini hesaplamaktadır. Tanımlanan noktasal hedeflerin zamanla değişen pozisyonu, kinematik modeller veya MOCAP verilerinden hesaplanmaktadır. Tüm insan vücudundan yansıyan radar sinyali ise üstdüşüm ilkesinden yararlanılarak noktasal hedeflerden yansıyan tüm sinyallerin toplamını alarak oluşturulmaktadır.

Bu yöntemlerden farklı olarak insanın radar yansıması çok ayrıntılı bir elektromanyetik modelleme işlemi yapılarak sonlu eleman analizi ile de elde edilebilmektedir. Özellikle, sonlu eleman analizi insanın RCS'ini hesaplamak ve modellemek için kullanılmaktadır. Bu da literatürde bahsedilen en ayrıntılı hedef modelleme yöntemi olarak ortaya çıkmaktadır [44].

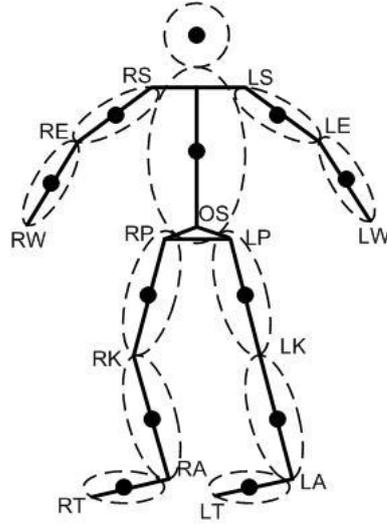
3.2.1 Boulic Modeli

Boulic yürüme modelinde [45] vücut 12 parçaya ayrılmıştır: baş, üst kollar, alt kollar, gövde, baldırlar, bacaklar ve ayaklar. Vücut parçaları Şekil 3.3’de gösterilmektedir. Her bir nokta hedefin zamanla değişen pozisyonudur ve vücut ölçümleri, modelde verilen denklem ve grafiklerle hesaplanabilmektedir. İlk bakışta model çok ayrıntılı gözükse de kullanılan tüm denklemler ve grafikler aslında sadece iki değişkene bağlıdır: İnsanın yürüme hızı ve bel uzunluğu. Vücut parçalarının açısal değişimleri genelde grafiksel olarak verildiğinden Boulic modeli kapalı-form bir model değildir. Kapalı-form olmaması Boulic modelinin insan sezimi gibi teorik hesaplamalar gerektiren konularda kullanımını kısıtlaya da mikro-Doppler benzetimi için Boulic modeli yürüme hareketinin benzetimi konusunda oldukça başarılıdır. Mikro-Doppler benzetimi uygulamasında birçok araştırmacı Boulic modelini kullanmaktadır. Bu nedenle Boulic yürüme modelinin mikro-Doppler literatüründeki yeri önemlidir.

Boulic modeliyle vücut parçalarının zamanla değişen pozisyonlarını hesaplamak için modellenmesi istenen insanın her parçasının uzunluğunun bilinmesi gerekmektedir. Modelde bulunan bir tablo ile vücut parçalarının hem erkek hem kadın için %5’lik ve %95’lik uzunlukları verilmektedir. İnsanın boyu Gauss dağılımlı olduğundan dolayı vücut parçalarının da Gauss dağılımlı olduğu varsayılmaktadır. Bu tabloya bakılarak istenen herhangi cinsiyet ve boy için vücut parçalarının uzunlukları hesaplanabilmektedir.

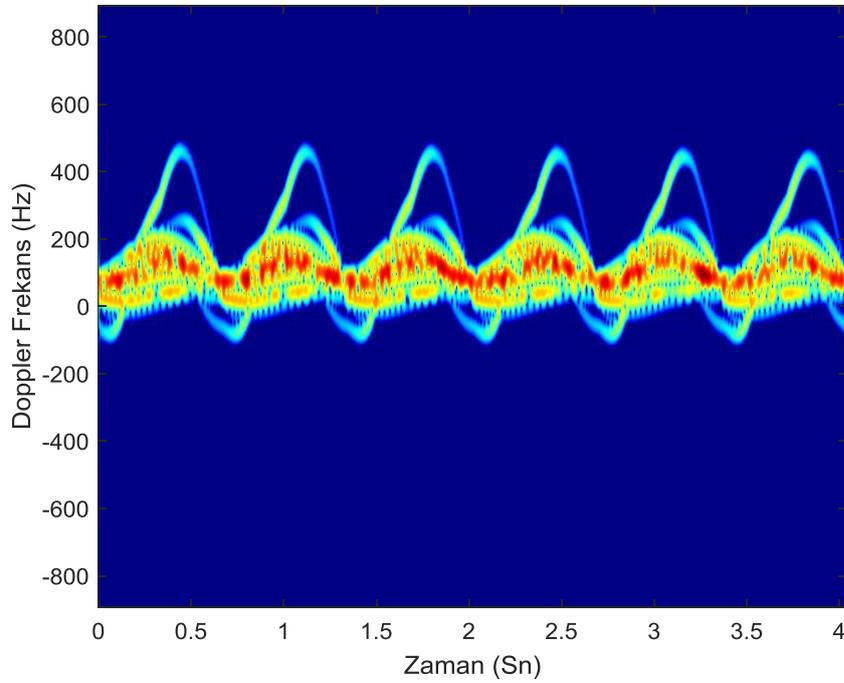
$$k = \Phi(x) = \frac{1}{2\pi} \int_{-\infty}^x e^{-t^2/2} dt \quad (3.5)$$

Burada vücut parçasının uzunluğu, $d_{bp} = \mu_{bp} + k\sigma_{bp}$ olarak tanımlanmaktadır. Vücut parça dağılımının ortalaması ve varyansı ise sırasıyla: μ_{bp} , σ_{bp} .



Şekil 3.3: İnsan vücudunu temsil etmek için kullanılan 12 noktasal hedef modeli [46]

Her noktasal hedefin zamanla değişen pozisyonu Boulic modeliyle hesaplandıktan sonra alınan radar sinyali radar menzil denklemi ile hesaplanabilmektedir. Bölüm 3.1’de bahsedilen radar benzetim adımları uygulandığında ortaya çıkan yürüme spektrogramı Şekil 3.4’de verilmektedir.



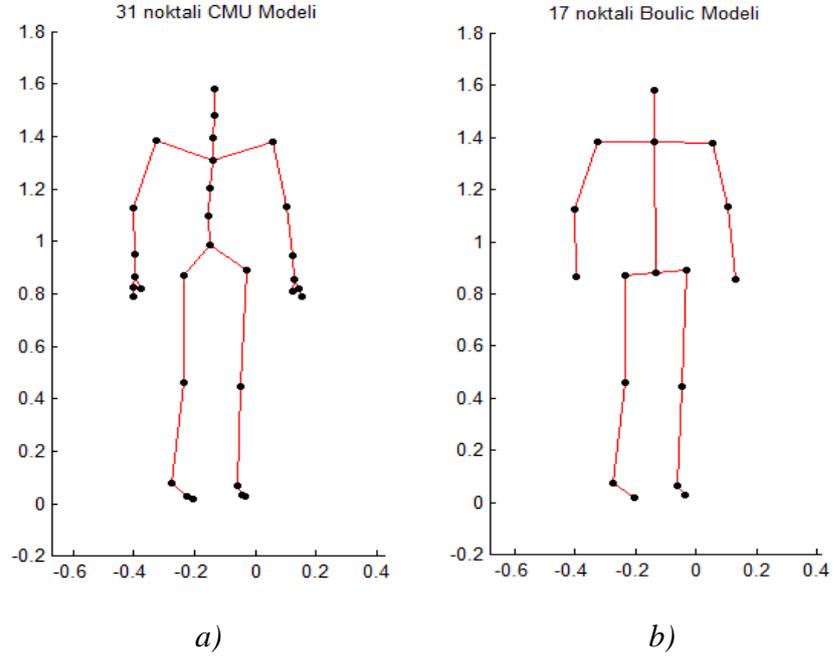
Şekil 3.4: Boulic tabanlı yürüme spektrogramı

3.2.2 CMU Veri Tabanı ile Oluşturulan Model

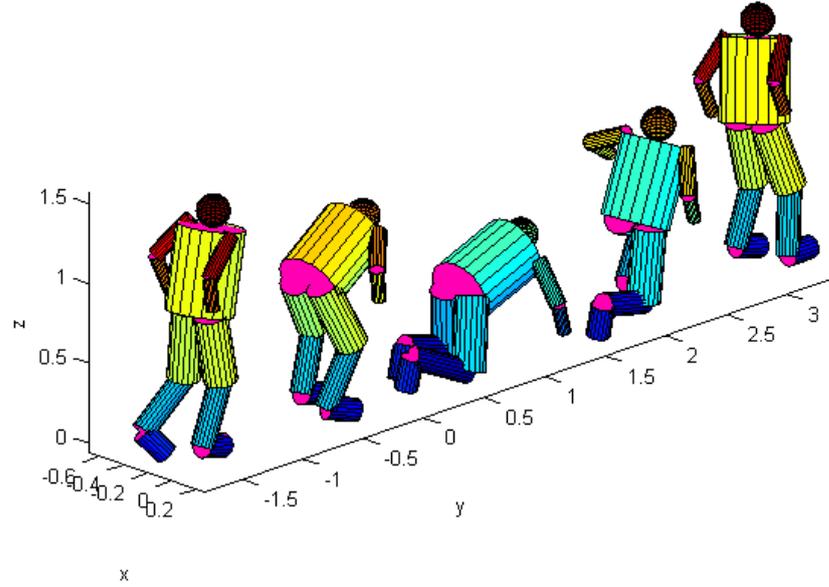
Boulic modeli deneysel verilerle uyumlu sonuçlar vermesine rağmen sadece yürüme hareketi için tanımlandığından bazı çalışmalarda yetersiz kalmaktadır. İnsana ait koşma, emekleme, nesne taşıma, tırmanma gibi hareketlerin tespitinde Boulic modelinden faydalanmak söz konusu değildir. Bu sebepten dolayı son yıllarda MOCAP verileriyle insan benzetimi yapılması önerilmiştir [47]. Bu amaçla, bazı araştırmacılar Carnegie Mellon Üniversitesi (CMÜ) Grafik Laboratuvarı tarafından kullanıma sunulan MOCAP veritabanını kullanmıştır [48]. Bu veritabanı, 112 deneğe ait toplam 2605 adet insan hareketi içermektedir. Yürüme, koşma, emekleme, tırmanma, merdiven çıkma, tekme atma gibi birçok farklı kategorideki hareket bulunmaktadır. İnsan vücuduna 41 adet işaretleyici nokta yerleştirilip 12 IR kamera ile bu işaretleyicilerin konumları zaman içinde tespit edilerek kayıt altına alınmıştır. Farklı deneklere ait, farklı kategorilerde çok miktarda veri sunmasından ötürü bu veritabanındaki verilerin benzetimlerde kullanımı araştırmacılara büyük kolaylık sağlamaktadır.

CMÜ hareket algılama veritabanından elde edilen veri, ağaç yapısı şeklinde düzenlenmiş 30 vücut parçasının verilerinden oluşmaktadır. Her bir parçanın verisi ağaç yapısı içinde kendi üstünde bulunan parçaya göre, yön ve dönme eksenlerinin açıları şeklinde sunulmaktadır. Her bir noktanın XYZ düzleminde aldığı değerler, bu bilgiler yardımıyla ileri kinematik hesaplamalar yapılarak bulunur.

CMÜ veritabanı verileri, radar çalışmalarında benzetim amacıyla kullanılan Boulic modeline göre daha ayrıntılı bir iskelet yapısı sunmaktadır. Örneğin, Boulic modelinde kol, alt ve üst olmak üzere iki parçadan oluşurken, CMÜ verilerinde altı parçadan oluşmaktadır. Boulic ve CMÜ verilerinin insan yapı karşılaştırılması Şekil 3.5'te verilmektedir. CMÜ verileriyle oluşturulmuş sıralı olarak alınan yürüme-emekleme-yürüme verisine ait animasyon görüntüsü Şekil 3.6'da gösterilmektedir.

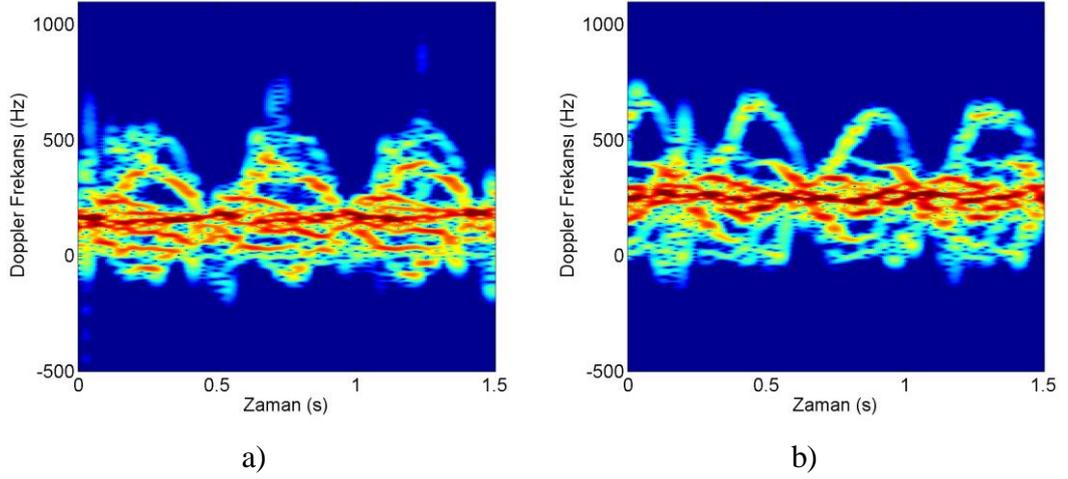


Şekil 3.5: Oluşturulan insan modeli- a) 31 noktayı içeren asıl model, b) 14 nokta çıkartılarak oluşturulan model [48]



Şekil 3.6: Yürüme-emekleme-yürüme verisinden benzetim yapılarak oluşturulan örnek görüntü [48]

CMÜ verileri ile oluşturulmuş farklı hareketler için ortaya çıkan spektrogramlar Şekil 3.7’de verilmektedir. Şekil 3.7 incelendiğinde MOCAP verileriyle kinematik modeller kullanarak ortaya çıkan mikro-Doppler imzalarının uyumlu olduğu görülmektedir.



Şekil 3.7: CMÜ tabanlı a) yürüme b) koşma hareket spektrogramları [48]

3.3 Kinect ile İskelet Takibi Algoritması

Veritabanlarında kayıtlı bulunan kullanıma açık, yüksek kaliteli MOCAP verilerinin en büyük dezavantajı kontrol dışında olmasıdır. Deneylede kullanılan deneklerin özellikleri (cinsiyet, boy, kilo vb.) ve kaydedilen hareketler ile hareket süreleri seçilememektedir. Aynı zamanda her hareketten farklı sayıda örnek olduğundan dolayı sınıflandırma yapılırken sorunlar ortaya çıkmaktadır. Diğer problem ise MOCAP sistemi kurmak ve veri toplamak çok maliyetli bir işlemdir. Örneğin, Organic Motion’nın geliştirdiği MOCAP sistemlerinin fiyatları 80.000 - 120.000 TL arasında değişmektedir. Bu çalışmada Kinect sensöründen yararlanan, maliyeti çok daha ucuz bir Kinect tabanlı MOCAP sistemi geliştirilmiştir [4].

Kinect içinde renkli kamera, dahili mikrofon, IR projektörü ve IR kamera barındıran Microsoft, Rare ve PrimeSense kuruluşları tarafından ortak geliştirilen bir hareket algılayıcısıdır. Örnek bir Kinect resmi Şekil 3.8’de gösterilmektedir. Piyasaya oyun

konsollarının bir parçası olarak çıkmasına rağmen biyomedikal ve robotik gibi birçok farklı alanda kullanılmaktadır.

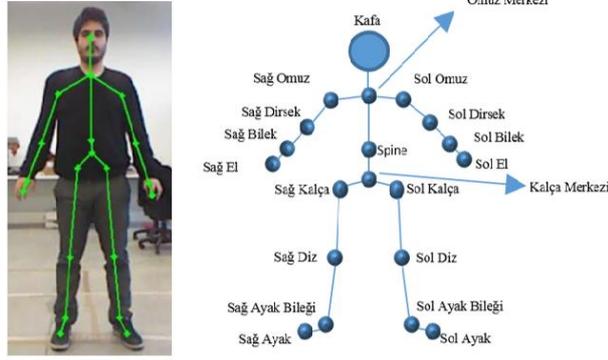


Şekil 3.8: Kinect algılayıcısının görünümü [4]

Kinect'in içinde bulunan IR projektörü, görüş alanında olan cisimlerin üstünde IR noktalardan oluşan bir alan yaratmaktadır. Oluşturulan IR noktaları insan gözü tarafından algınamasa da bu noktalar tarafından oluşturulan alanın görüntüsü IR kamera kullanılarak algılanabilmektedir. Algılanan bu görüntüden, iskelet yapısı ve insan vücudunda bulunan eklemlerin büyük bir kısmının 3 boyutlu uzayda bulunduğu pozisyon bilgileri çıkartılabilmektedir.

İskelet takibi günümüzde önemli bir problem olup insan bilgisayar etkileşimi, hareket yakalama ve hareket tanımlama dahil birçok alanda kullanılmaktadır. Ancak geniş uzay parametreleri ve bazı kısıtlamalardan dolayı iskelet takibinde zorluklar yaşanmaktadır. Kinect ile iskelet takibi yapılırken karşılaşılan diğer zorluklar ise IR kameranın görüş alanı, hatasız veri alabilmek için doğru ayarlanması gereken Kinect'in pozisyonu ve deneyin yapıldığı ortamdaki kaynaklanan sorunlar olarak belirlenmektedir. Bu sorunlar çözülmediği takdirde oluşturulan derinlik haritası etkilenecek ve çıkartılan verilerin doğruluk oranını düşecektir.

Yapılan çalışmada, iskelet takibini sağlayan yazılım MATLAB programı kullanılarak hazırlanmıştır. Oluşturulan yazılım Kinect'ten alınan derinlik haritasına erişebilmekte ve derinlik haritasından çıkartılan bilgiler ile iskelet takibi yapabilmektedir. Yazılım insan vücudunda bulunan on yedi farklı eklemi ve uç noktayı bulabilmekte; gerçek zamanlı olarak bu noktaların 3 boyutlu uzayda buldukları pozisyon bilgilerini kaydetmektedir. Örnek bir iskelet takibi Şekil 3.9' de gösterilmektedir.

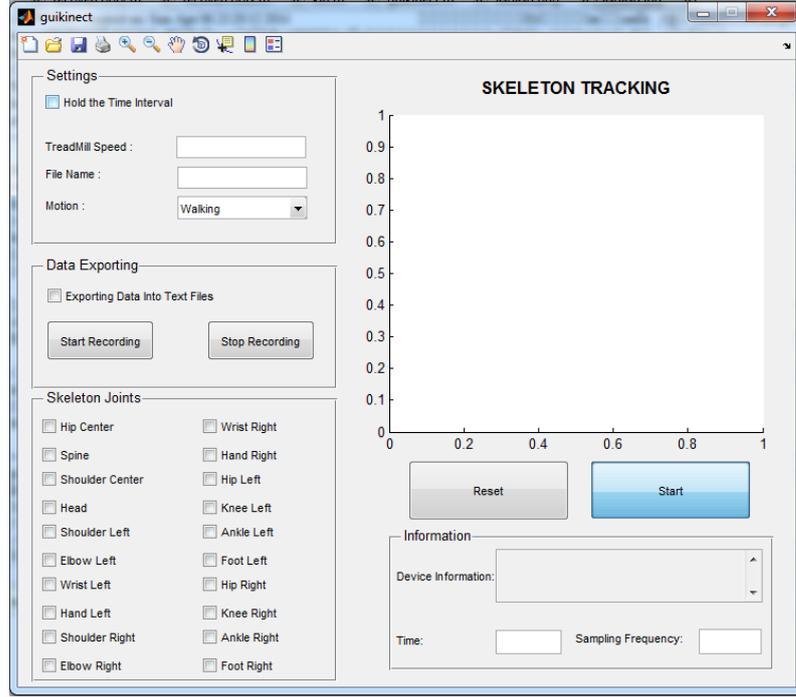


Şekil 3.9: Kinect iskelet takibi ve insan eklem modeli

İnsan hareketlerinin radar benzetiminin yapılabilmesi için vücuttaki eklem ve uç noktaların 3 boyutlu uzaydaki pozisyon bilgilerinin bilinmesi gerekmektedir. Bu çalışmada, kullanılan yazılım hareket benzetimi yapabilmek için gereken ve Thalmann [45] tarafından tanımlanan on yedi noktanın pozisyon bilgisini kaydetmektedir. Bu noktalar; kafa, boyun, omuzlar, dirsekler, eller, kalçalar, omurga kök noktası, dizler, bilekler ve ayak uçlarıdır. Programda veri alım süresi kullanıcıya bağlıdır. Veri alımı sonlandığında program otomatik olarak veri alım zamanı, deneğin hızı ve örnekleme frekansını vermektedir. Bu üç çıktı, hareketin radar benzetiminin yapılabilmesi için girdi olarak kullanılmaktadır. Oluşturulan MATLAB tabanlı kullanıcı arayüzü Şekil 3.10'de gösterilmektedir.

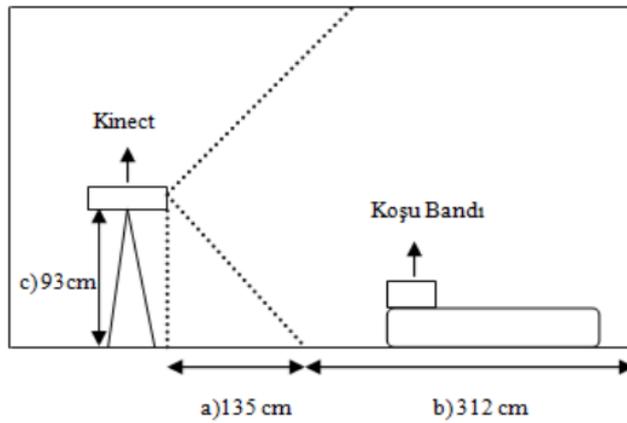
3.4 Oluşturulan Veri Tabanı

Bu çalışmada Kinect tabanlı mikro-Doppler benzetim sistemi kullanılarak farklı hareketlerin ve farklı koşulların bulunduğu bir veritabanı oluşturulmuştur. Veri alımı TOBB ETÜ Uzaktan Algılama Laboratuvarı'nda gerçekleştirilmiştir. Veri tabanında 5 hareket bulunmaktadır: Sırasıyla yürüme, koşma, karışık hareketler, zıplama ve boks hareketleridir. Veri tabanında emekleme ve sürünme gibi hareketlerin bulunmamasının sebebi Kinect'in iskelet takibi yapabilmek için insanları önden ve ayakta görmek zorunda olmasından kaynaklanmaktadır.

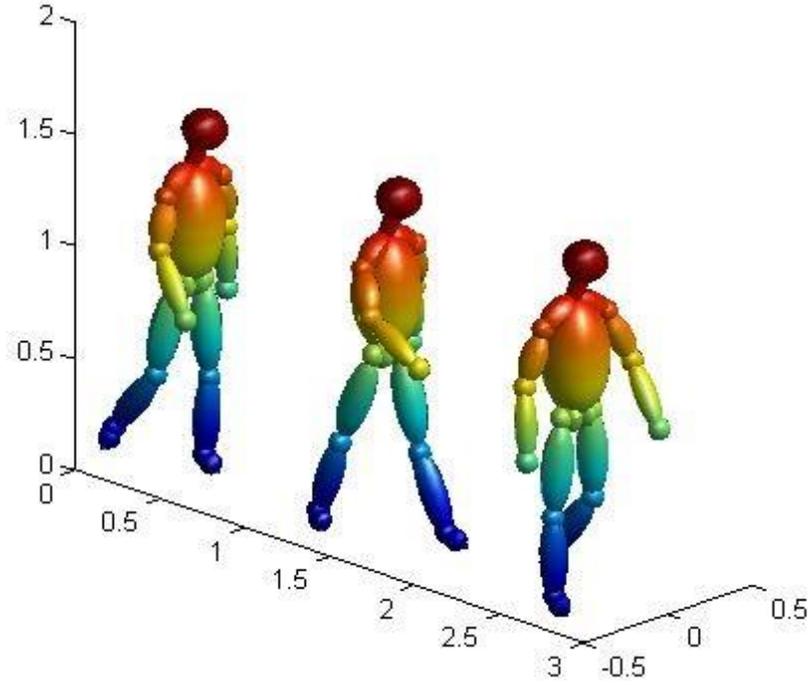


Şekil 3.10: İskelet takibi için oluşturulan MATLAB tabanlı kullanıcı arayüzü

Kinect'in derinlik menzilinin alt ve üst limitlerinden dolayı uzun süreli veri alınamamaktadır. Bundan dolayı yürüme, koşma ve karışık hareketler gibi periyodik ve uzun zamana ihtiyaç duyan hareketlerin veri alınmasını kolaylaştırmak için Kinect'in önüne bir koşu bandı konumlandırılmıştır. Hazırlanan deney düzeneği Şekil 3.11'da gösterilmektedir. Kinect verileri kullanılarak elde edilmiş bir insan yürüme animasyon görüntüleri ise Şekil 3.12'da gösterilmektedir.



Şekil 3.11: İskelet takibi için oluşturulan MATLAB tabanlı kullanıcı arayüzü



Şekil 3.12: Kinect tabanlı insan yürüme animasyonu

Veri tabanı oluşturulurken her bir hareket 5 kez kaydedilmiştir. Hareketlerin örnek süreleri 3 - 30 saniye arasında değişmektedir. Deneylere 18 kişi katılmıştır. Deneklerin boyları 1.61 ile 1.87 arasında, kiloları ise 55 kg ile 135 kg arasında değişmektedir.

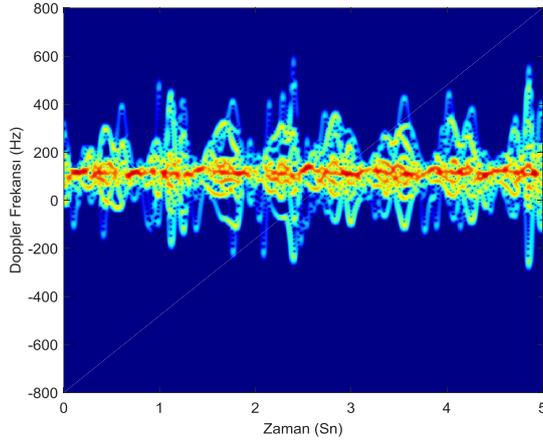
Benzetimler yapılırken radar parametreleri - merkez frekansı, PRF -, SGO ve görüş açısına bağlı olarak farklı benzetim parametreleri kullanılarak veriler oluşturulmuştur. Parametrelere bağlı veri sayıları Çizelge 3.1'de detaylı biçimde açıklanmaktadır.

Benzetimde kullanılan radar özellikleri: Taşıyıcı frekansı 15 GHz, darbe tekrarlama sıklığı 2400 Hz, menzil çözünürlüğü 1 m ve monostatik radar. Bu radar kullanılarak 5 farklı hareket için ortaya çıkan mikro-Doppler imzaları Şekil 3.13'da gösterilmektedir. Birleşik zaman frekans analizi yapılırken KZFD işlemi, 256 noktalı Hamming pencereleri üzerinden 16 noktada örtüşme olacak şekilde alınmıştır. Kullanılan Hızlı Fourier Dönüşümü uzunluğu 1024 olarak belirlenmiştir.

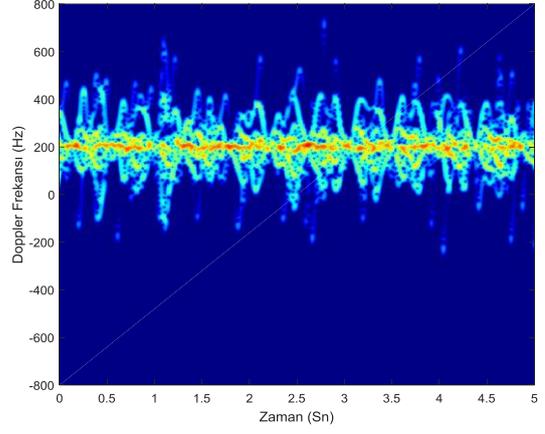
Çizelge 3.1: Kinect mikro-Doppler veri tabanı

	Aralık	Artış Basamakları	Toplam Veri
Görüş Açısı (°)	0 – 180	15	1560
SGO (dB)	0 – 35	5	840
PRF (Hz)	400 – 7400	1000	960
Merkez Frekansı (GHz)	1 – 75	Frekans Bant Sınırları	960
Hedef Üzerinde Kalma Süresi (Sn)	0.2 – 5	0.1	5880

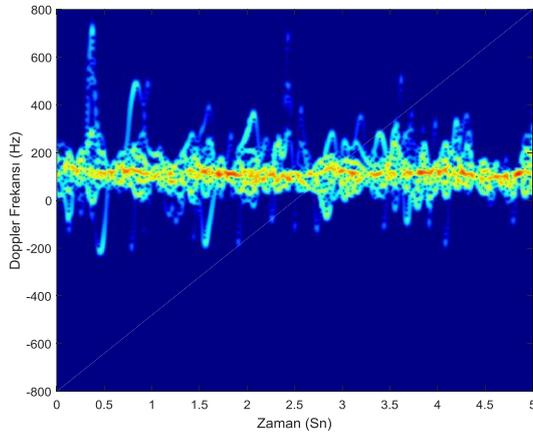
Şekil 3.12’de verilen spektrogramlar incelendiğinde dört hareketin mikro-Doppler imzalarının birbirinden farklılık gösterdiği görülmektedir. Yürüme hareketinin spektrogramında kol ve bacakların periyodik hareketi sonucu spektrogramda da periyodik salınımlar oluşmaktadır. Yürüme esnasında kolların geriye doğru hareket etmesi nedeniyle negatif Doppler frekansları görülmektedir. Bu negatif frekanslar aynı zamanda koşu bandından dolayı da oluşmaktadır. Koşu bandı bacağı geri götürerek bacağa negatif bir hız verilmesine sebep olmaktadır. Koşmanın yürümeden daha hızlı bir hareket olmasından dolayı gövdeden dönen sinyalin hızı koşma spektrogramında daha yukarıdadır. Ayrıca koşmanın daha periyodik bir hareket olmasından dolayı aynı süre zarfında daha çok salınım görülmektedir. Boks egzersizi hareketinde bacaklar ve gövde sabit durduğu için bu parçalardan dönen sinyalin hızı sıfırdır. Hareket boyunca sadece kollar ileri ve geriye doğru hareket ettiği için kollardan dönen sinyaller bir miktar salınıma neden olmaktadır; fakat bu salınımlar diğer hareketlere oranla daha küçüktür. İleriye doğru zıplama hareketinde denek başlangıçta sabit dururken, iki bacağı birbirine yapışık şekilde ileri doğru sıçramıştır. Bu hareketin spektrogramı incelendiğinde hedefin sabit durduğu ve zıplamayı gerçekleştirdiği zamanı gözle ayırmak oldukça kolaydır. Zıplama hareketi esnasından yapılan öteleme hareketinden ötürü gövdenin radar cevabında meydana gelen artış rahatlıkla görülebilmektedir.



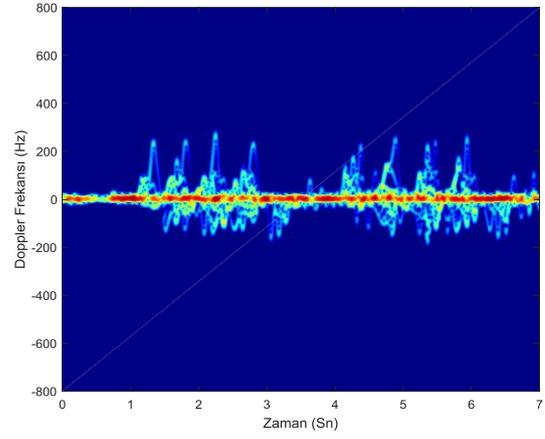
a)



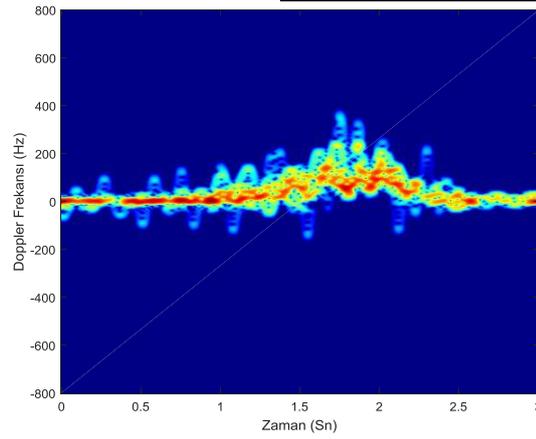
b)



c)



d)



e)

Şekil 3.13: Farklı insan hareketlerine ait spektrogramlar a) Yürüme b) Koşma c) Karışık Hareketler d) Boks egzersizleri e) İleriye doğru zıplama

Karışık hareket deneyleri yapılırken de kullanıcılardan istedikleri gibi yürümeleri istenmiştir. Her insan aynı şekilde yürümediği ve yürürken değişik hareketlerde bulunduğundan dolayı bir test kümesi yaratılmak istenmiştir. Bu hareketler içinde taşınma, sendeleme, selam verme, kolları esnetme gibi çeşitli hareketler bulunmaktadır. Ortaya çıkan mikro-Doppler imzası incelendiğinde yürüme ile neredeyse aynı hıza sahip olduğu, ancak kollardaki ve bacaklardaki salınımların farklı olduğu görülmektedir.

4 ÖZİNİTELİK ÇIKARIMI ve SINIFLANDIRMA SONUÇLARI

Öznitelik çıkarma işlemi makine öğrenmesi, örüntü tanıma gibi konularda büyük önem taşımaktadır. Sensörlerden alınan ölçümler veri tabanına aktarıldıktan sonra bu ölçümler hakkında yararlı bilgiler veren, sınıflar arası değişim gösteren, bağlılığı az, sınıflandırma ve genelleştirme işlemini başarıyla yapan özelleştirilmiş çıkarımlara öznitelik denmektedir.

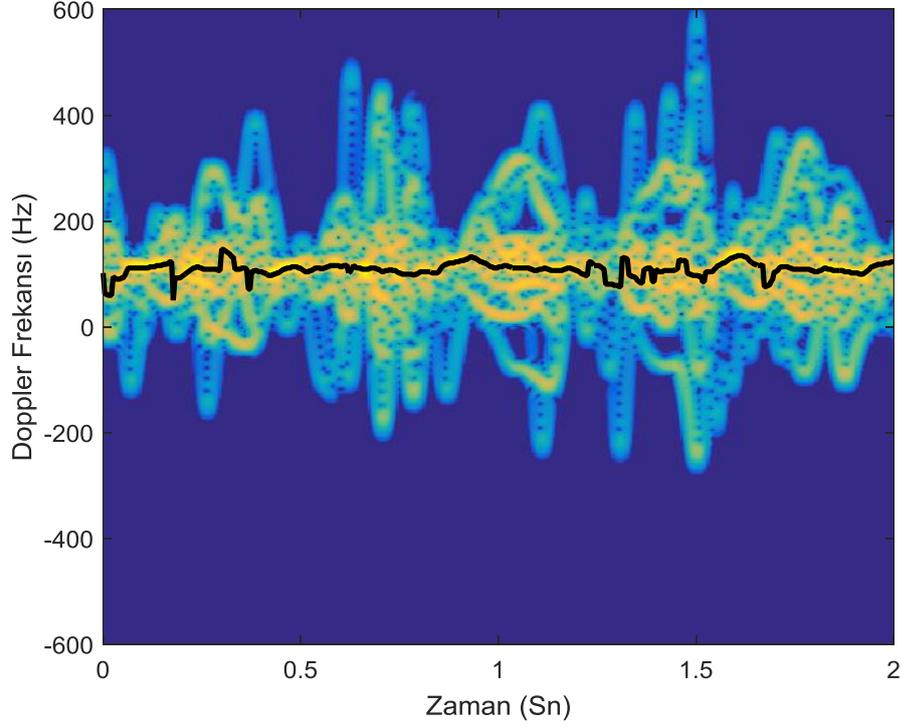
Literatürde mikro-Doppler insan tanıma konusu için birçok öznitelik önerilmektedir. Bu özniteliklerden bazıları bu çalışma kapsamında da incelenmektedir.

4.1 Fiziksel Öznitelikler

Fiziksel öznitelikler, radar I/Q verisinin KZFD alındıktan sonra ortaya çıkan spektrogramlar üzerinden bulunmaktadır. Farklı hareketlerin spektrogramları incelendiğinde ana Doppler kayması gövdede meydana gelmekte ve bu frekans kaymasının üzerine kol ve bacakların periyodik hareketlerinden dolayı frekans kiplemeleri oluşmaktadır. Fiziksel öznitelikler ile bulunmak istenen temel çıkarımlar, gövdeden yansıyan sinyalde meydana gelen ana Doppler kayması ve kol - bacak salınımlarının değişimleridir.

4.1.1 İnsan Gövdesine Bağlı Olarak Çıkarılan Öznitelikler

İnsan gövdesinden dönen sinyal, ana Doppler kaymasını meydana getirmekte ve diğer vücut parçalarından yansıyan sinyallere göre daha güçlü olmaktadır. Bunun sebebi insan gövdesinin diğer vücut parçalarına oranla daha geniş olmasından kaynaklanmaktadır. Bu kısımda insan gövdesinin yanıtına bağlı olarak iki farklı öznitelik çıkartılmıştır. Bunlar ortalama ana Doppler kayması ve ana Doppler kaymasının bant genişliği olarak tanımlanmaktadır. Ana Doppler kayması, örnek spektrogram üzerinde Şekil 4.1'de gösterilmektedir.



Şekil 4.1: Ana Doppler bileşenlerinin bulunması

Özniteliklerin matematiksel olarak ifade edilebilmesi için ilk olarak spektrogram tanımının yapılması gerekmektedir. $s(t)$ olarak tanımlanan bir sinyalin spektrogramı

$$\text{spektrogram}(t, w) = |KZFD(t, w)|^2 \quad (4.1)$$

Burada t zamanı, w frekans değerlerini temsil etmektedir. Spektrogramdaki ana Doppler kayması en güçlü bileşenlere sahip elemanlar tarafından temsil edilmektedir. Bundan dolayı spektrogram üzerinde her bir sütundaki en yüksek güce sahip olan elemanın bulunması gerekmektedir. Spektrogramda en yüksek güce sahip olan bileşenler bulunduktan sonra hangi frekans değerlerine karşılık geldikleri bulunduktan sonra frekans değerlerinin ortalaması alınmaktadır.

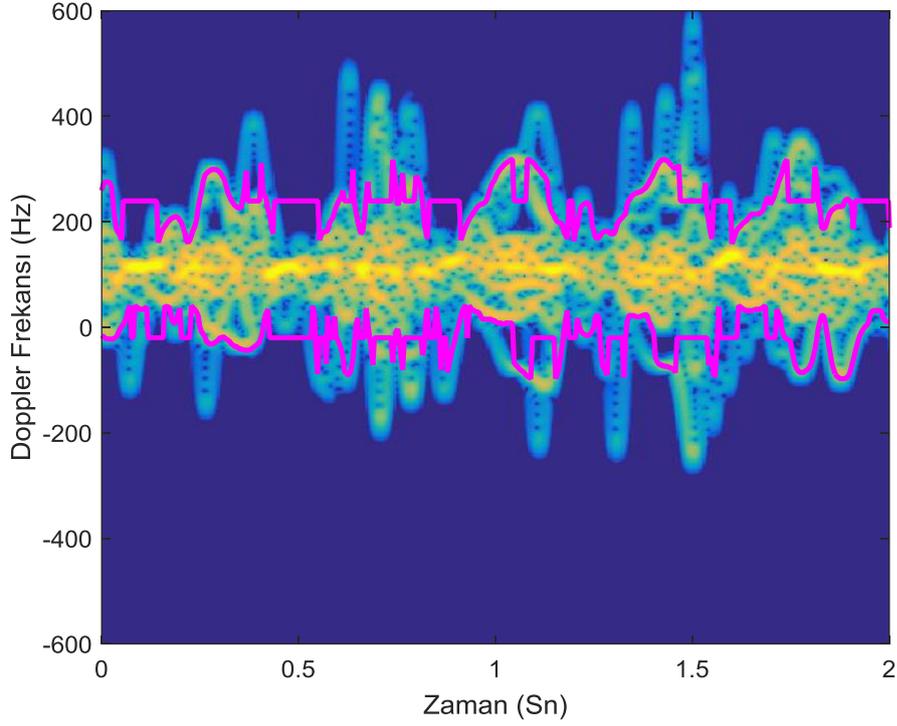
$$\begin{aligned}
P_t &= \arg \max_t \text{spektrogram}(t, w) \\
f_t &= w(P_t) \\
f_1 &= \left(\sum_{t=1}^T f_t \right) / (T - 1)
\end{aligned} \tag{4.2}$$

Ana Doppler kaymasının bant genişliği ise maksimum ve minimum frekans değerleri arasındaki fark alınarak bulunmektedir.

$$f_2 = \arg \max_t f_t - \min_t f_t \tag{4.3}$$

4.1.2 Kol ve Bacak Salınımlarına Bağlı Olarak Çıkartılan Öznitelikler

Kol ve bacak salınımlarının periyodik hareketlerinden kaynaklı frekans bileşenleri ana Doppler kayması üzerine kiplmeler yaratmaktadır. Kol ve bacak salınımlarına bağlı olarak 3 farklı öznitelik çıkartılmıştır. Bunlar sırasıyla: Üst kipleme frekans ortalaması, alt kipleme frekans ortalaması ve alt ve üst kiplmeler bant genişliğidir. Üst kipleme frekans ortalaması bulunurken, spektrogram sütunlarındaki belli bir eşik değerinden büyük güç değerine sahip ilk elemanlar bulunmaktadır. Bu işlem tüm spektrogram için yapıldıktan sonra bu tepe noktalarının hangi frekans değerlerine karşılık geldiği bulunmakta ve ortalaması alınarak üst kiplmelerin frekans değeri hesaplanmaktadır. Alt kipleme frekans ortalaması bulunurken, spektrogram sütunlarındaki belli bir eşik değerinden büyük güç değerine sahip son elemanlar bulunmaktadır. Bu işlem tüm spektrogram için yapıldıktan sonra bitiş noktalarının hangi frekans değerlerine karşılık geldiği bulunmakta ve ortalaması alınarak alt kiplmelerin frekans değeri hesaplanmaktadır. Alt ve üst kipleme bant genişliğini bulmak için üst kipleme frekans ortalaması ile alt kipleme frekans ortalaması arasındaki fark bulunmaktadır. Çıkartılan öznitelikler Şekil 4.2’de gösterilmektedir.



Şekil 4.2: Kol ve bacak salınımlarına bağlı öznitelikler

Veri tabanındaki tüm hareketler kullanılarak 6 kişinin her hareketi için 4 farklı deneme ile yukarıda tanımlanan 5 farklı fiziksel öznitelik çıkartılmıştır. Oluşturulan matris 7 farklı sınıflandırıcıya girdi olarak verilmiş ve çıktılar 5 farklı metrik cinsinden karşılaştırılmıştır. Ortaya çıkan sonuçlar Çizelge 4.1’de verilmektedir. Kullanılan sınıflandırıcılar sırasıyla karar ağaçları, lojistik regresyon, SVM, kNN, saf bayes, dışbükey zarf ve kare uydurmadır. Metrikler cinsinden sonuçlar incelendiğinde en yüksek başarımın SVM ve kNN ($k=5$) sınıflandırıcıları tarafından verildiği görülmektedir. Fiziksel özniteliklerin farklı hareketlere ait mikro-Doppler imzalarını ayırmada iyi sonuçlar verdiği saptanmıştır. Ancak fiziksel özniteliklerin çıkartılması için KZFD’ne ihtiyaç olması hesaplama gücünü ve buna bağlı olarak zamanında artmasına sebep olmaktadır.

Çizelge 4.1: Fiziksel özniteliklerin sınıflandırma sonuçları

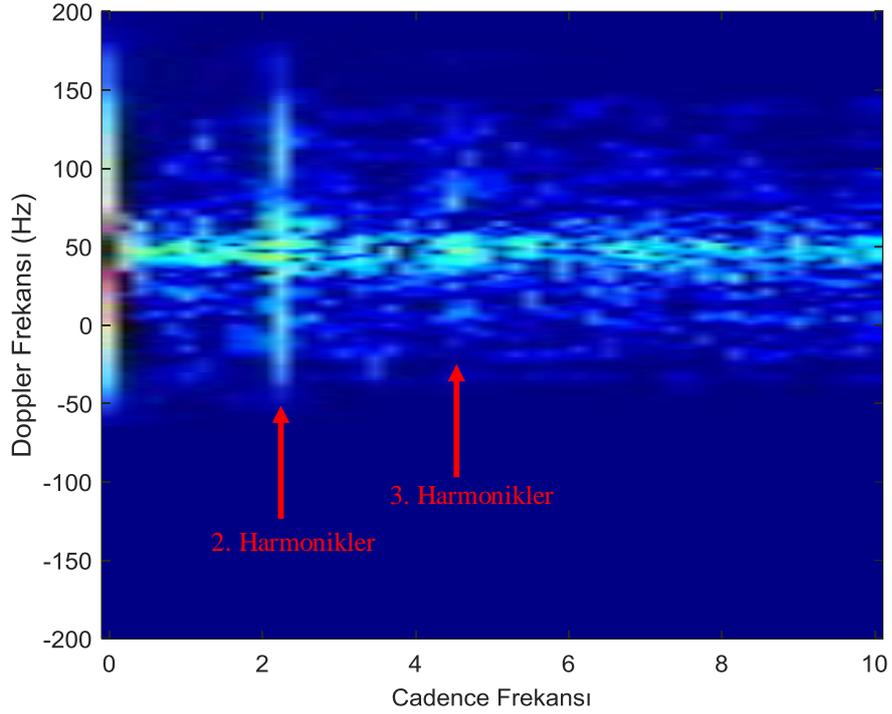
		Sınıflandırıcılar						
		KA	LR	SVM	kNN	SB	DZ	KU
Metrikler	ACC	0.93	0.86	0.97	0.96	0.93	0.84	0.93
	TPR	0.85	0.89	0.96	0.98	0.76	-	-
	SPC	0.95	0.85	0.98	0.95	0.97	-	-
	PPV	0.83	0.61	0.93	0.87	0.90	-	-
	F1	0.83	0.72	0.94	0.91	0.80	-	-

4.2 Cadence Frekansı

Cadence frekansı, insan hareket sınıflandırma problemine ilk olarak Otero [23] tarafından önerilmiştir. Otero sürekli dalga radarı kullanarak farklı insan ve hayvanlara ait mikro-Doppler imzalarını çıkarmıştır. Çalışmada insandan ve hayvanlardan çıkartılan öznitelikler karşılaştırılmış ve basit bir sınıflandırıcı kullanılarak ortaya çıkan sonuçlar gösterilmiştir.

Gelen radar sinyallerinden hız veya Doppler frekans bileşenlerinin çıkartılması için, I/Q ham radar verisine KZFD uygulanmaktadır. Yukarıdaki bölümlerde verilen örnek spektrogramlarda da görülebildiği gibi insan hareketlerinde gövde, kollar ve bacakların periyodik hareketleri bulunmaktadır. Bu hareketlerin periyodiklikleri Fourier dönüşümü kullanılarak ortaya çıkarılabilmektedir. Periyodik hareket bilgilerinin gözlemlenmesi için spektrogram üzerinde bulunan her Doppler hücresi için tüm zaman üzerinden Fourier dönüşümü alınmaktadır. Burada önemli olan bir nokta hareket süresinin hareket periyodikliğini ortaya çıkaracak uzunlukta olması gerekmektedir. Aksi takdirde hareketin önemliliği yeterince açık bir şekilde ortaya çıkmamaktadır. Fourier dönüşümü uygulandıktan sonra ortaya çıkan sonuç insan hareketinin spektral ayrışmasını göstermektedir. Periyodik harekete sahip olan insan vücut parçalarının frekansları ve harmoniklikleri ortaya çıkmaktadır. Örnek bir

frekans-cadence diyagramı Şekil 4.3’de gösterilmektedir. Şekilden de anlaşılacağı gibi insan gövdesinin periyodik hareketi az olduğundan dolayı Cadence frekansı yaklaşık olarak 0’a yakın ve Doppler frekansı da göreceli bir konumda bulunmaktadır. Şekilde gösterilen ikinci ve üçüncü harmonikler ise sırasıyla kollar ve bacakların periyodik hareketlerini belirtmektedir.



Şekil 4.3: Cadence-Doppler frekans diyagramı

Cadence frekansı matematiksel olarak modellenirse, radar sinyalinin spektrogramı SP ; N örneğe bölünmüş ve K örnekle üst üste bindirilmiş parçaların Hamming penceresinden geçirilip Hızlı Fourier dönüşümü alınarak oluşturulmaktadır.

$$SP(f, t) = \left| \sum_{l=1}^N s(l + (t - 1)(N - K)) e^{-\frac{j2\pi fl}{N}} w(l) \right|^2 \quad (4.4)$$

Burada $w(l)$ pencere fonksiyonunu temsil etmektedir. Bu işlemden sonra tüm zaman alanında SP 'nin sütun elemanları için bir daha Fourier dönüşümü alınırsa

$$SP'(f, k) = \left| \sum_{t=0}^q SP(f, t) e^{-\frac{j2\pi kt}{q}} \right| \quad (4.5)$$

Bu işlemden sonra \log fonksiyonu alınarak Cadence hız veya Doppler frekans diyagramı bulunabilmektedir.

$$SP'_{\log}(f, k) = \log(SP'(f, k)) \quad (4.6)$$

Veri tabanındaki tüm hareketler kullanılarak 6 kişinin her hareketi için 4 farklı deneme ile yukarıda tanımlanan 4 farklı Cadence özniteliği çıkartılmıştır. Oluşturulan matris 7 farklı sınıflandırıcıya girdi olarak verilmiş ve çıktılar 5 farklı metrik cinsinden karşılaştırılmıştır. Ortaya çıkan sonuçlar Çizelge 4.2'de verilmektedir. Kullanılan sınıflandırıcılar sırasıyla karar ağaçları, lojistik regresyon, SVM, kNN, saf bayes, dışbükey zarf ve kare uydurmadır. Doğruluk metriği incelendiğinde saf Bayes sınıflandırıcısının en iyi başarımı verdiği görülmektedir. Diğer sınıflandırıcılar doğrulukları %60 ile %74 olarak saptanmıştır. Bu oranlar otomatik hedef sınıflandırma sistemleri için oldukça düşüktür. Bundan dolayı Cadence frekans özniteliklerinin tek başına kullanılması mantıklı olmayacaktır. Aynı zamanda iki kere FFT alınmasından ve logaritma operasyonunun olmasından dolayı zamansal kısıtlar devreye girmektedir. Cadence frekans özniteliklerinin başka öznitelikler ile olan kombinasyonlarına bakılmalı ve öznitelik seçimi sonucu seçilip seçilmediği kontrol edilmelidir. Çünkü diğer öznitelikler ile sergilediği dağılım sınıflandırma başarımını arttıracak yönde olabilir.

Çizelge 4.2: Cadence frekans özniteliklerinin sınıflandırma sonuçları

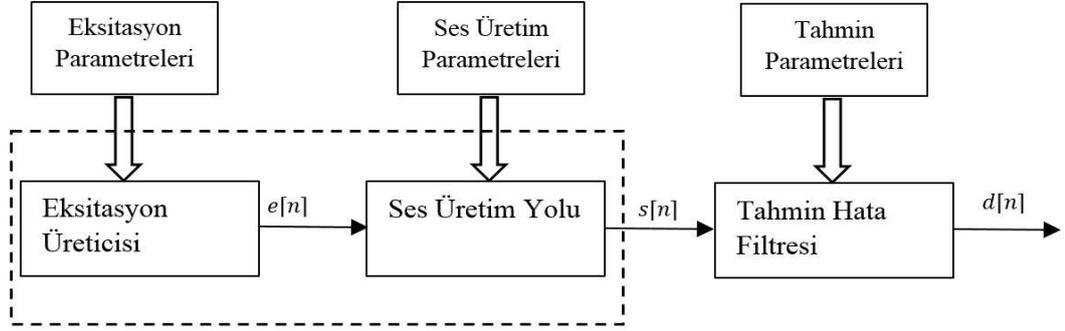
		Sınıflandırıcılar						
		KA	LR	SVM	kNN	SB	DZ	KU
Metrikler	ACC	0.74	0.65	0.69	0.65	0.82	0.64	0.66
	TPR	0.68	0.42	0.55	0.77	0.88	-	-
	SPC	0.75	0.70	0.73	0.62	0.80	-	-
	PPV	0.41	0.25	0.34	0.33	0.53	-	-
	F1	0.83	0.72	0.94	0.91	0.80	-	-

4.3 Doğrusal Öngörülü Kodlama

LPC günümüzde en çok kullanılan güçlü bir ses analiz yöntemidir. Bu yöntemin önemi konuşma parametrelerini iyi bir şekilde sezmesinden ve hızlı hesaplama gücünden kaynaklanmaktadır. Bu özneliğin mikro-Doppler problemine uygulanabilmesi için ses tanımadaki teorik ve matematiksel tabanının bilinmesi gerekmektedir.

Konuşma ve ses sinyalleri kaynak/sistem yapısı ile modellenmektedir. Doğrusal öngörüsül analiz tarafından oluşturulan kaynak/sistem modeli Şekil 4.4'de verilmektedir. Burada konuşmanın oluşması ilk iki sütunda gerçekleşmektedir. Konuşma tanıma için çıkartılan çoğu öznitelik eksitasyon üreticisinden kaynaklanan etkileri yok etmeye çalışır. Genellikle konuşma işlemede ilgilenilen bölge ses üretim yoluyla alakalıdır. Eksitasyon etkileri konuşma sinyalinin spektrumunu çok fazla detaylandırmakta ve ses üretim parametrelerinin bulunmasını zorlaştırmaktadır. Kısa zaman aralıkları için doğrusal sistem, tüm kutupsal bir sistem olarak tanımlanmaktadır. Bu sistemin transfer fonksiyonu

$$H(z) = \frac{S(z)}{E(z)} = \frac{G}{1 - \sum_{k=1}^p a_k z^{-k}} \quad (4.7)$$



Şekil 4.4: Konuşma sinyallerinin doğrusal tahmin modeli

Doğrusal tahmin analizinde, eksitasyon ses üretim sistem modeli tarafından dolaylı olarak tanımlanmaktadır. Bu modelin en büyük avantajı bir kazanç parametresinin - G - olması ve filtre katsayılarının a_k kolaylıkla ve hesaplama gücü açısından verimli bir şekilde bulunmasıdır.

Şekil 4.4 ve (4.7)'da tanımlanan ses üretim modelinde, konuşma örnekler $s[n]$ eksitasyon üreticisine $e[n]$ 'e fark denklemiyle bağlıdır.

$$s[n] = \sum_{k=1}^p a_k s[n-k] + Ge[n] \quad (4.8)$$

LPC katsayıları - α_k - sistem çıkışı olarak

$$\hat{s}[n] = \sum_{k=1}^p \alpha_k s[n-k] \quad (4.9)$$

Tahmin hatası ise, $\hat{s}[n]$ 'nin gerçek örnekleri $s[n]$ değerini tahmin edemediği yerler olarak tanımlanmaktadır.

$$d[n] = s[n] - \hat{s}[n] = s[n] - \sum_{k=1}^p \alpha_k s[n-k] \quad (4.10)$$

Denklem (4.10) incelendiğinde lineer sistemin sistem fonksiyonu

$$A(z) = 1 - \sum_{k=1}^p \alpha_k z^{-k} = \frac{D(z)}{S(z)} \quad (4.11)$$

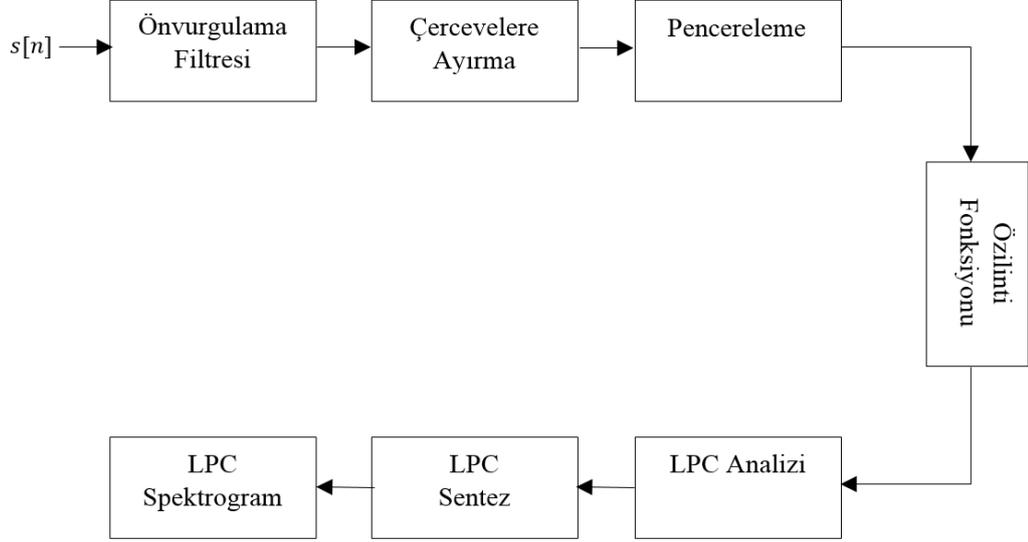
(4.7) ve (4.9) denklemleri incelendiğinde konuşma sinyali $\alpha_k = a_k$ olduğu durumda (4.8)'da verilen modele uymakta bundan dolayı $d[n] = Ge[n]$ olmaktadır. Tahmin hata filtresi $-A(z)$ - (4.7)'da tanımlanan sisteme uyarlanırsa

$$H(z) = \frac{G}{A(z)} \quad (4.12)$$

Doğrusal tahmin analizinde karşılaşılan temel problem konuşma sinyalinin zamanla değişen ses üretim yolunda oluşan kısımların $\{\alpha_k\}$ setleri kullanılarak tahmin edilmesi üzerinedir. Eksitasyondan kaynaklı kısımların sinyalden atılması ve asıl odaklanması gereken ses üretim yoluna ait kısımların tahmin edilmesidir. Kısa zamanda sinyallere bakılarak tahmin hata oranını minimize edecek katsayılar bulunarak bu işlem gerçekleştirilebilmektedir. Tahmin katsayılarının bulunabilmesi için literatürde iki yöntem bulunmaktadır: Kovaryans ve özilinti yöntemi. Çıkarımlar yapıldıktan sonra Levinson Durbin Özyineleme kullanılarak katsayılar hesaplanmaktadır.

Örnek bir doğrusal tahmin işlem yapısı Şekil 4.5'de verilmektedir. İlk olarak ses sinyali alındıktan sonra önvurgulama filtresi uygulanmaktadır. Ancak alınan I/Q radar sinyalleri sisteme sokulduğunda herhangi bir önvurgulama filtre adımı bulunmamaktadır. Bundan sonraki iki adım KZFD'de kullanılan adımlara benzemektedir. Filtreden çıkan sinyal birbiri üzerine binen çerçevelere ayrıldıktan sonra tanımlanan pencere fonksiyonundan geçirilmektedir. Sonra her bir çerçeve LPC katsayılarının bulunması için özilinti fonksiyonuna verilmekte çıkan bilgiler Levinson Durbin Özyineleme yöntemine sokularak LPC katsayıları elde edilmektedir. Algoritmanın detayları bu çalışmada anlatılmamaktadır. LPC sentez aşamasında ise

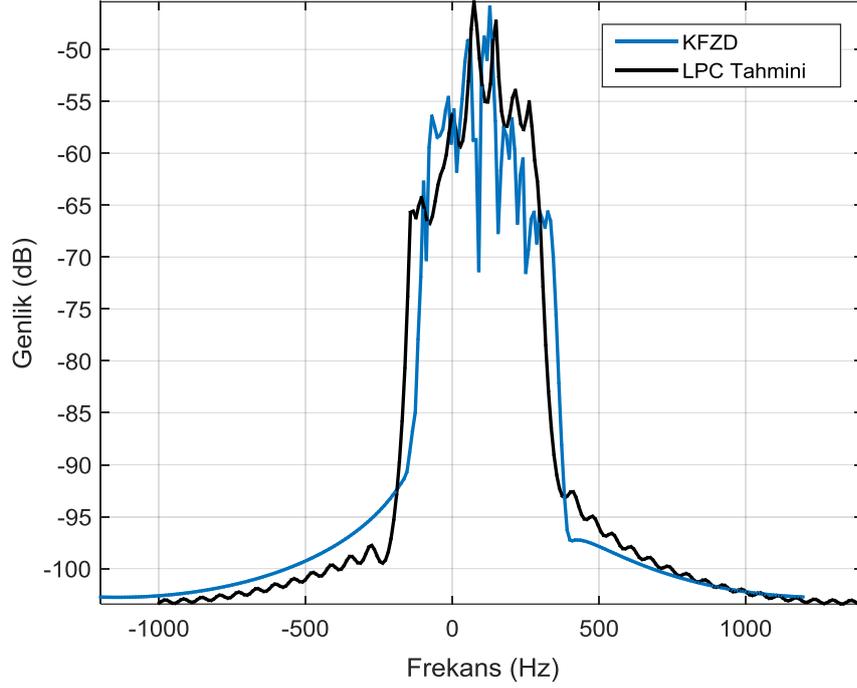
tahmin edilen katsayılar ile sinyalin tekrar oluşturulması sağlanmaktadır. Tahmin hatası, oluşturulan sinyal ile gerçek sinyal birbirinden çıkartılarak bulunmaktadır. Kullanılan katsayısı sayısı artıkcı tahmin hatasının azalması beklenmektedir.



Şekil 4.5: Doğrusal öngörülü kodlama blok diyagram şeması

LPC analizinin frekans alanında yorumlanması KZFD yöntemine bilgilendirici bir bağlantı sağlamaktadır. Özilinti yöntemi kısa zamanlı özilinti fonksiyonuna bağlı olarak tanımlanmakta - $\theta_n(m)$ - kare büyüklüğü alınmış KZFD sinyalinin ters ayrık Fourier dönüşümüne denk gelmektedir. Buradan da sistemin transfer fonksiyonuna bağlı olarak frekans cevabı ve buna bağlı olarak spektral zarfı ortaya çıkartılmaktadır. Şekil 4.6'da KZFD yöntemi ile doğrusal öngörülü kodlama kullanılarak ortaya çıkan spektral sinyaller verilmektedir. Sonuçlar sadece tek bir çerçeve için çıkartılmış ve darbe tekrarlama sıklığı 2400 olarak belirlenmiştir. Şekil 4.6'da verilen doğrusal öngörülü kodlama spektrumu 40 katsayı kullanılarak oluşturulmuştur. Şekil 4.6 incelendiğinde KZFD ile oluşturulan spektrumda hızlı değişimler görülmektedir. Bu değişimler ortaya çıkan imzayı detaylandırmaktadır. Ancak doğrusal öngörülü kodlama spektrumuna bakıldığında spektrum zarflarının yakalandığı görülmektedir. Spektrum detayları kısa zamanlı özilinti katsayılarına yoğunlaşarak silinmektedir. Oluşturulan zarfın düzgünlüğü kullanılan katsayı sayısına göre değişmektedir. Fazla katsayı kullanıldığında sinyal daha iyi geri oluşturulduğu için spektrum zarfı daha

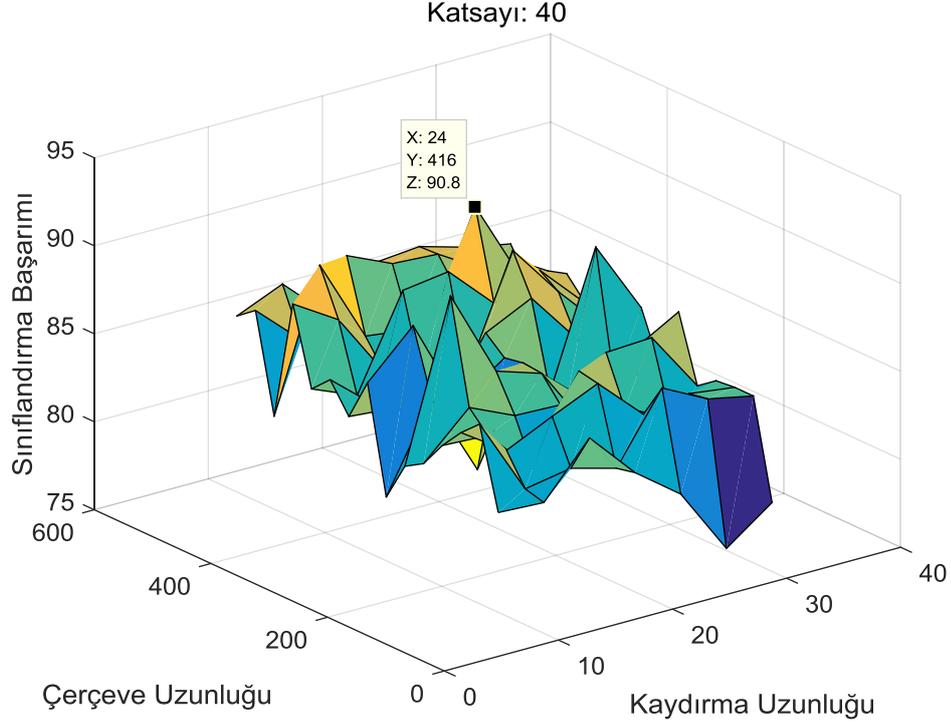
detaylı bir hale dönecek aynı zamanda hata oranı azalacaktır. Az katsayı kullanıldığında ise hata oranı artacak ancak hesaplama gücü ve depolama alanı bakımından kazanç sağlanacaktır.



Şekil 4.6: KFZD ve Doğrusal Öngörülü Kodlama spektrum karşılaştırılması

Doğrusal öngörülü kodlama analizinde başarımlarını etkileyen bir kaç önemli parametre bulunmaktadır. Bunlar sırasıyla: Çerçeve uzunluğu, örtüşme uzunluğu ve katsayı sayısıdır. Bu üç parametre çıkartılan öznelikleri etkilemekte ve özneliklerin ayırıştırıcı özelliklerinin ortaya çıkması sağlamaktadır. Hangi parametrelerin kullanılması gerektiğinin bulunması için kaba kuvvet yöntemi uygulanarak bir sınıflandırma başarımlarını karşılaştırılması yapılmıştır. Üç parametre için farklı kombinasyonlar denenerek hangi değerlerde maksimum başarımlar elde edildiği incelenmiştir. Şekil 4.7'de maksimum başarımların ulaşıldığı parametre değerleri gösterilmektedir. Maksimum başarımlar %90.8 olduğu durumda çerçeve uzunluğu 416, örtüşme uzunluğu 24 ve kullanılan katsayı sayısı 40 olarak belirlenmiştir. Belirlenen parametreler sisteme bağlı olduğu için farklı sistemler için simülasyonların tekrardan denemesi gerekmektedir. Kinect tabanlı mikro-Doppler imzalarının sınıflandırılması

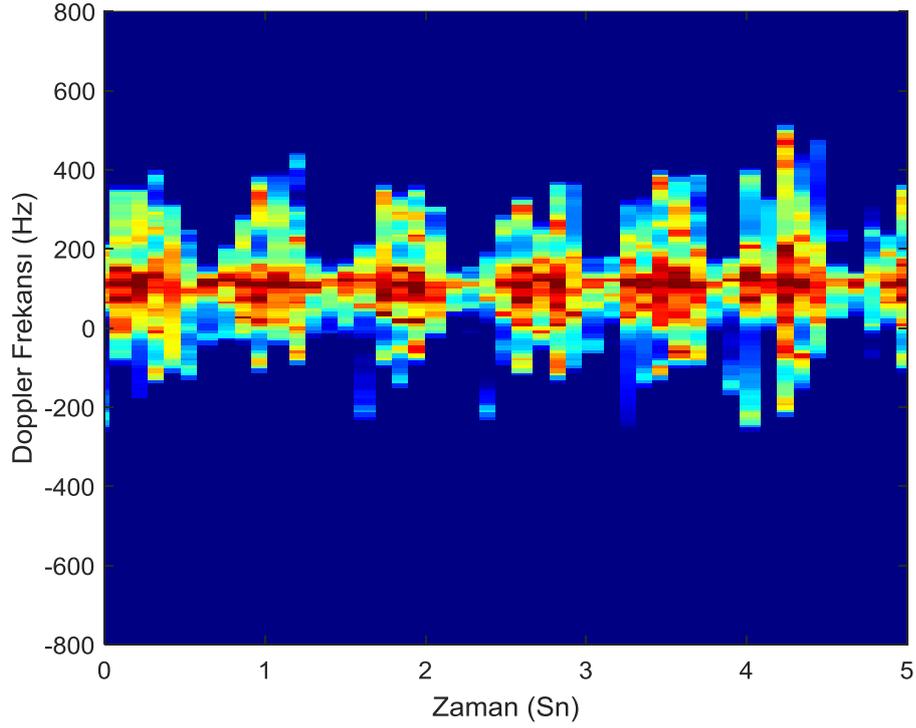
için doğrusal öngörülü kodlama yöntemi öznitelikleri belirlenen bu parametrelerle çıkartılmaktadır. Bu en iyileme yöntemi kullanılacak olan radar parametrelerine veya ortamsal değişikliklere göre de uyarlanabilmekte bundan dolayı sınıflandırma sonuçları maksimize edilebilmektedir.



Şekil 4.7: Sınıflandırma başarımı en iyilemesi

Doğrusal öngörülü kodlama ile her bir çerçevenin spektrumu Şekil 4.6'da gösterildiği gibi bulunmaktadır. Bu spektral imzaların her biri yanyana koyularak KZFD yönteminde oluşturulduğu gibi spektrogramlar oluşturulabilmektedir. Şekil 4.8' de doğrusal öngörülü kodlama yöntemi kullanılarak oluşturulan spektrogram örneği gösterilmektedir. Oluşturulan spektrogramlar kullanılarak 5 farklı öznitelik çıkartılmıştır. Çıkartılan öznitelikler sırasıyla: Ortalama ana Doppler kayması, gövdedeki yansımadan dolayı oluşan Doppler kaymasının bant genişliği, kol ve bacakların hareketlerinden dolayı oluşan ortalama alt ve üst zarf Doppler kaymaları ve son olarak toplam hareket Doppler kayması bant genişliğidir. Doğrusal öngörülü kodlama ile oluşturulan spektrogram incelendiğinde KZFD spektrumunda olan detaylar bu yöntemde olmadığından ve KZFD'de Fourier alınacak noktalar yöntemin bir girdisi olduğundan dolayı çözünürlük daha iyi bir biçimde ortaya çıkmaktadır.

Ancak doğrusal öngörülü kodlama ile oluşturulan spektrogramda insan yürümesinin örüntüsü belli olmakta ve üst ve alt zarf değerleri daha anlaşılır biçimde ortaya çıkmaktadır. Ayrıca yapılan çalışmalar doğrusal öngörülü kodlamanın KZFD'ye göre daha hızlı çalıştığını göstermektedir [31]. Gerçek zamanlı sistemlerde doğrusal öngörülü kodlama ile oluşturulmuş özniteliklerin kullanılması daha mantıklı olacaktır.



Şekil 4.8: Doğrusal öngörülü kodlama spektrogram örneği

Veri tabanındaki tüm hareketler kullanılarak 6 kişinin her hareketi için 4 farklı deneme ile yukarıda tanımlanan 5 farklı doğrusal öngörülü kodlama özniteliği çıkartılmıştır. Oluşturulan matris 7 farklı sınıflandırıcıya girdi olarak verilmiş ve çıktılar 5 farklı metrik cinsinden karşılaştırılmıştır. Ortaya çıkan sonuçlar Çizelge 4.3'de verilmektedir. Kullanılan sınıflandırıcılar sırasıyla karar ağaçları, lojistik regresyon, SVM, kNN, saf bayes, dışbükey zarf ve kare uydurmadır. Doğruluk metriği incelendiğinde lojistik regresyon sınıflandırıcısının en iyi başarımı verdiği görülmektedir. Diğer sınıflandırıcılar ise yaklaşık olarak %88 ve %90 arasında başarımları vermektedir. Doğrusal öngörülü kodlama yöntemi ile oluşturulan öznitelikler fiziksel öznitelikler kadar iyi başarımlar veremeler bile zamansal ve

hesaplamasal kısıtlar düşünöldüğünde gerçek sistemler için önerilebilecek bir öznitelik yapısı olarak ortaya çıkmaktadır. KZFD işlemleri donanımsal olarak yapılmak istediğinde sistemsel zorluklarla karşılaşmaktadır. Bundan dolayı doğrusal öngörölü kodlama yöntemi gerçek zamanlı otomatik hedef tanıma sistemleri için önerilmektedir.

Çizelge 4.3: Doğrusal öngörölü kodlama özniteliklerinin sınıflandırma sonuçları

		Sınıflandırıcılar						
		KA	LR	SVM	kNN	SB	DZ	KU
Metrikler	ACC	0.88	0.93	0.90	0.91	0.91	0.85	0.86
	TPR	0.71	0.81	0.75	0.82	0.88	-	-
	SPC	0.93	0.95	0.94	0.90	0.91	-	-
	PPV	0.73	0.85	0.78	0.73	0.72	-	-
	F1	0.71	0.82	0.75	0.71	0.80	-	-

4.4 Kepstrum Katsayıları

KZFD zamanın bir fonksiyonu olan sinyallerin incelenmesinde çok önemli bir yöntemdir. KZFD'den yola çıkılarak bulunan diğeri önemli bir yöntem ise kepstrum, daha spesifik olarak kısa zamanlı kepstrum olarak tanımlanmaktadır. Kepstrum Bogert, Healy ve Tukey tarafından logaritmik büyüklüğü alınmış spektrumun ters Fourier dönüşümü olarak tanımlanmaktadır [49]. Orijinal tanımı; yankı içeren bir sinyalin Fourier spektrumunun logaritması, yankının uzunluğuna ve gecikmesine bağlı olarak ekstra bir periyodik eleman içermesiyle ortaya çıkmıştır. Oppenheim, Schafer ve Stockham kepstrumu daha genel bir konsept olan homomorfik filtreleme ile tanımlamaktadır [49]. Yankı içeren bir sinyal

$$x(t) = s(t) + as(t - \tau) \quad (4.13)$$

Burada τ gecikme olarak tanımlanmaktadır. Bu sinyalin Fourier dönüşümü alındıktan sonraki spektral yoğunluğuna bakılırsa

$$|X(f)| = |S(f)|^2 [1 + \alpha^2 + 2\alpha \cos(2\pi f\tau)] \quad (4.14)$$

Bu denklemden yankı içeren bir sinyalin spektral yoğunluğu frekansın periyodik bir fonksiyonun sahip zarf şeklinde oluşmaktadır. Spektrumun logaritması alındığında bu çarpım işlemi iki terimin toplamına dönüşmektedir.

$$\begin{aligned} C(f) &= \log|X(f)|^2 \\ &= \log|S(f)|^2 + \log[1 + \alpha^2 + 2\alpha \cos(2\pi f\tau)] \end{aligned} \quad (4.15)$$

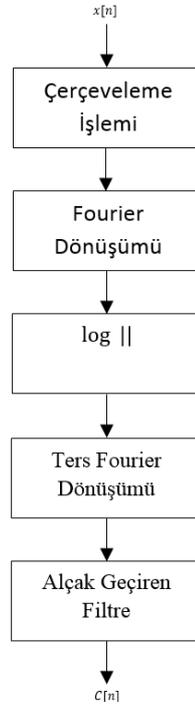
Bundan dolayı, $C(f)$ ek bir periyodik elemanı olan ve temel frekansı yankı gecikmesi olarak tanımlanan bir dalga şeklindedir. Zaman dalgalarının genel analizinde periyodik elemanlar Fourier spektrumunda keskin tepe noktaları oluştururlar. Bundan dolayı spektrumun logaritması alındığında da bir tepe noktası görülmektedir. Ancak yeni oluşturulan “spektral” yapı aslında frekans alanında olmadığı gibi zaman alanında da değildir. Bundan dolayı Bogert yeni alanı yani spektrumun logaritması alınmış halini “quefreny” olarak adlandırmaktadır.

Homomorfik filtreleme yaklaşımı eklenemez şekilde birleştirilmiş sinyalleri - evrişim veya çarpım - ayırmada kullanılan bir yöntemdir. Homomorfik filtreleme 3 tane ardışık sıralanmış doğal sistemden oluşmaktadır. İlk sistem geri çevrilemez lineer olmayan bir karaktere sahiptir. Örnek yapı: Evrişimi normal toplama işlemine eşlemektedir. İkinci sistem eklenebilir üstdüşüm ilkesine uyan lineer bir yapıdır. Üçüncü sistem ise ilk lineer olmayan yapının tersidir. Bundan dolayı evrişim tarafından birleşmiş sinyaller için, homomorfik ters evrişim sistemi evrişimi toplamaya, toplamayı toplamaya, toplamayı evrişime çevirmektedir. İki sinyal evrişim halindeyse, sinyallerin Fourier dönüşümü çarpılmış, uygun olarak tanımlanmış kompleks logaritma fonksiyonu, logaritmik Fourier dönüşümlerinin toplamı haline gelmektedir.

Toplamın ters Fourier dönüşümü alındığında sinyaller tek başlarına ortaya çıkmaktadır.

Konuşma sinyalleri oluşma aşamaları Şekil 4.4’de anlatılmaktadır. Konuşma işleme yapılırken amaçlanan eksitasyon etkilerinin sinyalden atılması ve sesin oluştuğu ses üretim yolu kısmına odaklanmaktadır. Eksitasyon üreticisi ve ses üretim yolu çarpım halinde bulunmaktadır. Bu sinyalleri ayırmak için homomorfik filtreleme kullanılmaktadır. İlk olarak logaritmik fonksiyon kullanıldığında toplam haline gelen sinyaller ters Fourier dönüşümü ile incelendiğinde spektral zarfı oluşturan ses yolu üreticisi düşük frekans alanında, spektral detaylar ise yüksek frekans alanında çıkmaktadır. Alçak geçiren bir filtre kullanılarak spektral zarf ve detaylar ayırt edilebilmektedir.

Radar sinyalleri incelenirken de bu yöntem izlenmiştir. Radar sinyalinin spektral zarfına odaklanarak burada ortaya çıkartılan katsayılar öznitelik olarak kullanılmıştır. Öznitelik çıkartılan izlenen blok şeması Şekil 4.9’da gösterilmektedir.



Şekil 4.9: Kepstrum katsayıları blok şeması

Kepstrum katsayıları her bir çerçeve için hesaplanmaktadır. Çerçeveler ayrık Fourier dönüşümünden geçirilmekte, sonucun genliğinin logaritması alındıktan sonra ters ayrık Fourier dönüşümü alınmakta ve alçak geçiren filtre ile kepstrum sayıları ortaya çıkartılmaktadır. Alçak geçiren filtre kullanılarak her bir çerçevede bulunan ilk katsayı alınmaktadır. Çerçeve k 'dan alınan kepstrum sayısı c_k olarak ifade edilirse kepstrum katsayı vektörü $s(k)$ ile buradan çıkartılan 3 farklı öznitelik aşağıdaki denklem ile ifade edilmektedir.

$$s(k) = c_k(1) \quad k = 1, 2, \dots, N_H \quad (4.16)$$

$$p_1 = [\text{argmax}_k s(k)] \quad (4.17)$$

$$p_{2,3} = [\text{argmax}_k \text{diff}(s(k)); \text{argmin}_k \text{diff}(s(k))] \quad (4.18)$$

Seçilen öznitelikler $s(k)$ vektörünün maksimum olduğu nokta ve ilk nümerik türevinin (diff operatörü $\text{diff}(x) = x[n] - x[n - 1]$) maksimum ve minimum olduğu indeks değerleri olarak seçilmektedir.

Denenen ancak başarılı olmadığı için vazgeçilen bir diğer kepstrum tabanlı öznitelik çıkarımı ise çerçevelerden çıkartılan kepstrum katsayılarının ilk 10 tanesinin öznitelik olarak seçilmesidir [50]. Ancak bu şekilde çıkartılan özniteliklerin sınıflara göre herhangi bir ayırıcı özelliği bulunmadığından sınıflandırma başarımları çok düşük gelmektedir. Bu yöntem bu çalışma kapsamında incelenmemektedir.

Veri tabanındaki tüm hareketler kullanılarak 6 kişinin her hareketi için 4 farklı deneme ile yukarıda tanımlanan 3 farklı kepstrum özniteliği çıkartılmıştır. Oluşturulan matris 7 farklı sınıflandırıcıya girdi olarak verilmiş ve çıktılar 5 farklı metrik cinsinden karşılaştırılmıştır. Ortaya çıkan sonuçlar Çizelge 4.4'te verilmektedir. Kullanılan sınıflandırıcılar sırasıyla karar ağaçları, lojistik regresyon, SVM, kNN, saf bayes, dışbükey zarf ve kare uydurmadır. Doğruluk metriği incelendiğinde karar destek makinası sınıflandırıcısının en iyi başarımları verdiği görülmektedir. Diğer

sınıflandırıcılar ise yaklaşık olarak %80 başarımlar vermektedir. Kepstrum katsayıları çok yüksek başarımlar vermemektedir. Sınıflar arasında en çok karıştırma karışık hareketler ve yürüme sınıfları arasında meydana gelmektedir. Ancak %84 sınıflandırma başarımları otomatik hedef sınıflandırma problemi için yeterli olarak görülebilmektedir.

Çizelge 4.4: Kepstrum özneliklerinin sınıflandırma sonuçları

		Sınıflandırıcılar						
		KA	LR	SVM	kNN	SB	DZ	KU
Metrikler	ACC	0.81	0.80	0.84	0.80	0.80	0.75	0.78
	TPR	0.63	0.64	0.73	0.79	0.88	-	-
	SPC	0.85	0.84	0.87	0.81	0.77	-	-
	PPV	0.51	0.50	0.60	0.51	0.50	-	-
	F1	0.55	0.55	0.65	0.66	0.64	-	-

4.5 Ayrık Kosinus Katsayıları

Ayrık kosinus katsayıları [21] çalışmasında gösterildiği gibi çıkartılmaktadır. İlk 10 katsayı öznelik olarak seçilip sınıflandırma işlemi yapılmaktadır. Veri tabanındaki tüm hareketler kullanılarak 6 kişinin her hareketi için 4 farklı deneme ile yukarıda tanımlanan 10 farklı ayrık kosinüs dönüşüm özneliği çıkartılmıştır. Oluşturulan matris 7 farklı sınıflandırıcıya girdi olarak verilmiş ve çıktılar 5 farklı metrik cinsinden karşılaştırılmıştır. Ortaya çıkan sonuçlar Çizelge 4.5'te verilmektedir. Kullanılan sınıflandırıcılar sırasıyla karar ağaçları, lojistik regresyon, SVM, kNN, saf bayes, dışbükey zarf ve kare uydurma sınıflandırıcılarıdır. Doğruluk metriği incelendiğinde karar destek makinası sınıflandırıcısının en iyi başarımları verdiği görülmektedir.

Çizelge 4.5: Ayrık kosinüs dönüşümü özniteliklerinin sınıflandırma sonuçları

		Sınıflandırıcılar						
		KA	LR	SVM	kNN	SB	DZ	KU
Metrikler	ACC	0.85	0.91	0.92	0.87	0.86	0.84	0.85
	TPR	0.75	0.93	0.90	0.97	0.66	-	-
	SPC	0.88	0.92	0.93	0.87	0.91	-	-
	PPV	0.62	0.84	0.78	0.65	0.66	-	-
	F1	0.75	0.92	0.90	0.87	0.83	-	-

Çıkarılan tüm özniteliklerin kullanıldığı durumda ortaya çıkan sınıflandırma sonuçları Çizelge 4.6’da verilmektedir. Toplamda 28 öznitelik çıkarılmıştır. Öznitelik sayısı arttığında incelenen uzay boyutu arttığından dolayı hesaplama gücü ve zaman da artmaktadır. Ancak sonuçlar incelendiğinde tüm sınıflandırıcılarda neredeyse %90’nın üstünde bir başarı oranı görülmektedir. Hesaplama gücü ve zamansal kısıtlar devre dışı bırakıldığında tüm özniteliklerin beraber kullanılması sınıflar arası bir ayırıcılık sağlanmasına sebep olmaktadır. Tek başına kötü sonuçlar veren cadence frekansına bağlı özniteliklerin diğer özniteliklerle kullanıldığında ayırıcı bir özelliğe sahip olduğuda görülmektedir. Bu durumda yine SVM en yüksek başarı sonucunu vererek güvenilirliğini kanıtlamaktadır.

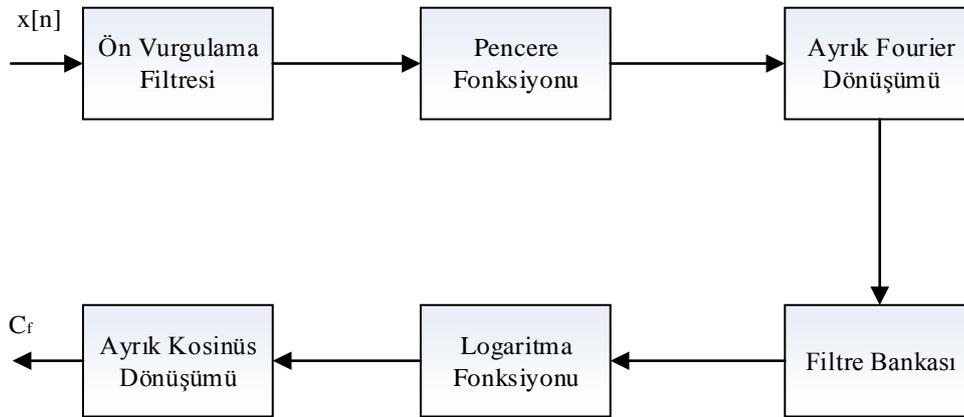
Çizelge 4.6: Tüm özniteliklerinin sınıflandırma sonuçları

		Sınıflandırıcılar						
		KA	LR	KDM	kNN	SB	DZ	KU
Metrikler	ACC	0.90	0.95	0.96	0.88	0.93	0.86	0.89
	TPR	0.74	0.94	0.94	0.82	0.77	-	-
	SPC	0.94	0.95	0.96	0.90	0.97	-	-
	PPV	0.77	0.92	0.88	0.73	0.87	-	-
	F1	0.74	0.96	0.90	0.71	0.82	-	-

5 İNSAN MİKRO DOPPLER İMZALARINA UYARLANMIŞ KEPSTRUM KATSAYILARI

İnsan mikro Doppler imzalarına uyarlanmış kepstrum katsayıları konuşma tanıma sistemlerinde kullanılan MFCC öznitelik çıkartma yönteminden esinlenerek geliştirilmiştir.

MFCC öznitelikleri insan kulağının frekans seçiciliğini taklit ederek konuşmacıları ayırt edici değerler elde edilmesi üzerine kurulmuştur. Ayrıca MFCC katsayıları değişimlerden ve ses dalga yapısından çok az daha etkilenmektedir [51]. Ses tanımda kullanılan örnek bir MFCC öznitelik çıkartma şeması Şekil 5.1’de gösterilmektedir. İlk olarak sinyal önvurgulama filtresine sokulmaktadır. Bu bölüm uyarlanmış mikro-Doppler öznitelik yönteminde kullanılmamıştır. Filtreden sonra sinyal çerçevelere ayrılıp Hamming pencereleme fonksiyonu ile ayrılmaktadır. Her bir çerçeveye ayrık Fourier dönüşümü uygulandıktan sonra önceden tanımlanan bir filtre bankası ile spektral analiz yapılmaktadır. Logaritma fonksiyonu ile homomorfik filtrenin kuralları uygulanmakta bundan sonra veriyi sıkıştırmak için ayrık kosinüs dönüşümü kullanılmaktadır. Ayrık kosinüs dönüşümünden sonra alçak geçiren bir filtre ile katsayılar ortaya çıkmaktadır.



Şekil 5.1: MFCC öznitelik blok şeması

Matematiksel olarak çerçevelere ayrılan sinyaller ilk olarak ayrık Fourier dönüşümü ile spektral düzleme taşınmaktadır.

$$X_a[k] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi nk/N} \quad (5.1)$$

Ayrık Fourier dönüşümü uygulandıktan sonra filtre bankalarının tanımlanması gerekmektedir. MFCC özniteliklerinin en önemli ve ayırıcı özelliğe sahip oldukları kısım filtre bankalarının kullanılmasıdır. Araştırmacılar insan kulağına odaklanarak Mel ölçüsü denilen bir frekans bükücü fonksiyon tanımlamıştır. Bu fonksiyon frekans aralığındaki bazı değerlere karşı daha seçiciyken diğer frekans bileşenlerini elemektedir. Kullanılacak filtreler bükme fonksiyonunun odaklanma aralığına bağlı olarak frekans alanında daha sık; genlik alanında ise daha yüksek değerlere sahip olmaktadır. Mel ölçüsü frekans fonksiyonu ve tersi tanımlanırken

$$f_{mel} = 2595 \log_{10} \left(1 + \frac{f_{Hz}}{700} \right) \quad (5.2)$$

$$f_{Hz} = 700 \left[e^{\left(\frac{f_{mel}}{1127} - 1 \right)} \right]$$

Mel ölçüsünün tersi Mel ölçüsü fonksiyonundan f_{Hz} 'in çekilmesiyle oluşturulmaktadır. Frekans aralığı 0-8000 Hz olduğu durumda ortaya çıkan Mel ölçü grafiği Şekil 5.2.a'da verilmektedir. Görülebildiği gibi insan kulağının daha rahat anlayabildiği frekanslara bükücü fonksiyonun lineer olmayan yapısı sayesinde daha çok odaklanılmaktadır. Bu fonksiyona bağlı olarak M tane ($m = 1, 2, \dots, M$) filtre bankası tanımlanmaktadır. Bu filtreler üçgen şeklindedir.

$$H'_m[k] = \begin{cases} 0 & k < f[m-1] \\ \frac{(k - f[m-1])}{(f[m] - f[m-1])} & f[m-1] \leq k \leq f[m] \\ \frac{(f[m+1] - k)}{(f[m+1] - f[m])} & f[m] \leq k \leq f[m+1] \\ 0 & k > f[m+1] \end{cases} \quad (5.3)$$

Kullanılacak filtrelerin sınır noktalarının bulunabilmesi için en yüksek - f_h - ve en düşük - f_l - frekansların, örnekleme frekansının - F_s -, filtre sayısının - M - ve FFT noktalarının belirlenmesi gerekmektedir. Bunlar kullanılarak filtrelerin sınır noktaları

$$f[m] = \left(\frac{N}{F_s}\right) B^{-1} \left(B(f_l) + m \frac{(B(f_h) - B(f_l))}{M + 1} \right) \quad (5.3)$$

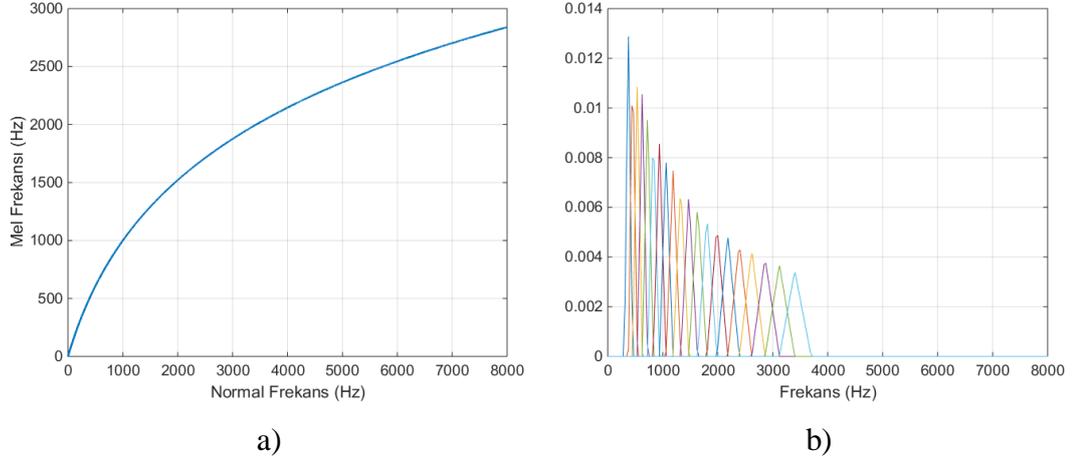
Burada B ve B^{-1} sırasıyla bükülme ve bükülme fonksiyonunun tersi olarak tanımlanmaktadır. Örnek olarak Mel ölçü fonksiyonu ile oluşturulmuş filtreler Şekil 5.2.b'de gösterilmektedir. Bükülme fonksiyonundaki gibi düşük frekanslara odaklanılmakta yüksek frekanslarda filtrelerin bant genişliği artmakta genlikleri azalmaktadır. Filtre bankası oluşturulduktan sonra her bir filtrenin çıkışındaki logaritmik enerjisi hesaplanmaktadır.

$$S[m] = \ln \left[\sum_{k=0}^{N-1} |X_a[k]|^2 H_m[k] \right] \quad (5.4)$$

Burada $X_a[k]$ çerçevelemiş ve pencerelenmiş sinyal olarak tanımlanmaktadır. M tane filtrenin çıkış enerjisi ayrık kosinüs dönüşüme girdi olarak verilerek katsayılar hesaplanmaktadır.

$$c[n] = \sum_{m=0}^{M-1} S[m] \cos \left(\frac{\pi n \left(m + \frac{1}{2} \right)}{M} \right) \quad (5.4)$$

Burada M sayısı uygulamaya göre değişmektedir. Ayrık kosinüs katsayılarının kullanılmasının sebebi katsayılar sıkıştırılmış bir formata getirmektir. MFCC yöntemi teorikte homomorfik filtreleme – spektral zarf ayrıştırması – amacıyla kullanılsa da pratikte bu amaca hizmet ettiği görülmektedir.



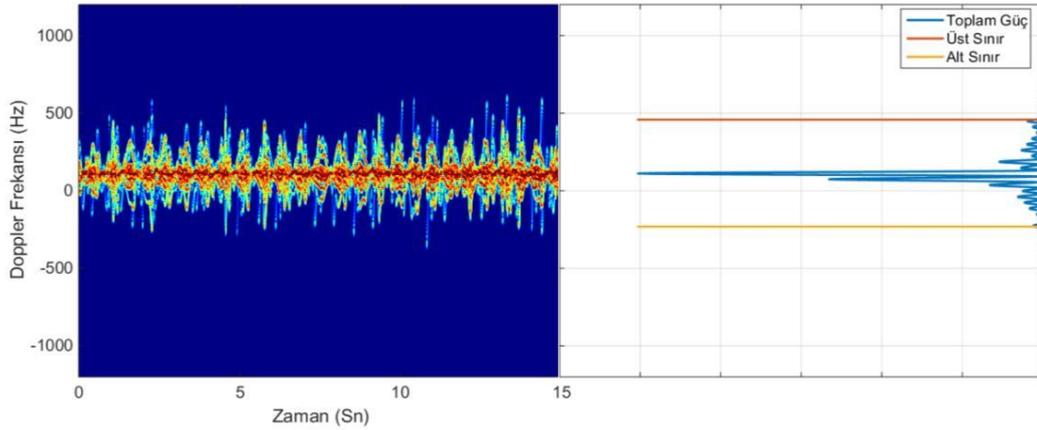
Şekil 5.2: Mel ölçüsü a) bükme fonksiyonu b) Filtre bankası

Literatür incelendiğinde MFCC öznitelikleri birçok çalışmada kullanılmaktadır [30]. Ancak yukarıda da anlatıldığı gibi Mel ölçüsü insan kulağı için tanımlanmaktadır. Bundan dolayı odaklanılan frekans aralıkları tamamen insan kulağına bağlıdır. İnsan hareketlerinden kaynaklı meydana gelen Doppler kaymaları ile Mel ölçüsü arasında herhangi bir bağlantı bulunmamaktadır. Doppler kaymaları insan hareketinin hızına ve periyodikliğine ve merkez frekansına bağlı olarak değişmekte, PRF değeriyle de örnekleme yapılmaktadır. Aynı zamanda hedeflerin radara ters yönde yaptıkları hareketler ters Doppler kaymalarına neden olmaktadır. Mel ölçüsü, bükülme fonksiyonunun tanımından dolayı negatif frekansları kapsamamaktadır. Bu sorunları ortadan kaldırabilmek için bu çalışmada iki tür bükülme fonksiyonu önerilmektedir. Bunlar lineer aralıklı ve hiperbolik tanjant bükülme fonksiyonu olarak tanımlanmaktadır.

Lineer aralıklı filtre için ilk olarak odaklanılacak bir aralık belirlenmektedir. Bu aralık hiperbolik tanjant için de aynı yöntemle belirlenmektedir. Lineer aralıklı filtrenin bükülme ve ters bükülme fonksiyonları

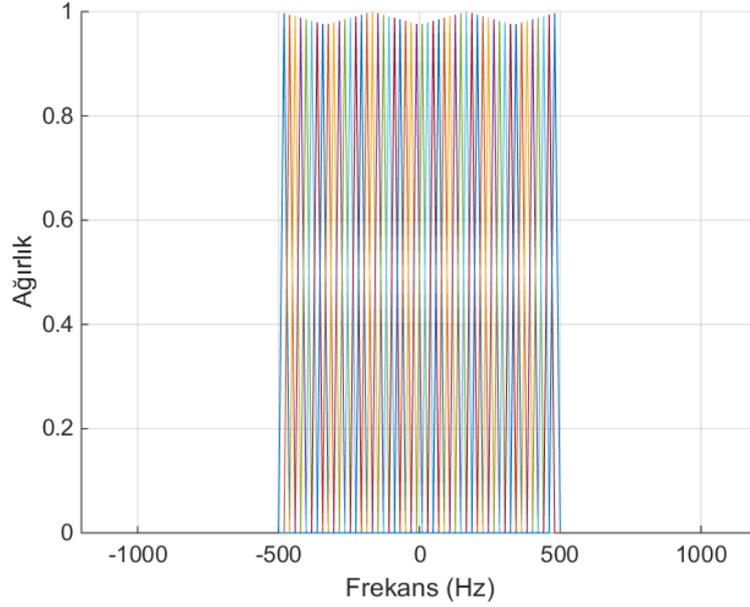
$$\begin{aligned}
 f_{warp} &= f_{Hz} \\
 f_{Hz} &= f_{warp}
 \end{aligned}
 \tag{5.5}$$

Filtre tasarımı yapılırken dikkat edilmesi gereken önemli bir kısıt bükülme fonksiyonunun odaklanma aralığıdır. Bu çalışmada, odaklanılacak aralık mikro-Doppler spektrogramlarına bakılarak bulunmaktadır. Spektrogramın her bir frekans değeri için zamanda aldığı değerler toplanmaktadır. Böylelikle frekans bileşenlerinin sahip oldukları güç değerleri bulunmaktadır. Örnek olarak bir spektrogram ve ortaya çıkan bileşenler Şekil 5.3'te gösterilmektedir. Görüldüğü gibi bükülme fonksiyonunun odaklanacağı üst ve alt sınırlar mikro-Doppler imzalarına bakılarak çıkartılmaktadır. Böylelikle her bir eğitim verisine ait bir odaklanma aralığı tanımlanacaktır. Lineer aralıklı filtreler (5.5)'ye gösterildiği gibi tanımlandığından filtrelerin oluşumu Şekil 5.4'de gösterilmektedir.



Şekil 5.3: Odaklanma aralığının bulunması

Simülasyonlar yapılırken her bir veri için odaklanma fonksiyonu Şekil 5.3'te gösterildiği gibi hesaplanmıştır. Ancak lineer aralıklı filtre bankalarının oluşumunu gösterebilmek amacıyla Şekil 5.4'te odaklanma fonksiyonu -500 ve 500 Hz arasında belirlenmiştir. Filtreler odaklanma aralığını kullanılacak filtre sayısına ve filtrelerin bant genişliğine bağlı olarak eşit aralıklarla bölmektedir. Bu grafikte 50 tane filtre kullanılmıştır. Lineer aralıklı filtreler mikro-Doppler insan sınıflandırma probleminde kullanıldığında ortaya çıkan karışıklık matrisi Çizelge 5.1'de verilmektedir. Burada sınıflandırıcı olarak SVM kullanılmıştır.



Şekil 5.4: Lineer aralıklı filtre bankası

Çizelge 5.1: Lineer aralıklık filtre öznitelikleriyle ortaya çıkan karışıklık matrisi

		Sınıf			
		Yürüme	Koşma	Karışık Hareketler	Zıplama
Hareket	Yürüme	0.85	-	0.15	-
	Koşma	0.10	0.90	-	-
	Karışık Hareketler	0.20	-	0.80	-
	Zıplama	-	-	-	1

Lineer aralıklı filtre bankası genel bir yapıya sahip olduğundan dolayı özel durumlara uyarlanabilmesi zordur. Çalışmanın bu kısmında hiperbolik tanjant formuna sahip olan bir bükülme fonksiyonu tanımlanmaktadır. Orijinal, hiperbolik tanjant fonksiyonu 0 etrafında oluşmaktadır. Ancak mikro-Doppler imzaları incelendiğinde asıl spektral bileşenler ana Doppler kayması etrafında olduğu görülmektedir. Bundan dolayı fonksiyon ilk olarak ana Doppler kayması kadar kaydırılmaktadır ve genliği ayarlanmaktadır. En önemli parametre ise fonksiyonun sahip olduğu bükülme derecesidir. Fonksiyon yüksek bir bükülme derecesine sahip ise lineer bir yapıda düşük

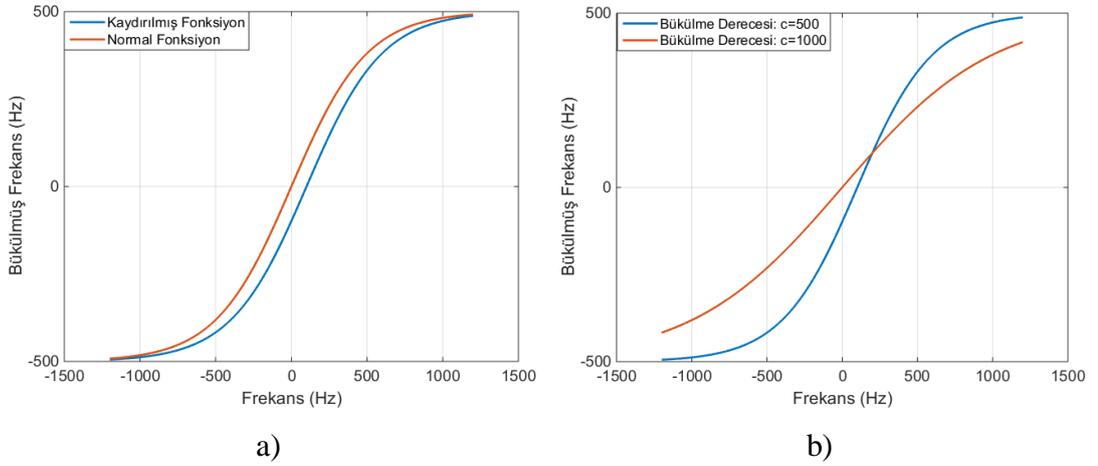
bir derecede ise hiperbolik yapıda olmaktadır. Şekil 5.5.a'da ana Doppler kayması kadar kaydırılan bükülme fonksiyonu ile normal fonksiyonu gösterilmektedir. bu duruma örnek gösterilebilir.

Matematiksel olarak hiperbolik tanjant bükülme fonksiyonu

$$f_{warp} = a \tanh(f_{Hz} - b) / c$$

$$f_{Hz} = c \tanh\left(\frac{f_{warp}}{a}\right) + b \quad (5.6)$$

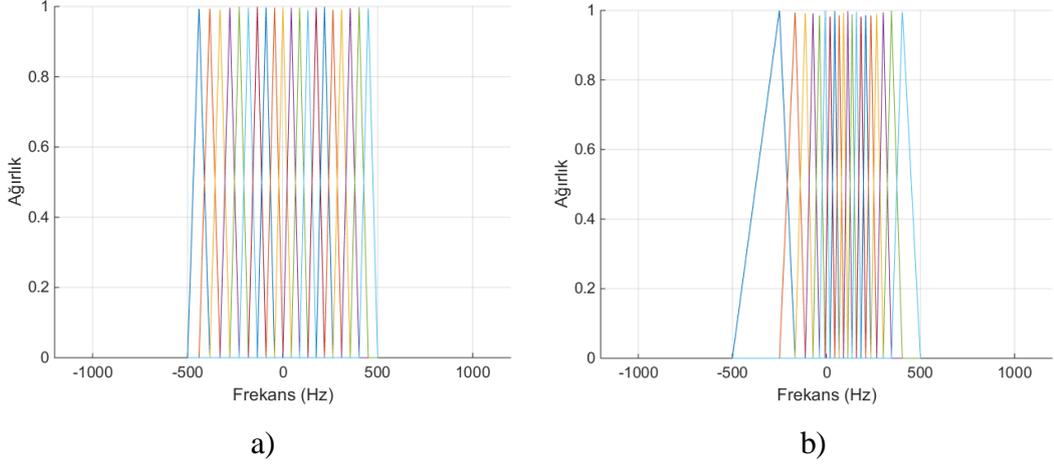
Burada a genliği, b kayma derecesini ve c fonksiyon bükülmesinin derecesini tanımlamaktadır. Şekil 5.5.b'de ise bükülme derecesinin etkisi kolaylıkla görülebilmektedir. c katsayısı büyüdüğü durumda bükülme fonksiyonu lineer yapıya yaklaşırken küçük olduğunda hiperbolik yapıya sahip olmaktadır.



Şekil 5.5: Hiperbolik tanjant bükülme fonksiyonunun a) Kaydırılma b) Bükülme derecesinin etkisi

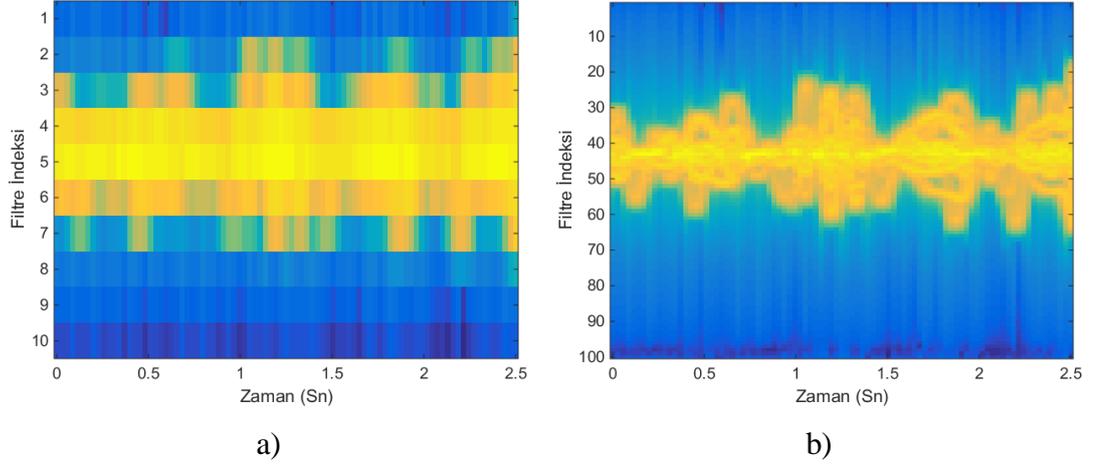
Bükülme derecesi tanımlanan fonksiyon için önemli bir parametredir. Fonksiyonun şeklini etkilemesi sebebiyle filtrelerin hangi bant genişliklerine sahip olacağını belirlemektedir. Mikro Doppler imzaları incelendiğinde hareketler belli frekans aralıklarında olduğundan ve bazı bileşenler sınıflandırma için diğerlerine göre daha önemli olduğundan bu fonksiyon istenilen frekans aralığına daha çok odaklanmak

için kullanılabilir. Örnek olarak $c = 500$ ve $c = 1000$ iken ortaya çıkan filtre yapıları Şekil 5.6'da verilmektedir. Bükülme katsayısının küçük olduğu durumda belli bölgelere daha çok filtre konulmakta büyük olduğu durumda ise lineer bir yapı ortaya çıkmaktadır.



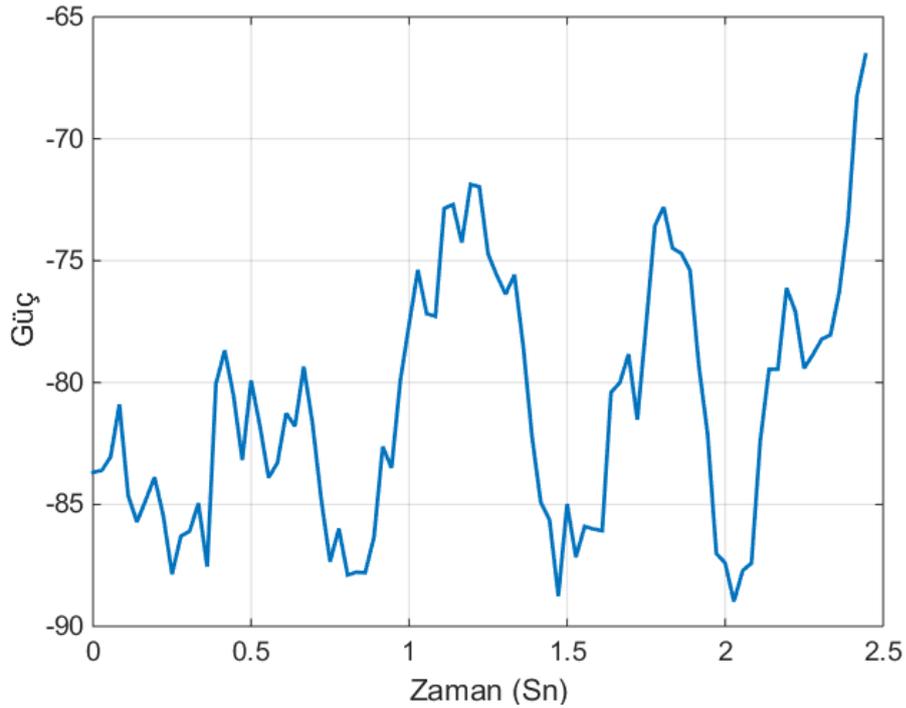
Şekil 5.6: Bükülme derecesinin filtre yapıları üzerindeki etkisi a) $c=1000$ b) $c=500$

Ayrık Fourier dönüşümü alınmış sinyaller filtre bankasından geçirildikten sonra logaritma fonksiyonuna sokulmaktadır. Burada elde edilen logaritmik filtre bankası çıktıları her bir filtredeki enerjiyi depolamaktadır. Logaritmik filtre bankasının enerji çözünürlükleri kullanılan filtre sayısına göre değişmektedir. Bükülme fonksiyonunun odaklanma aralığı -500 ve 500 Hz seçildiğinde ve filtre sayıları 10 ve 100 olarak belirlendiğinde ortaya çıkan log-filtre enerji grafikleri Şekil 5.7'de verilmektedir. Kolaylıkla görüldüğü gibi çözünürlük filtre sayısından etkilenmektedir. Normal öznitelik çıkarma yönteminde filtreler sadece ilgili odaklanma aralığına konmuştur. Şekil 5.7'de sadece çözünürlüğe örnek olmasından dolayı filtreler -500 ve 500 arasında bulunmaktadır. Burada farklı özniteliklerde çıkarılabilmektedir. Örnek olarak filtrelerin sahip olduğu enerjiler birbirlerine oran olarak basit bir sınıflandırıcı gerçekleştirilebilmektedir. Ancak bu çalışma kapsamında bu öznitelikler bulunmamaktadır.



Şekil 5.7: Log filtre enerji karşılaştırmaları a) $M=10$ b) $M=100$

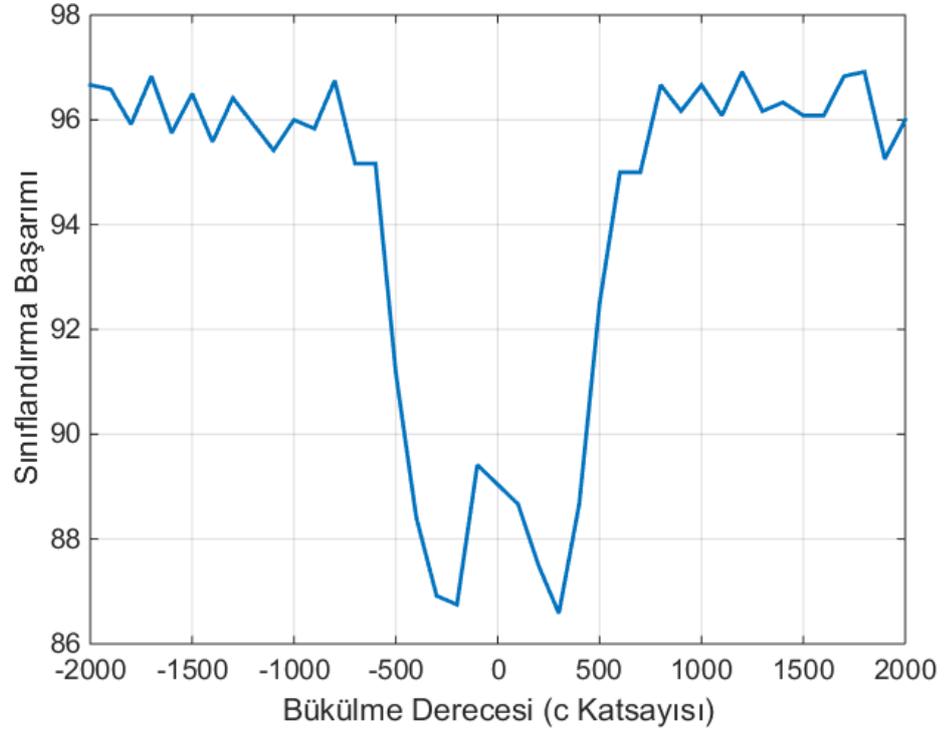
Log filtre enerjileri sonra ayrık kosinüs dönüşümü kullanılarak sıkıştırılmaktadır. Dönüşümden sonra çıkan katsayılar alçak geçiren bir filtre ile ayrılmaktadır. Ayrık kosinüs dönüşüm çıktısı Şekil 5.8’de gösterilmektedir. Grafik incelendiğinde log filtre enerjisinde bulunan üst zarfların yakalandığı görülmektedir. MFCC yöntemi teorik olarak homomorfik bir yöntem olmasada çıktı olarak spektral zarfı verdiği için homomorfik bir yöntem olarak değerlendirilebilmektedir.



Şekil 5.8: Alçak filtreden geçirilmiş ayrık kosinüs katsayıları

Ayrık kosinüs dönüşümünden sonra ses tanıma için genellikle ilk 13 katsayı öznitelik olarak seçilmektedir. Mikro-Doppler ile insan hareket tanıma problemi için iki farklı öznitelik çıkartma yöntemi oluşturulmuştur. Bunlardan bir tanesi ayrık kosinüs dönüşüm katsayıları bulunduktan sonra tepe tespiti yapılmasıdır. Bulunan tepelerin güç değerlerinin ortalaması alınarak her bir veriden tek bir öznitelik çıkartılmaktadır. Ancak bu yöntem koşma yürüme ayrımı için başarılı olarak çalışsa da yürüme ve karışık hareket ayırımında istenen başarıyı vermemektedir. Geliştirilen ikinci yöntem ise katsayıların tamamının sınıflandırıcıya girdi olarak verilmesidir. Ancak katsayılar yani öznitelikler sınıflandırıcıya girdi olarak verilmeden önce t-test filtre yöntemi ile 20 tane sınıflar arası en fazla ayırıcılığı sağlayan öznitelik seçilmektedir. Bu yöntemin başarısı tüm sınıflar için yüksek gelmektedir.

Filtre bankasının hangi aralıklarda çalıştığı ve odaklandığı frekans değerleri önemli bir parametredir. Bunlar sistemin başarımının maksimize edilmesi için kullanılabilir. Burada bükülme derecesini belirleyen (5.6)'da gösterilen c katsayısı belli aralıklarla değiştirilerek ayrılması en zor olan iki sınıf yürüme ve karışık hareketler arasındaki başarımın maksimum olduğu nokta bulunmaya çalışılmıştır. Yürüme ve karışık hareketlerin mikro-Doppler imzaları incelendiğinde bu hareketlerin birbirlerine çok benzediği görülmektedir. Bu iki hareket deneklerden alınırken koşu bandının hızı aynı tutulmuştur. Hareketlerde tek ayırt edici özellik kolların ve bacakların periyodikliklerinden kaynaklanmaktadır. Bölüm 4'de farklı öznitelik sonuçlarına bakıldığında en yüksek sonucu fiziksel öznitelikler vermektedir. Ancak fiziksel özniteliklerin yürüme ve karışık hareketleri ayırma oranı yaklaşık olarak %90 olarak çıkmaktadır. MFCC katsayıları uygulanırken 16 tane farklı yürüme ve karışık hareket verisi kullanılmaktadır. Sınıflandırıcı olarak SVM seçilmiş sınıflandırma işlemi 200 kez tekrarlanarak ortalama başarımlar bulunmuştur. Bükülme derecesi yani c 'ye göre ortaya çıkan sınıflandırma başarımları Şekil 5.9'da gösterilmektedir. Görüldüğü gibi c katsayısı 0 etrafında olduğunda sınıflandırma performansı düşmektedir. Ancak c katsayısı -1000 ile 1000 olduğunda sınıflandırma başarımları yaklaşık olarak %97 olmaktadır.



Şekil 5.9: Karışık ve yürüme hareketleri için bükülme derecesine bağlı en iyileme operasyonu

6 RADAR SİSTEM PARAMETRELERİNE VE OPERASYONEL KOŞULLARA BAĞLI ÖZİNİTELİK SEÇİMİ

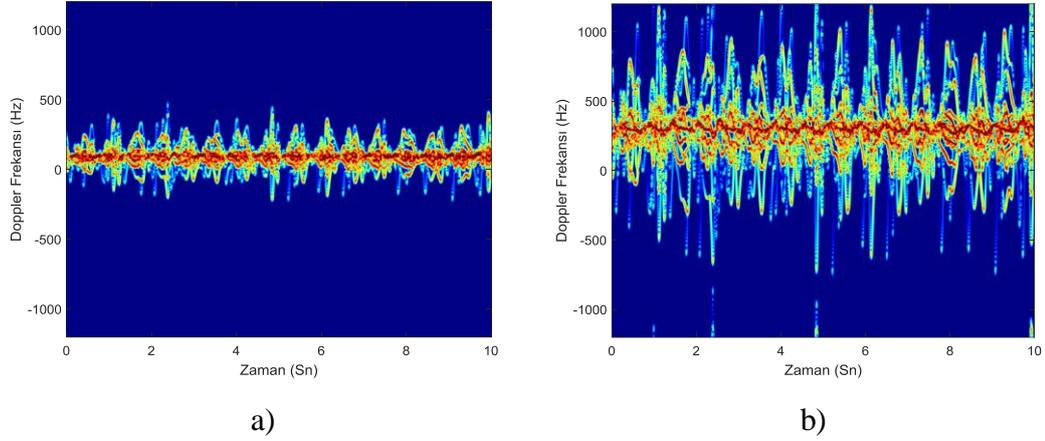
6.1 Radar Sistem Parametreleri

Darbe Doppler radarları LFM veya ötüş sinyali göndermektedirler. Gönderilen sinyalin özellikleri merkez frekansı, bant genişliği, PRF ve darbe uzunluğu göre değişmektedir. Bu parametreler aynı zamanda radarın ölçüm kabiliyetlerini de etkilemektedir. Örnek olarak menzıl çözünürlüğü bant genişliğine, Doppler çözünürlüğü darbe tekrarlama sıklığına ve Doppler kayması merkez frekansa bağlı olarak değişmektedir. Bu çalışmada önemli iki radar parametresi olan merkez frekansı ve PRF'in mikro-Doppler tabanlı insan hareket sınıflandırma problemi üzerindeki etkisi incelenmektedir. İki radar parametresinin değişiminin farklı öznelik kümeleri üzerindeki sınıflandırma başarımına etkisinin gözlemlenmesi amaçlanmaktadır. Sınıflandırıcı olarak kullanılması ve uygulanması kolay olduğundan dolayı kNN (k=5) sınıflandırıcısı kullanılmıştır.

Doppler kayması merkez frekansa bağlı olarak değişmektedir. Benzetimler yapılırken 9 farklı merkez frekansı kullanılmıştır. Bu frekans değerleri Çizelge 6.1'de gösterilmektedir. Benzetimlerdeki merkez frekansları her bandın başlangıç değeri alınarak seçilmiştir. Şekil 6.1'de merkez frekansı 12 GHz olan bir yürüme hareketi ile 40 GHz olan bir yürüme hareketi için ortaya çıkan mikro-Doppler imzaları verilmektedir. İki mikro-Doppler imzasında da PRF 2400 Hz, görüş açısı 0° , SGO 40 dB olarak belirlenmiştir.

Çizelge 6.1: Radar frekans bantları

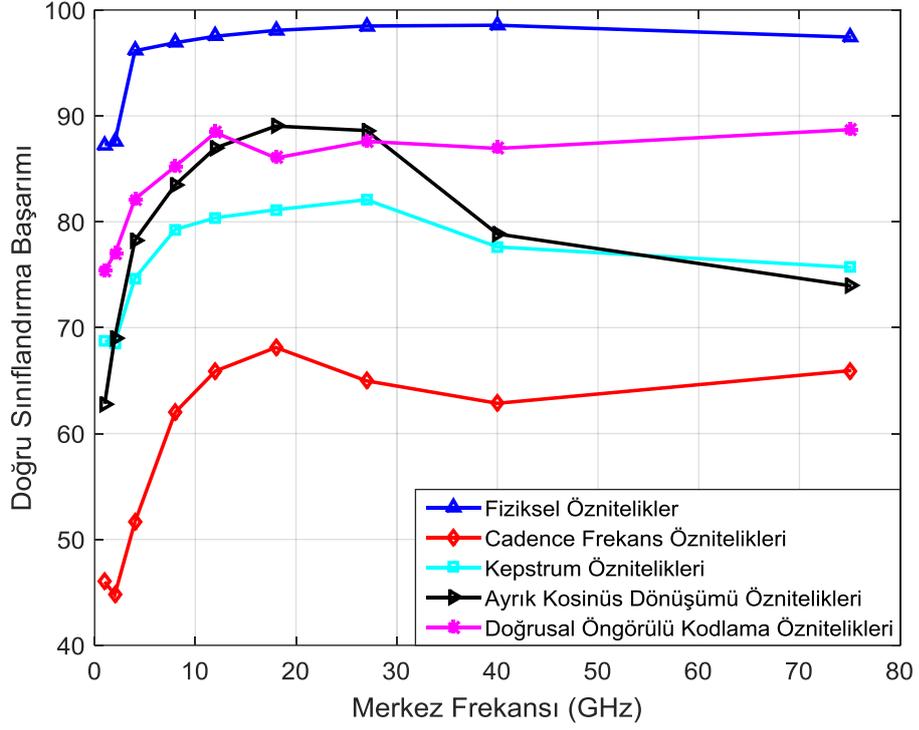
	Frekans Bantları								
	L	S	C	X	Ku	K	Ka	V	W
Değerler (GHz)	1-2	2-4	4-8	8-12	12-18	18-27	27-40	40-75	75-110



Şekil 6.1: Yürüme hareketi için farklı merkez frekanslarında ortaya çıkan mikro-Doppler imzaları a) 12 GHz b) 40 GHz

Şekil 6.1 incelendiğinde merkez frekansının Doppler kayması üzerindeki etkisi rahatlıkla görülebilmektedir. Denklem (2.1)'de gösterildiği gibi merkez frekansı artmasıyla beraber Doppler kayması doğru orantılı olarak artmaktadır. Düşük merkez frekans değerlerinde ise Doppler kayma değerleri çok küçük olacaktır. Çok yüksek merkez frekans değerlerinde ise Şekil 6.1.b'de görüldüğü gibi PRF yeterince büyük olmadığından dolayı Doppler frekans ekseninde kırılmalar meydana gelmekte ve alt frekans değerlerine bindirmeler oluşmaktadır. Bu etki Doppler belirsizliği yaratmakta, çıkartılan öznitelikler yanlış olmaktadır.

Radar merkez frekansının değişik öznitelik kümeleri için ortaya çıkan sınıflandırma sonuçları Şekil 6.2'de gösterilmektedir. Bölüm 4'de detaylı olarak anlatılan 6 farklı öznitelik kümesi kullanılarak farklı merkez frekans değerleri için sınıflandırma sonuçları gösterilmektedir. Düşük merkez frekanslarında ayırıcı özelliğe sahip öznitelikler çıkartılmadığından dolayı tüm öznitelik kümeleri için başarımlar düşüktür. Merkez frekansı arttıkça sınıflandırma başarımlarındaki değişimler azalmaktadır. 10 GHz üzerinde doğrusal öngörülü kodlama ve fiziksel özniteliklerin sınıflandırma performanslarındaki değişimler azalmıştır. Kepstrum ve ayırık kosinüs dönüşümü öznitelikleri incelendiğinde 27 GHz değerlerinden sonra düşüğe geçmektedir. Bunun sebebi iki öznitelik yönteminde homomorfik filtreme tabanlı olmasından kaynaklandığı düşünülmektedir.



Şekil 6.2: Farklı merkez frekanslarının değişik öznitelik kümeleri üzerindeki sınıflandırma etkileri

Cadence frekans öznitelikleri genel olarak sabit bir başarımla diğer öznitelik kümelerine göre sınıflandırma sonuçları çok düşük çıkmaktadır. Sonuç olarak Şekil 6.2'den de anlaşılabilceği gibi mikro-Doppler tabanlı insan hareket sınıflandırma için düşük merkez frekansları uygun olmamaktadır. Fiziksel öznitelikler merkez frekansından en az etkilenen ve en yüksek başarımla veren öznitelik kümesi olarak görülmektedir.

Önemli bir sorun PRF ile merkez frekansı arasında olması gereken oranının yeterli olmaması durumunda ortaya çıkmaktadır. Burada PRF yüksek olduğundan dolayı Doppler belirsizlikleri çok görülmemekte, sınıflandırma başarımları büyük ölçüde bu durumdan etkilenmemektedir. Ancak bu konuya dikkat edilmediği takdirde yukarıda gösterilen kırılmalar ve bindirmelerden dolayı frekans alanında belirsizlikler oluşacak ve sınıflandırma başarımları oldukça etkilenecektir.

Radarlar periyodik seri halinde darbeler yollamaktadırlar. Bu periyodiklik zaman alanında PRI olarak adlandırılmaktadır. Frekans alanında ise PRF olarak

isimlendirilmektedir. PRF radar sisteminin kullanım amacına göre geniş bir aralığa sahip olabilir.

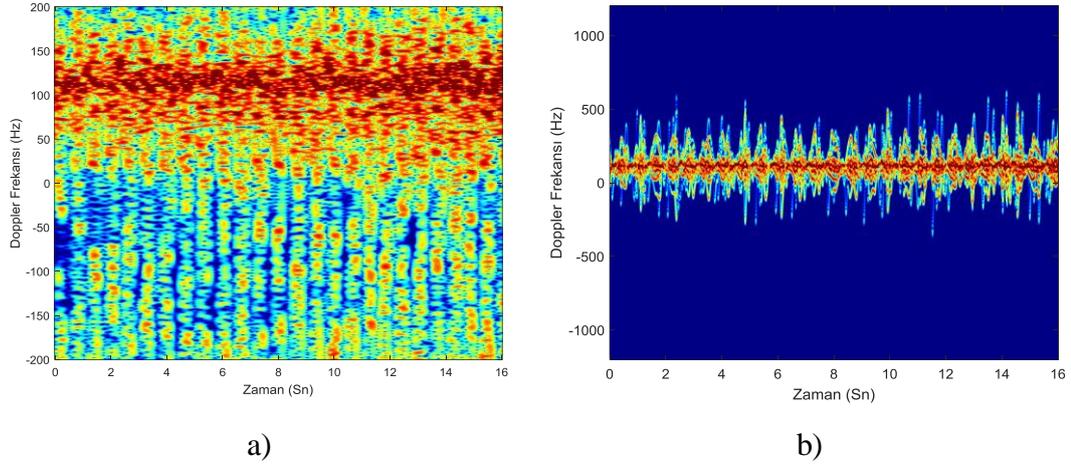
Radar tarafından ölçülebilen kesin radyal hızın, radarın ölçmek istediği hedefin hızıyla en az aynı olması gerekmektedir. Bundan dolayı radarın ölçeceği kesin hız, merkez frekansı f veya dalga boyu $\lambda = c/f$ ve iki örnek noktası arasındaki zaman aralığına Δt 'ye bağlıdır.

$$v_{maks} = \frac{f_{Dmaks}}{2f/c} = \pm \frac{\lambda}{4\Delta t} \quad (6.1)$$

Uyumlu darbe radarı hem hız hem de menzil ölçümü yapabilmekte ve zaman aralığı $1/\Delta t$ PRF'e eşit olmaktadır. Bundan dolayı darbe Doppler radarının ölçebileceği maksimum hız

$$v_{maks} = \pm \frac{\lambda PRF}{4} \quad (6.2)$$

(6.2)'de tanımlanan ifade $\lambda PRF/4$ 'den daha büyük hızlar Nyquist hızları denilen $\pm \lambda PRF/4$ 'e katlanacaktır. PRF'in arttırılması ile ölçülebilecek maksimum hızlarda artacaktır. PRF'in menzil belirsizliği üzerinde de bir etkisi bulunmaktadır ancak mikro-Doppler imzaları menzile bağlı olmadığından bu çalışmada incelenmemiştir. Şekil 6.3'de düşük ve yüksek PRF'e sahip radarlar için ortaya çıkan yürüme mikro-Doppler imzası gösterilmektedir. İki mikro-Doppler imzasında da merkez frekansı 15 GHz, görüş açısı 0° , SGO 40 dB olarak belirlenmiştir. Denekler radara doğru yürümektedir.

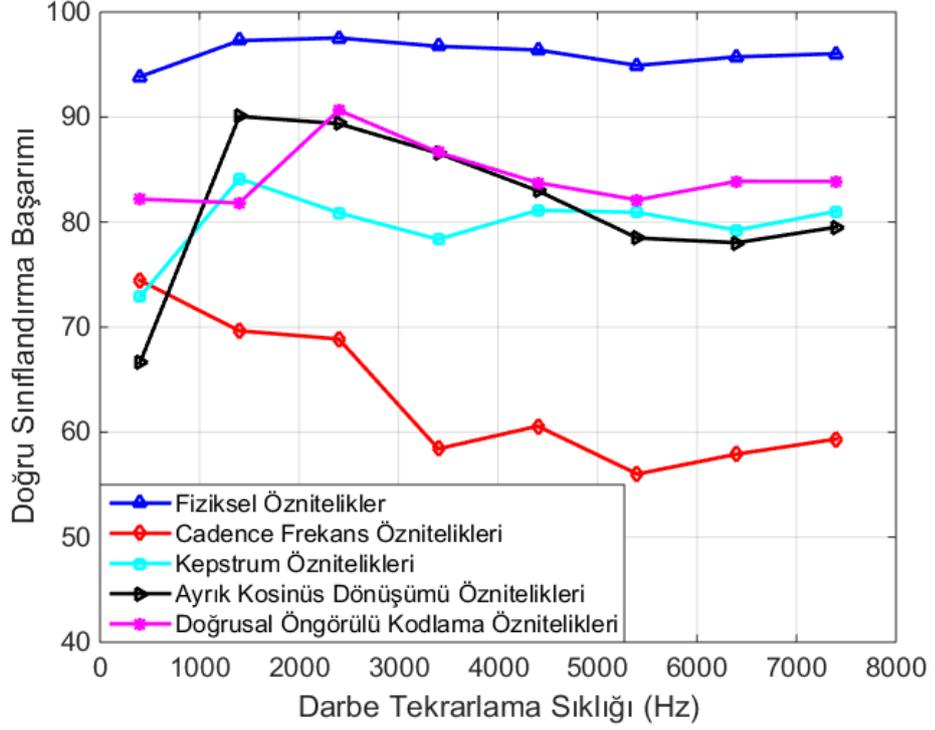


Şekil 6.3: Yürüme hareketi için farklı PRF değerlerinde ortaya çıkan mikro-Doppler imzaları a) 400 Hz b) 2400 Hz

Bölüm 2’de detaylıca anlatıldığı gibi Kinect’den alınan 3 boyutlu zamanla değişen pozisyon verilerine ara değerlendirme yöntemi uygulanarak istenen örnekleme frekansına getirilmektedir. Burada tanımlanan örnekleme frekansı PRF’i temsil etmektedir. Şekil 6.3.a’da görüldüğü gibi düşük PRF’ler kullanıldığında alınan veriler iyi şekilde modellenememektedir. Şekil 6.3.b’ye bakıldığında ise harekete ait özellikler net bir şekilde görülmektedir. Diğer önemli bir etki ise Doppler frekans düzleminde katlamaların meydana gelmesidir. Şekil 6.3.a’da görülebileceği gibi PRF’in düşük olduğu durumlarda Doppler belirsizlikleri ortaya çıkmaktadır. Burada insan yürümesinde meydana gelen Doppler kaymaları radarın gözlemleyebileceği Doppler kaymasından daha fazla olduğundan frekans alanında katlamalar görülmektedir.

Şekil 6.4’de farklı öznitelik kümelerinin değişik PRF değerleri için sınıflandırma başarımları verilmektedir. Kullanılacak olan PRF değerinin radarın kullanım alanına göre belirlenmesi gerekmektedir. Örnek olarak hava gözetleme radarı için yüksek PRF değerleri seçilmelidir çünkü tespit edilmesi gereken hedefler yüksek hızlara sahiptir. Kara gözetleme radarı için yüksek PRF seçilmesi durumunda Doppler spektrumu çok genişleyecek ve istenilen aralıktaki hedef kaymaları gözden kaçabilecektir. Bundan dolayı bazı öznitelik kümelerinde yüksek PRF değerlerinde düşüşler meydana gelmektedir. Şekil 6.4 incelendiğinde en yüksek başarımın fiziksel öznitelikler

tarafından verildiği görülmektedir. Aynı zamanda fiziksel özniteliklerin sınıflandırma başarımının PRF değişiminden çok fazla etkilenmediği de gözlemlenmektedir.



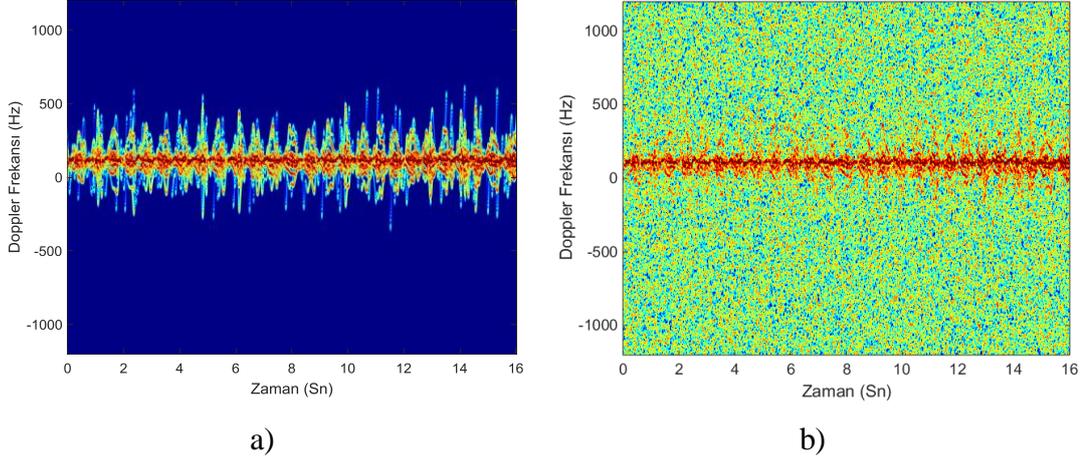
Şekil 6.4: Farklı darbe tekrarlama sıklık değerlerinin değişik öznitelik kümeleri üzerindeki sınıflandırma etkileri

6.2 Sinyal Gürültü Oranı

Günümüz radarlarının uzak menzillerde tespit kabiliyetinin olması istenmektedir. Ancak menzilin artması beraberinde birçok kötü etki getirecektir. Bunlardan en önemlisi sinyal gürültü oranı olarak tanımlanmaktadır. Radar menzil denklemine bağlı olarak SGO uzak menzillerde azalma göstermektedir. SGO hedef tespiti için kritik önem taşımaktadır.

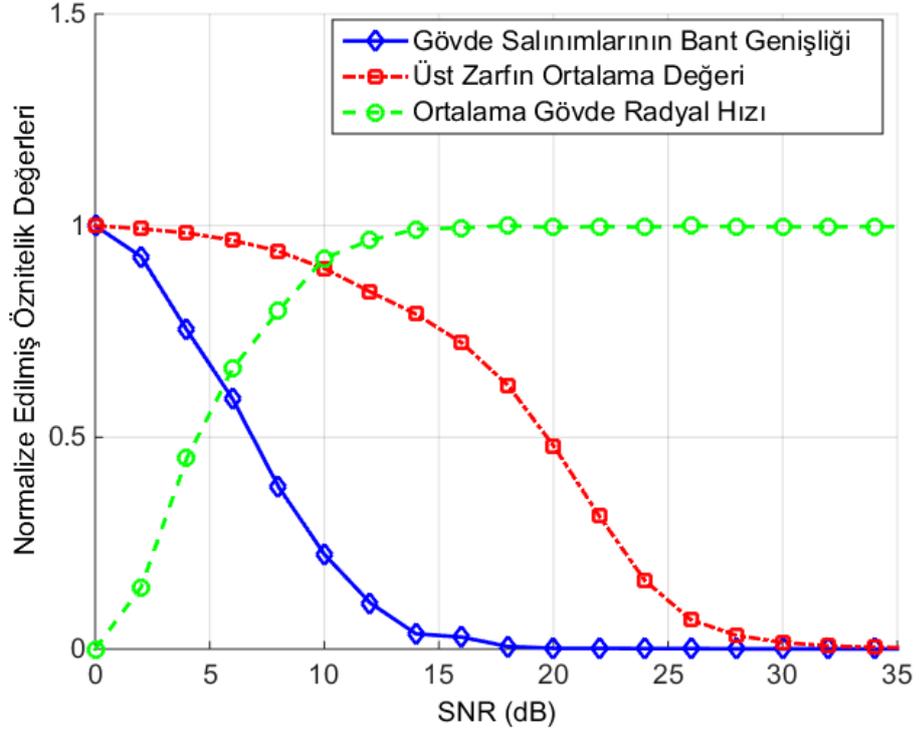
Gürültü ortamlarda mikro-Doppler imzalarından sağlıklı öznitelik çıkarımı yapmak zorlaşmaktadır. Halbuki özniteliklerin yüksek doğrulukla bulunması başarılı bir sınıflandırma işlemi için şarttır. Bu çalışmada gürültü, radar sinyalinin üzerine kompleks eklemeli beyaz Gaussian gürültü olarak eklenmiştir. İstatiksel olarak tutarlı

olabilmesi için 100 kere tekrar edilmiş ve ortalaması alınarak gürültü eklenmiş sinyal ortaya çıkartılmıştır. Şekil 6.5’de SGO’nun 35 dB ve 15 dB olduğu iki durum için ortaya çıkan yürüme mikro-Doppler imzası verilmektedir.



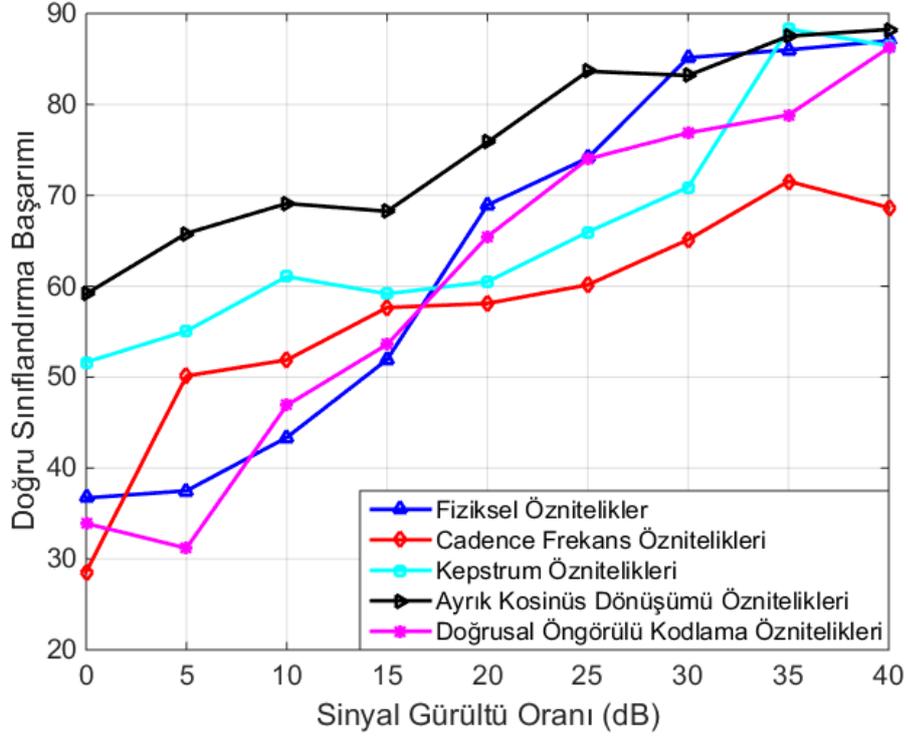
Şekil 6.5: Yürüme hareketi için farklı SGO değerlerinde ortaya çıkan mikro-Doppler imzaları a) 35 dB b) 15 dB

Şekil 6.6’da 3 tane fiziksel öznitelik değerinin SGO’ya göre değişimleri verilmektedir. Bu grafikte örnek olarak seçilen özniteliklerden ortalama ana Doppler kayması ve ana Doppler bant genişliği, kolların ve bacakların periyodik hareketi sebebiyle oluşan üst zarfın ortalama değerine daha gürbüzdür. Grafik incelediğinde bu iki gövdeye bağlı özniteliğin yaklaşık olarak 15 dB’lik SGO’da gerçek değerlerine, diğer taraftan üst zarf özniteliğinin yaklaşık olarak 30 db değerinde gerçek değerine oturduğu görülmektedir. Burada ortaya çıkan sonuçlar Şekil 6.5’de ortaya çıkan spektrogramlar ile uyumluluk göstermektedir.



Şekil 6.6: SGO'ya bağlı olarak fiziksel öznitelik değerlerinin değişimleri

Şekil 6.7'de SGO'ya bağlı farklı öznitelik kümelerinin sınıflandırma sonuçları verilmektedir. Grafik incelendiğinde tüm öznitelik kümeleri için sınıflandırma başarımının SGO'nun artışına bağlı olarak yükseldiği görülmektedir. Fiziksel, doğrusal öngörülü kodlama ve cadence frekans özniteliklerinin SGO'ya olan bağımlılıkları daha fazladır. Ancak kepstrum ve ayrık kosinüs dönüşüm özniteliklerinin değişim aralıkları çok yüksek değildir. Bu iki öznitelik kümesi 0 db'de bile yaklaşık %60 başarımla verebilmektedir. Fiziksel, ayrık kosinüs dönüşümü ve doğrusal öngörülü kodlama öznitelikleri 25 dB'de %75 ile %85 arasında başarımla sağlamaktadırlar. Sonuç olarak ayrık kosinüs dönüşüm özniteliklerinin gürültüye karşı daha gürbüz olduğu görülmekte ve düşük SGO durumlarının kullanılmaları önerilmektedir.

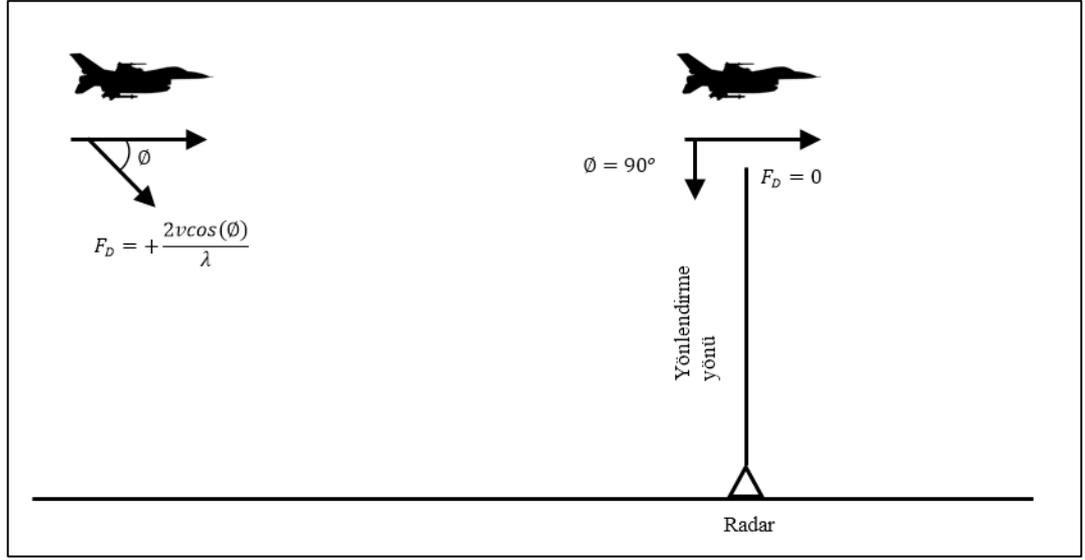


Şekil 6.7: SGO'ya bağlı olarak ortaya çıkan sınıflandırma sonuçları

6.3 Hedef Açısı Geometrisi

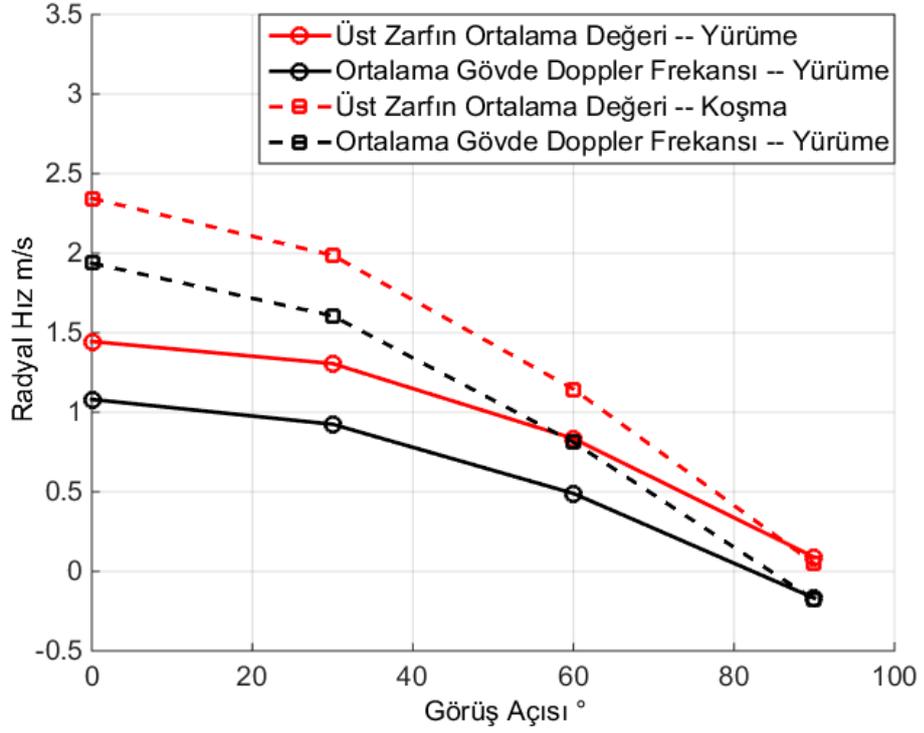
Günümüzde kullanılan radarlar sadece menzil değil hedeflerin radyal hızlarını da ölçebilmektedir. Bundan dolayı radar görüş alanı ile hedefin hareket yönü arasındaki açı mikro-Doppler imzalarını etkilemektedir. Kolaylıkla ayrıt edilebilen mikro-Doppler imzaları genellikle hedefin radara doğru veya karşı yürüdüğü ve buna bağlı olarak maksimum Doppler yayılması olduğu durumlardır.. Görüş açısının Doppler kaymasına olan etkisi Şekil 6.8'de gösterilmektedir. Radar ile hedef arasındaki açı 90° olduğu durumda Doppler kayması 0 olmaktadır. Açılı durumlarda ise Doppler kayması

$$f_d = \frac{2v \cos(\theta)}{\lambda} \quad (6.3)$$



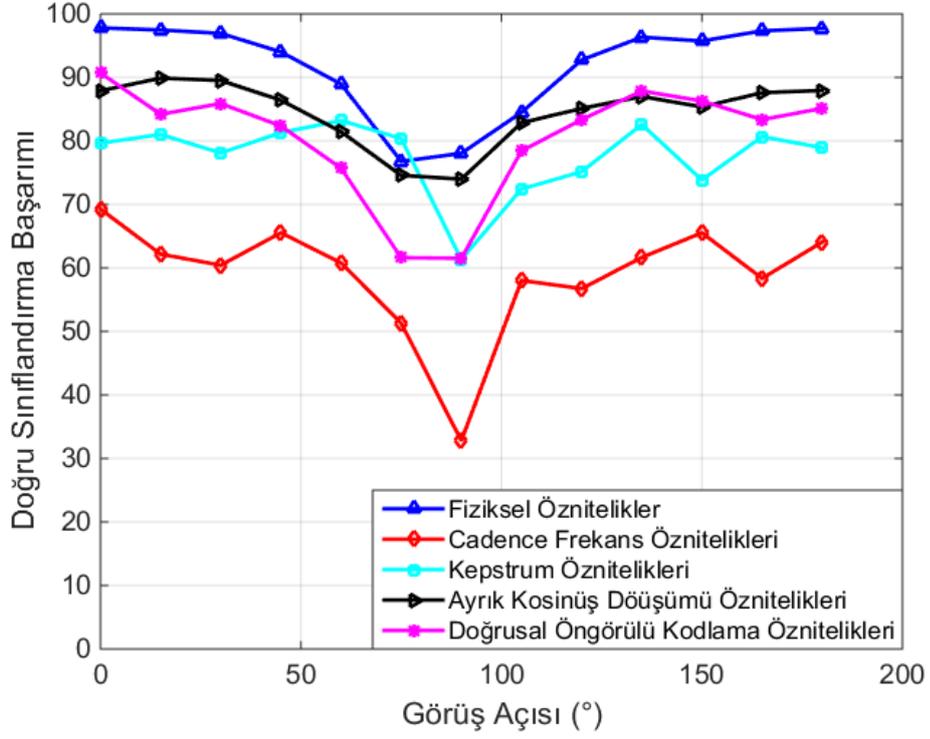
Şekil 6.8: Görüş açısının Doppler kayması üzerindeki etkisi

Görüş açısı arttıkça radar tarafından görülen radyal hız azalmakta, bağlantılı olarak Doppler yayılmasının da azalmasına sebep olmaktadır. Ortaya çıkan mikro-Doppler imzası frekans alanında sıkışık olmakta ve özniteliklerin ayırıcılık özellikleri azalmaktadır. Şekil 6.9'da iki farklı hareket için çıkartılan iki fiziksel özniteliğin farklı açılarda aldıkları değerler gösterilmektedir. Kullanılan fiziksel öznitelikler, kolların ve bacakların periyodik hareketlerinden kaynaklanan ortalama üst zarf değeri ve ortalama ana Doppler kayması olarak seçilmiştir. Görüş açısı 0° olduğu durumda hedef direk olarak radara yürümektedir. Buna bağlı olarak kullanılan öznitelik değerleri arasındaki farkın maksimum değerlerine ulaştığı ve sınıflara göre daha iyi ayırıcılık sağladığı görülmektedir. Ancak görüş açısı yükseldikçe üst zarf ve ortalama ana Doppler kayması arasındaki farklar azalmaktadır. Sonuç olarak, iki öznitelik hareketlerin değişik olmasına rağmen görüş açısının yüksek olmasından kaynaklı aynı değerlere yakınsamaktadır.



Şekil 6.9: Aynı kişinin yürüme ve koşma hareketlerinden çıkartılmış iki özneliğin görüş açısına göre aldıkları değerler

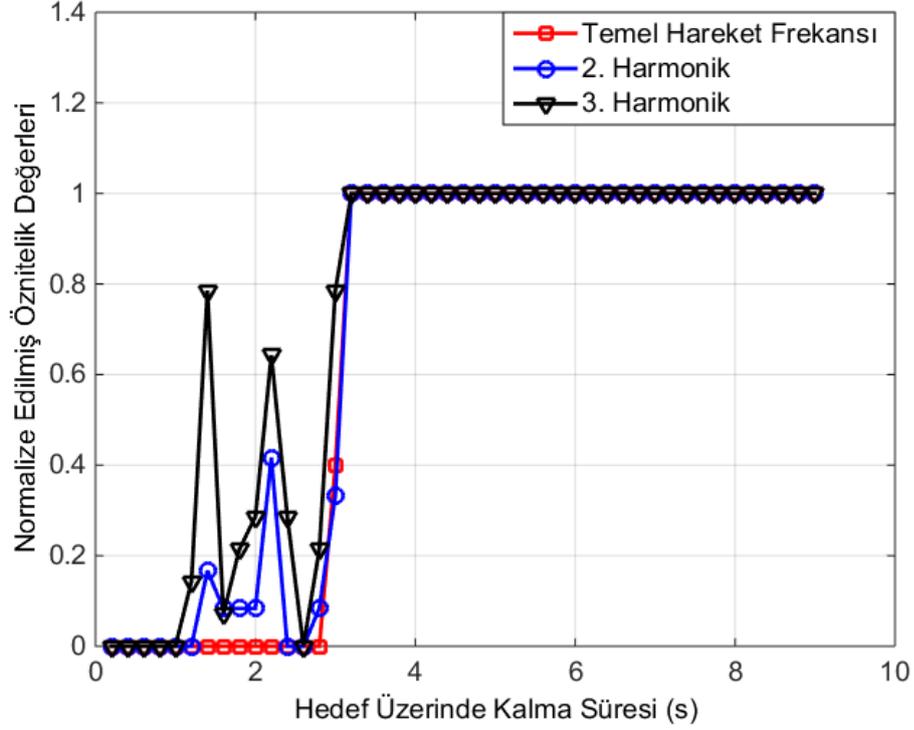
Görüş açısının etkisinin incelenebilmesi için 13 farklı açı için merkez frekansı 15 GHz, darbe tekrarlama sıklığı 2400 Hz, SGO 40 dB olacak şekilde bir veri tabanı oluşturulmuştur. 4 kişinin 6 farklı verisi kullanılarak 5 farklı hareket için bu işlemler tekrar edilmiştir. Öznelik kümelerinin sınıflandırma başarımları görüş açısının bir fonksiyonu olarak Şekil 6.10'da verilmektedir. Tüm öznelik kümelerinde görüş açısının 90° yaklaşmasıyla sınıflandırma başarımında bir düşüş yaşamaktadır. Fiziksel öznelikler en yüksek başarımları verirken ayrık kosinüs katsayılarının başarımları fiziksel özneliklere göre düşük olsa da açıya göre bağımlılığın daha az olduğu görülmektedir.



Şekil 6.10: Görüş açısına bağlı olarak ortaya çıkan sınıflandırma sonuçları

6.4 Hedef Üzerinde Kalma Süresi

Mikro-Doppler imzaları insan hareketindeki periyodik ve titreşimsel hareketlerden kaynaklandığı için hedefin gözlemlendiği zaman aralığının mikro-Doppler imzalarından çıkartılan öznitelikler üzerinde kritik bir etkisi bulunmaktadır. İyi bir sınıflandırma başarımı genellikle bu periyodikliğe bağlı olarak ortaya çıkmaktadır. Şekil 6.11’de Cadence frekans özniteliklerinin hedef üzerinde kalma süresine göre aldığı değerler gösterilmiştir. Cadence frekansı Bölüm 4’de anlatıldığı insan hareketindeki periyodiklikleri yakalanmasını sağlamaktadır. Ancak periyodiklerin çıkartılabileceği yeterli süre olmadığı durumda yanlış değerler öznitelik olarak çıkartılmaktadır. Şekil 6.10’dan da görülebileceği gibi yaklaşık 3 saniyeden sonra özniteliklerin doğru olarak çıkartılmaktadır. 0 ve 3 saniye arasında ise öznitelikler rastgele değerler alınmaktadır.



Şekil 6.11: Cadence frekans özniteliklerinin hedef üzerinde kalma süresine olan bağımlılıkları

6.5 Öznitelik Seçimi Karışıklık Matrisi

Radar parametrelerinin ve operasyonel koşulların mikro-Doppler imzalarından çıkartılan öznitelik kümelerini etkilediği görülmektedir. Her bir parametreye ve operasyonel koşula bazı öznitelik kümeleri daha bağımlı iken diğerlerinin daha gürbüz olduğu saptanmıştır. Örneğin fiziksel öznitelikler görüş açısına göre başarımları iyi olsada, SGO'ya göre bağımlılığının çok olduğu, ayırık kosinüs katsayıları görüş açısından ortalama bir performans gösterece SGO'ya karşı gürbüz olduğu görülmektedir. Zamansal kısıtlarda dikkate alındığında fiziksel özniteliklerin çıkartılmasının çok uzun zaman ve hesaplama gücü gerektirdiğinden daha az çözünürlüğe sahip doğrusal öngörülü kodlama katsayılarının kullanılması daha mantıklı olacaktır. Çıkartılan tüm öznitelik setinin sınıflandırmada kullanılması sistemi kompleks hale getirecek ve büyük olasılıkla sınıflandırma başarımlarını düşürecektir. Bundan dolayı önceden belirlenmiş zorlu bir senaryoya SFS yöntemi uygulanmıştır. Burada senaryo için görüş açısının 60° , SGO'nun 20 dB ve hedef

üzerinde kalma süresinin 1.5 saniye olduğu kısıtlar belirlenmiştir. Radar olarak merkez frekansı 15 GHz, PRF'ı 2400 Hz olan bir kara gözetleme radarı benzetimi yapılmıştır. Çizelge 6.2'de hiçbir öznitelik seçim yöntemi uygulanmadığında ortaya çıkan karışıklık matrisi verilmektedir. Çizelge 6.3'de ise 10 öznitelik seçildiği durumdaki karışıklık matrisi verilmiştir. Çizelge 6.2'de genel başarımlarının %77.75, Çizelge 6.3 incelendiğinde ise başarımlarının %86.76 olduğu görülmektedir. Bu durumda iyi seçilmiş bir öznitelik kümesinin zor operasyonel ve çevresel koşullar altında tüm öznitelik kümesine göre daha yüksek sonuçlar verdiği görülmektedir. Aynı zamanda tüm öznitelik kümesinin kullanılması durumunda boyut artacağından dolayı sınıflandırıcının kompleks yapısı artacak ve sistemi gerçek zamanlı hale getirmek zorlaşacaktır.

Çizelge 6.2: Tüm öznitelikler kullanıldığında ortaya çıkan karışıklık matrisi

		Sınıf			
		Yürüme	Koşma	Karışık Hareketler	Zıplama
Hareket	Yürüme	0.78	-	0.22	-
	Koşma	0.20	0.76	0.4	-
	Karışık Hareketler	0.35	-	0.65	-
	Zıplama	0.8	-	-	0.92

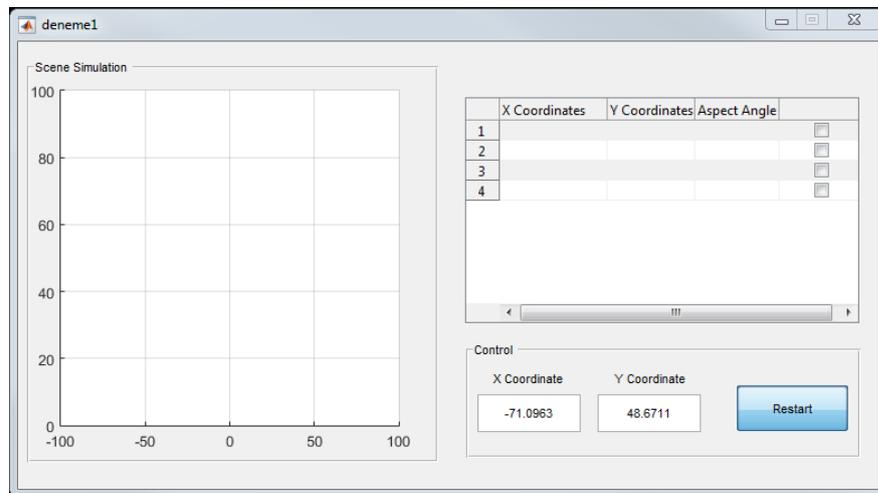
Çizelge 6.3: Öznitelik seçimi yapıldığında ortaya çıkan karışıklık matrisi

		Sınıf			
		Yürüme	Koşma	Karışık Hareketler	Zıplama
Hareket	Yürüme	0.83	-	0.17	-
	Koşma	-	1.0	-	-
	Karışık Hareketler	0.26	-	0.74	-
	Zıplama	-	-	0.10	0.90

7 UYARLANABİLİR ÖZNETELİK SEÇİMİ

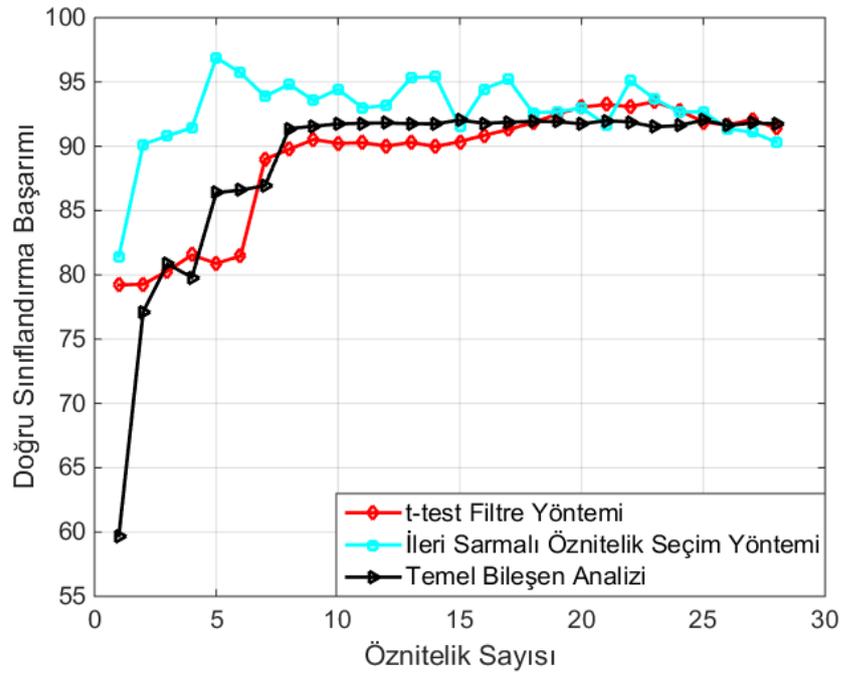
Bölüm 6’da gösterildiği gibi sınıflandırma performansı birçok çevresel ve operasyonel koşula bağlı olarak değişmektedir. Gerçek hareketler göz önüne alındığında insanlar her zaman sabit bir rotada ve belli bir hızla yürüyememektedir. Hedefin aydınlatıldığı süre, hedef-açı geometrisi, SGO gibi birçok durum sınıflandırma performansını kötüleştirecek şekilde etki etmektedir. Bundan dolayı, öznetelik seçim yöntemleri kullanılarak verilen bir durum için sınıflandırma başarımı iyileştirilebilmektedir. Gerçek, dinamik ve açının değiştiği bir rotanın sınıflandırma başarımını test edilmek için önceden tanımlanmış ve seçilmiş bir eğitim verisi oluşturulmalıdır. Bu bölümde dinamik hareket rotaları için sınıflandırma performansını iyileştirecek bir uyarlanabilir öznetelik seçim algoritması önerilmiştir.

Gerçeğe yakın dinamik rotalar sahip test verileri oluşturabilmek için Şekil 7.1’de verilen MATLAB tabanlı kullanıcı arayüzü oluşturulmuştur. Program radarı (0,0) koordinatlarında konumlandırmakta, uzaklığa ve verilen noktaya göre bir açı hesaplaması yapmaktadır. Hedefin genellikle hareket yönü aşağı olarak kabul edilmekte elde edilen açı değeri kadar hedef çevrilmektedir. Gerekli açı verileri oluşturulduktan sonra Bölüm 3’de anlatılan Kinect tabanlı mikro-Doppler benzetim sistemine girdi olarak verilmekte ve veri tabanı oluşturulmaktadır.



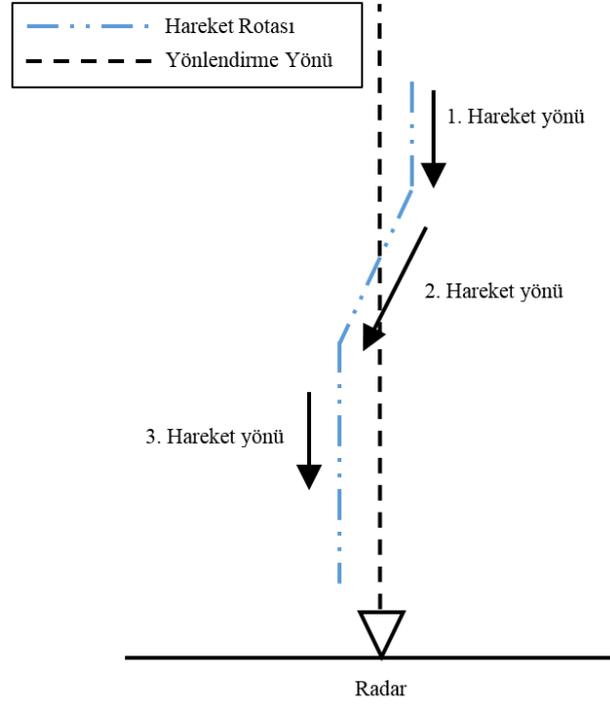
Şekil 7.1: Açı değerlerinin yaratılması için oluşturulan MATLAB tabanlı kullanıcı arayüzü

Öznelik seçimi, uyarlanabilir öznelik seçim yönteminin önemli bir kısmıdır. Bu bölümde seçilen öznelik sayısının sınıflandırma başarımı üzerindeki etkisinin gözlemlenmesi istenmektedir. Şekil 7.2’de iki öznelik seçim yöntemi ve bir boyut indirgeme yöntemi - t-test filtre, SFS ve PCA - için bir karşılaştırma yapılmaktadır. Bu veri tabanı oluşturulurken hedeflerin direk olarak radara doğru yürüdükleri durum seçilmiştir. Şekil 7.2’den görülebileceği gibi öznelik sayısı 10’nun altındayken PCA ve t-test filtre yöntemleri iyi sonuç vermemektedir. Bundan dolayı öznelik sayısı bu bölümdeki tüm simülasyonlar için 10 olarak seçilmiştir.

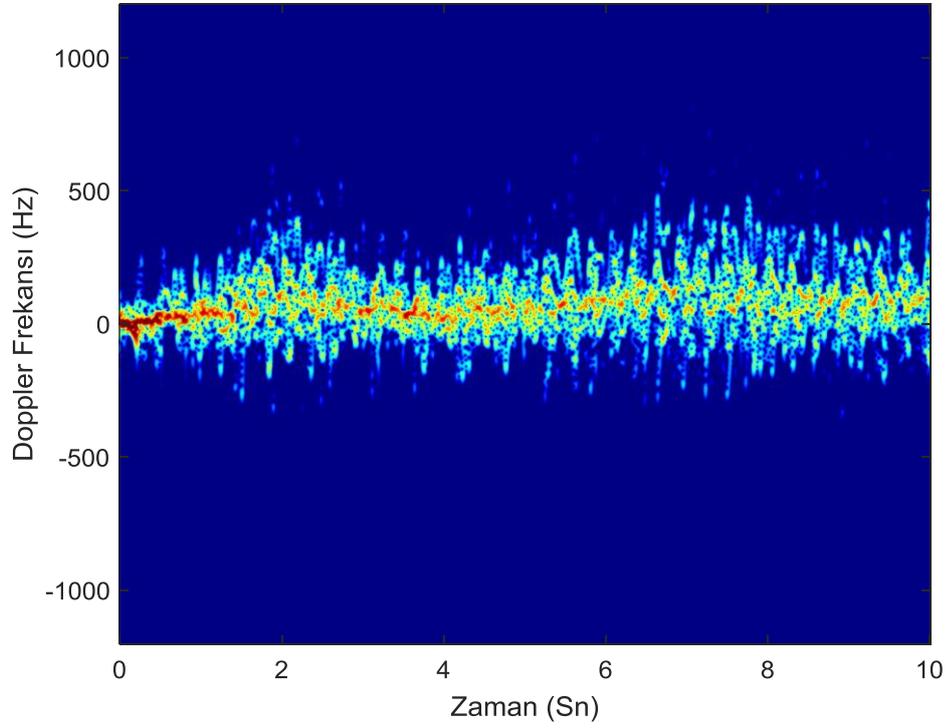


Şekil 7.2: Öznelik seçim yöntemlerinin başarımlarının öznelik sayısına göre değişimi

Açı verileri Kinect tabanlı mikro-Doppler benzetim sistemine verildikten sonra X (15 GHz) bandında yayın yapan, PRF’ı 2400 olan ve 60° lik bir görüş genişliğine sahip olan radar benzetimi yapılmıştır. Hareket rotası hedefin ilk olarak radar yaklaşık olarak 0° lik bir açıyla yürüdüğü, açının artarak hareket yönünün değiştiği ve tekrardan hedefin 0° yakın bir açıyla radara yürüdüğü durum incelenmektedir. Hedefin yürüme rotası Şekil 7.3.a’da verilmektedir. Bu hareket sonucu ortaya çıkan spektrogram ise Şekil 7.3.b’de gösterilmektedir.



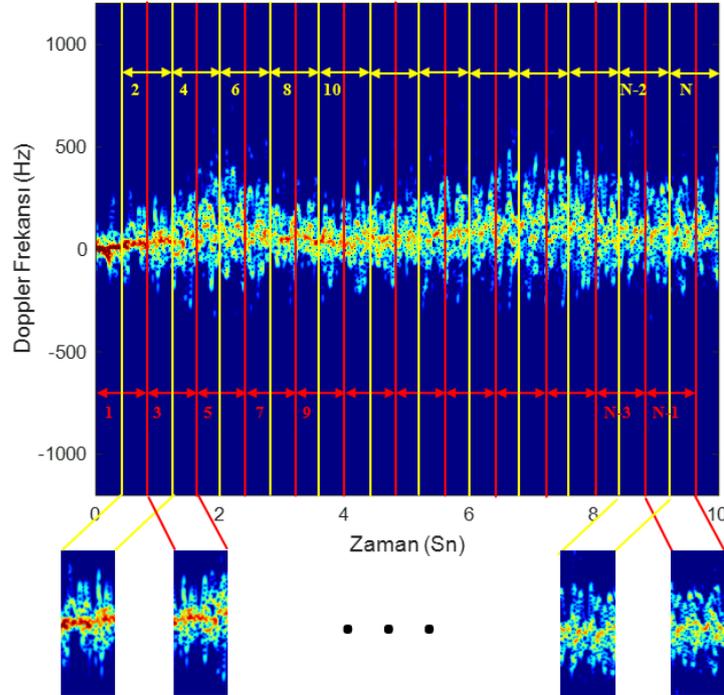
a)



b)

Şekil 7.3: Örnek olarak oluşturulan a) Hareket rotası b) Hareketin spektrogramı

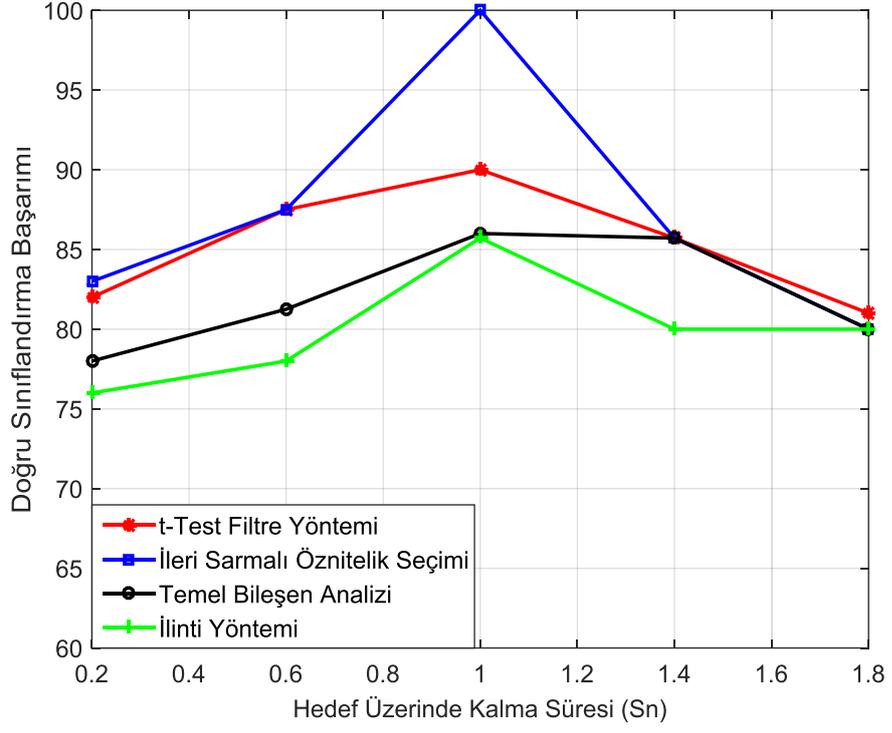
Bu çalışmada uyarlanabilir bir öznitelik seçim yöntemi önerilmektedir. Şekil 7.3.b'deki açılı spektrogram incelendiği durumda zamana bağlı olarak mikro-Doppler imzasındaki Doppler kaymalarında değişiklikler meydana geldiği görülmektedir. Ortaya çıkan mikro-Doppler imzasına bir bütün olarak bakıldığında açılı kısmındaki değişimlerden dolayı öznitelikler yanlış olarak çıkartılacaktır. Açılı kısımdaki Doppler kaymaların düşük olmasından dolayı asıl hareket olan yürüme özellikleri kaybedilecektir. Uyarlanabilir öznitelik seçim yönteminde tüm verinin tek bir imza olarak incelenmesi yerine, verinin çoklu ve kısa süreli olarak incelenmesi önerilmektedir. Bölüm 6.4'te gösterildiği gibi hedef üzerinde kalma süresinin artmasına ve azalmasına bağlı olarak sınıflandırma başarımı artmakta veya azalmaktadır. Geçici örnekleme arttırmak için belirlenen hedef üzerinde kalma sürelerine belli bir örtüşme uygulanmaktadır. Bu örtüşme ile segmentlerin boyutlarını ve sınıflandırma başarımını arttırmak amaçlanmaktadır. Örtüşmenin ve segment sürelerinin spektrogram üzerinde anlatılması Şekil 7.4'te verilmektedir. N segmente ayrılan spektrograma örtüşme uygulanmaktadır. Her ayrılan bölüm ayrı olarak incelenmekte açıdan kaynaklı etkiler azaltılmaya çalışılmaktadır.



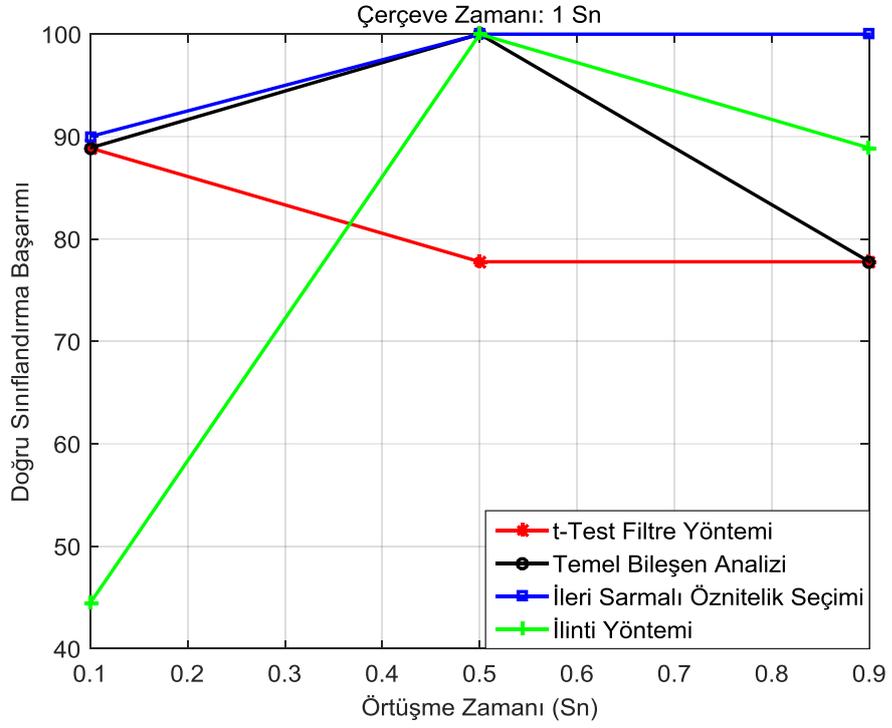
Şekil 7.4: Segmentasyon ve örtüşmenin spektrogram üzerinde anlatılması

Eđitim verileri üç farklı hareketten oluřmaktadır. Bunlar yürüme, kořma ve zıplama olarak seçilmiřtir. Bu üç farklı hareketin 0°, 30° ve 60° deki açıları kullanılmıřtır. Bu veriler eğitim seti olarak kullanılmıř, tüm öznitelik seçim yöntemlerine verilmiř ve çıkan öznitelikler ile bir kNN (k=5) sınıflandırıcısı eğitilmiřtir. Sonra gelen test verisi üzerindeki tüm segmentler için öznitelikler ayrı ayrı çıkartılmıř ve önceden oluřturulan sınıflandırıcılara test verisi olarak verilmiřtir. Ařađıda anlatılacađı gibi segment ve örtüřme süresi belirlendikten sonra sınıflandırma başarımlarına toplu olarak bakılmıřtır.

Oluřturulan test spektrogramının segment zamanının bulunması için veri üzerinde bir zaman analizi yapılmıřtır. Ortaya çıkan grafik Őekil 7.5.a'de verilmektedir. Neredeyse tüm öznitelik seçim yöntemlerinin performansı 1. saniyede bir yükselme göstermektedir. PCA bu artıřı 1.4 saniyede de göstererek sonradan azalmaktadır. Hedef üzerinde kalma süresi 1 saniye olarak seçilmiřtir. SFS yöntemi herhangi bir örtüřme zamanına ihtiyaç duymadan 1. saniyede %100 sınıflandırma başarımlı vermektedir. Diđer kalan yöntemler için sınıflandırma başarımlının arttırılması kritik bir öneme sahiptir. Çünkü SFS yöntemi hantal bir yöntem olduđundan dolayı fazla zaman ve hesaplama gücüne ihtiyaç duymaktadır. Bundan dolayı SFS yönteminin gerçek zamanlı bir sisteme uygulanması zorlařmaktadır. Ancak t-test filtre, ilinti ve PCA yöntemleri daha hızlı çalışmakta ve herhangi bir sınıflandırma sonucuna ihtiyaç duymamaktadır. Sadece veriler arasındaki istatistiksel iliřkilere bakarak bir ayırım yapmaktadırlar. Seçilen örtüřme zamanları için ise ortaya çıkan grafik Őekil 7.5.b'de verilmektedir. Kolaylıkla görülebileceđi gibi örtüřme zamanı 0.5 saniye seçildiđinde t-test filtre yöntemi dıřında tüm yöntemler %100 başarımlı ile test verisini yürüme olarak sınıflandırmaktadır. t-test filtre yönteminde yaklaşık %5'lik bir düşüř gözlemlenmektedir. Ancak her yöntemin seçtiđi öznitelikler farklı olduđundan dolayı tüm yöntemler için genel bir örüntü yakalamak zorlařmaktadır. T-test filtre yöntemi için farklı segment ve örtüřme zamanları denendiđinde sınıflandırma performansını maksimum yapabilecek zaman deđerleri bulunabilecektir. Ancak genel haliyle incelendiđinde 4 yöntemden 3'ünde %100'lük bir başarı görüldüđünden dolayı yöntemin başarıyla çalıştıđı söylenebilmektedir. Bundan dolayı örtüřme zamanı 0.5 olarak seçilmiřtir.



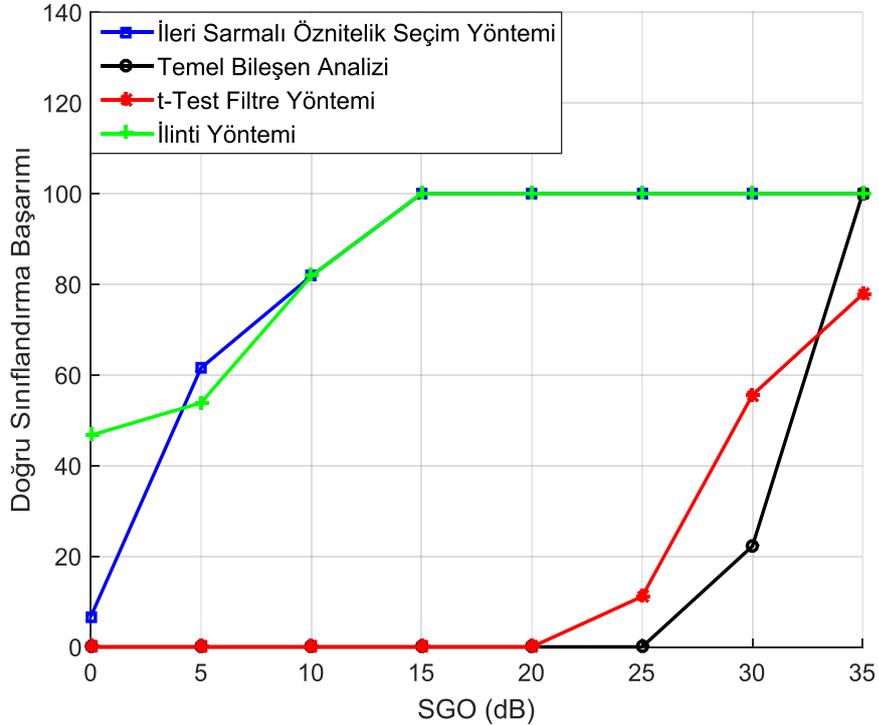
a)



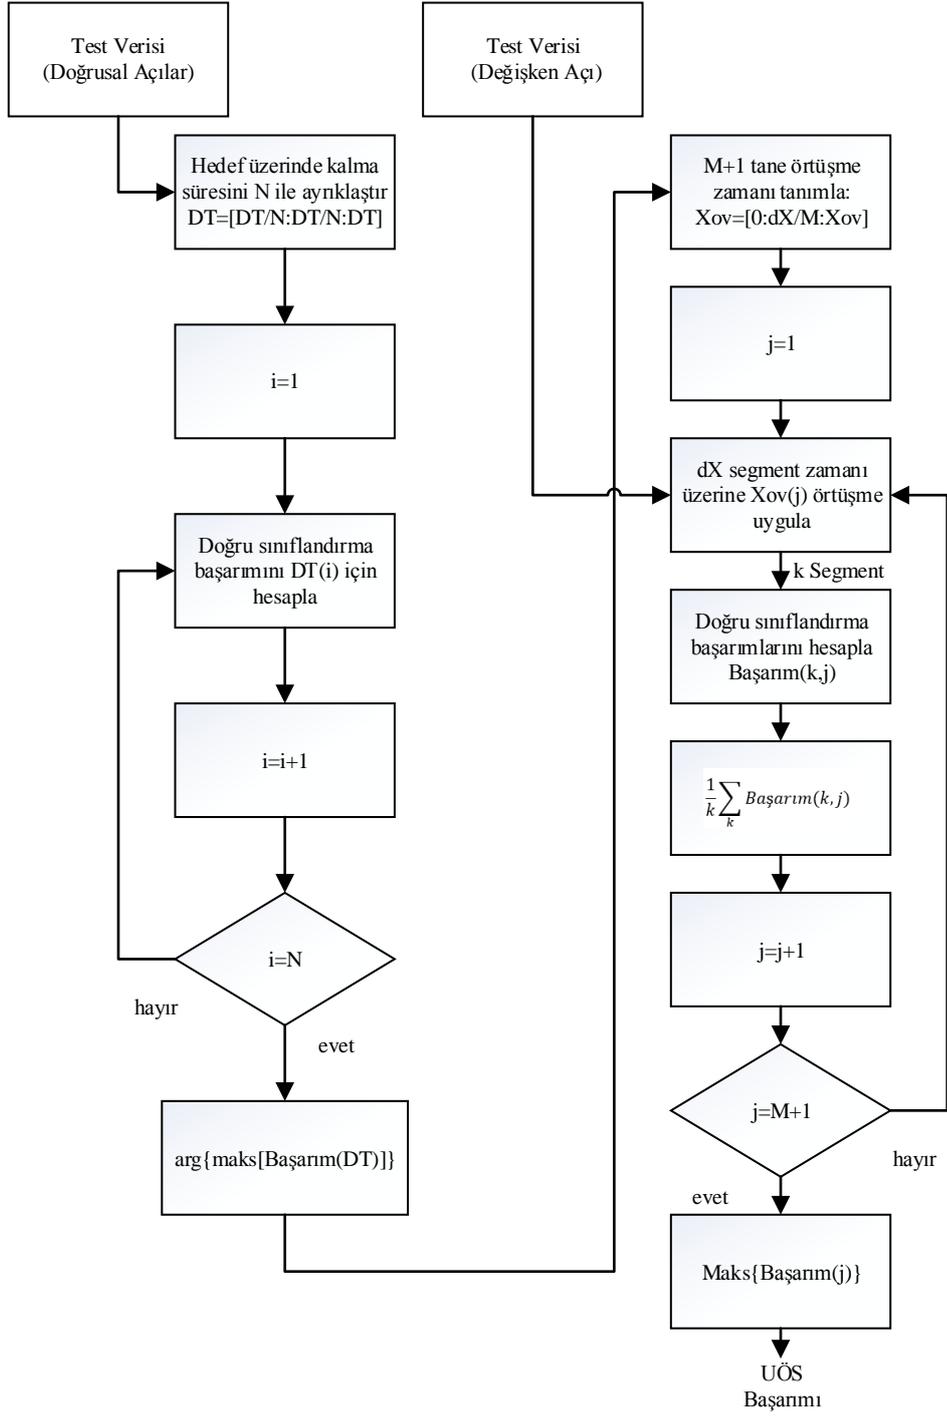
b)

Şekil 7.5: Öznitelik seçim yöntemlerinin a) Segmentasyon b) Örtüşme zamanı için ortaya çıkan sınıflandırma sonuçları

Bu yöntemin farklı koşullar altında yararlarının görülebilmesi için test verilerine farklı SGO'lar eklenerek başarımlarını karşılaştırılmıştır. SGO'ya göre ortaya çıkan sınıflandırma performansları Şekil 7.6'de verilmektedir. Görülebildiği gibi SFS ve ilinti yöntemi gürültüye karşı çok daha gürbüzdür. Yaklaşık olarak 15 db'de başarımın %100 olduğu görülmektedir. Diğer öznitelik seçim ve boyut indirgeme yöntemleri incelendiğinde ise en temiz verilerde çıkardıkları başarımların Şekil 7.5.b'deki sonuçlar uyumlu oldukları ancak seçtikleri özniteliklerin gürültüye dayanıklı olmadığı saptanmıştır. SGO'nun 20 db olduğu duruma kadar sınıflandırma başarımı 0 olarak görülmekte sonradan bir artış meydana gelmektedir. İlinti yöntemi SFS yöntemiyle aynı sonuçları verdiği için dolayı zamansal ve hesaplamalar kısıtları düşünülürken daha avantajlı olarak ortaya çıkmaktadır. Uyarlanabilir öznitelik seçiminin akış şeması Şekil 7.7'da gösterilmektedir.



Şekil 7.6: Uyarlanabilir öznitelik seçim yönteminin SGO'ya göre ortaya çıkan sınıflandırma sonuçları



Şekil 7.7: Uyarlanabilir öznitelik seçim yöntemini akış şeması

8 SONUÇ ve GELECEK ÇALIŞMALAR

Bu çalışmadan, çeşitli sonuçlar çıkartılmaktadır. İlk olarak yeni bir mikro-Doppler benzetim sistem oluşturulmuştur. Benzetim sistemi sonuçlarına bakıldığında farklı hareketler için ortaya çıkan mikro-Doppler imzalarının gerçek veriler ile benzerlik gösterdiğinden dolayı literatüre yeni bir benzetim sistemi kazandırılmıştır. Ham verilerin Kinectten alınması dolayısıyla farklı insanlara bağlı mikro-Doppler imzaları oluşturulabilmektedir. Benzetim sistemiyle veri tabanı oluşturulması kullanıcının elindedir. Simülasyonun bir başka yararı ise radar parametrelerinin değiştirebilmesi sebebiyle farklı radarlar için mikro-Doppler imzaları oluşturulabilmektedir.

Çalışma kapsamında, 5 farklı öznitelik kümesinin matematiksel tabanları ile çıkarılma yöntemleri anlatılmıştır. Farklı öznitelik kümeleri için farklı sınıflandırıcıların verdiği sınıflandırma sonuçları verilmiş ve performans karşılaştırılması yapılmıştır. Bazı öznitelik kümelerinin başarımları düşük olurken bazılarının yüksek başarıma sahip olduğu gözlemlenmiştir. Farklı sınıflandırıcıların performans yükseltilmesinde çok etkili olmadığı önemli olan noktanın özniteliklerin ayırıcılık özellikleri olduğu görülmüştür. Ses tanımada kullanılan insan mikro-Doppler imzalarına uyarlanmış yeni bir öznitelik kümesi oluşturulmuştur. Öznitelik kümesinde kaba kuvvet yöntemi kullanılarak birbirleriyle en çok karışmayı yapan yürüme ve karışık hareketler arasındaki ayırım performansı yaklaşık olarak %97 oranına yükseltilmiştir.

Çevresel ve operasyonel koşulların öznitelik kümeleri üzerindeki etkisi araştırılmıştır. Sonuç olarak bazı özniteliklerin çevresel ve operasyonel koşullara bağlı olduğu görülürken diğerlerinin daha gürbüz sonuçlar verdiği saptanmıştır. Aynı zamanda farklı koşullar için farklı öznitelik kümeleri iyi sonuçlar verdiğiinden dolayı çevresel ve operasyonel koşullar altında öznitelik seçiminin gerekliliği ortaya çıkartılmıştır. Zorlu koşullarda öznitelik seçim yönteminin başarımları yaklaşık olarak %10 arttığı gösterilmiştir.

Son bölümde ise dinamik ve açının sürekli deđiřtiđi rotalarda sınıflandırma başarımını yükseltecek bir yöntem önerilmiřtir. Uygulanan yöntemin seçilen rota için %100 başarıya ulařtıđı gösterilmiřtir. Böylelikle yöntemin geçerliliđi kanıtlanmıřtır.

Gelecek çalışmalar için oluşturulan veri tabanına daha fazla veri ve hareket eklenecektir. Böylelikle geliştirilen algoritmalar test edilirken daha güvenilir sonuçlar elde edilmesi planlanmaktadır. Birbirine daha çok karıřacak hareketler çıkartılarak sınıf sayısı yükseltilebilir. Literatürde önerilen daha deđiřik öznitelik kümeleri eklenecek, yenilikler yapılacak ve sınıflandırma sonuçları incelenecektir. Bu çalışmada kullanılmayan sınıflandırıcılar kullanılarak sonuçlar paylaşılacaktır. Farklı radar parametrelerinin -bant genişliđi vb. - mikro-Doppler imzaları üzerindeki etkileri araştırılacaktır. Literatürde bulunan farklı öznitelik seçim yöntemleri simülasyona eklenecektir. Önerilen yöntem daha geliştirilerek, genel bir forma getirilip dinamik olarak parametreler kendiliđinden belirlenmesi sağlanacaktır.

KAYNAKLAR

- [1] X.-B. Cao, H. Qiao, ve J. Keane, “A Low-Cost Pedestrian-Detection System With a Single Optical Camera”, *IEEE Trans. Intell. Transp. Syst.*, c. 9, sayı 1, ss. 58–67, Mar. 2008.
- [2] L. Jiang, F. Tian, L. E. Shen, S. Wu, S. Yao, Z. Lu, ve L. Xu, “Perceptual-based fusion of IR and visual images for human detection”, içinde *Proceedings of 2004 International Symposium on Intelligent Multimedia, Video and Speech Processing, 2004*, 2004, ss. 514–517.
- [3] M. Mercuri, P. J. Soh, X. Zheng, P. Karsmakers, G. A. E. Vandebosch, P. Leroux, ve D. Schreurs, “Analysis of a fall detection radar placed on the ceiling and wall”, içinde *Microwave Conference (APMC), 2014 Asia-Pacific*, 2014, ss. 947–949.
- [4] B. Erol ve S. Z. Gurbuz, “A kinect-based human micro-doppler simulator”, *IEEE Aerosp. Electron. Syst. Mag.*, c. 30, sayı 5, ss. 6–17, May. 2015.
- [5] D. P. Fairchild ve R. M. Narayanan, “Classification of human motions using empirical mode decomposition of human micro-Doppler signatures”, *IET Radar Sonar Navig.*, c. 8, sayı 5, ss. 425–434, Haz. 2014.
- [6] Y. Wang, Q. Liu, ve A. E. Fathy, “CW and Pulse Doppler Radar Processing Based on FPGA for Human Sensing Applications”, *IEEE Trans. Geosci. Remote Sens.*, c. 51, sayı 5, ss. 3097–3107, May. 2013.
- [7] Y. Kim ve H. Ling, “Human activity classification based on micro-Doppler signatures using an artificial neural network”, içinde *IEEE Antennas and Propagation Society International Symposium, 2008. AP-S 2008*, 2008, ss. 1–4.
- [8] Y. Kim ve H. Ling, “Human Activity Classification Based on Micro-Doppler Signatures Using a Support Vector Machine”, *IEEE Trans. Geosci. Remote Sens.*, c. 47, sayı 5, ss. 1328–1337, May. 2009.
- [9] B. Cagliyan ve S. Z. Gurbuz, “Micro-Doppler-Based Human Activity Classification Using the Mote-Scale BumbleBee Radar”, *IEEE Geosci. Remote Sens. Lett.*, c. PP, sayı 99, ss. 1–5, 2015.
- [10] S. Bjorklund, H. Petersson, A. Nezirovic, M. B. Guldogan, ve F. Gustafsson, “Millimeter-wave radar micro-Doppler signatures of human motion”, içinde *Radar Symposium (IRS), 2011 Proceedings International*, 2011, ss. 167–174.
- [11] D. Tahmouh ve J. Silvius, “Modeled gait variations in human micro-doppler”, içinde *Radar Symposium (IRS), 2010 11th International*, 2010, ss. 1–4.
- [12] M. B. Guldogan, F. Gustafsson, U. Orguner, S. Bjorklund, H. Petersson, ve A. Nezirovic, “Radar micro-Doppler parameter estimation of human motion using particle filters”, içinde *2011 IEEE 19th Conference on Signal Processing and Communications Applications (SIU)*, 2011, ss. 395–398.
- [13] P. Setlur, M. Amin, ve F. Ahmad, “Urban target classifications using time-frequency micro-Doppler signatures”, içinde *9th International Symposium on Signal Processing and Its Applications, 2007. ISSPA 2007*, 2007, ss. 1–4.
- [14] J. Lei ve C. Lu, “Target classification based on micro-Doppler signatures”, içinde *Radar Conference, 2005 IEEE International*, 2005, ss. 179–183.

- [15] Y. Tian, C. Ning, ve X. Zhang, “Characteristic Study of Target Micro-motion Based on the Wavelet Analysis”, içinde *Green Computing and Communications (GreenCom), 2013 IEEE and Internet of Things (iThings/CPSCom), IEEE International Conference on and IEEE Cyber, Physical and Social Computing*, 2013, ss. 1571–1575.
- [16] J. Bryan ve Y. Kim, “Classification of human activities on UWB radar using a support vector machine”, içinde *2010 IEEE Antennas and Propagation Society International Symposium (APSURSI)*, 2010, ss. 1–4.
- [17] J. L. Geisheimer, E. F. Greneker III, ve W. S. Marshall, “High-resolution Doppler model of the human gait”, 2002, c. 4744, ss. 8–18.
- [18] P. van Dorp ve F. C. A. Groen, “Human walking estimation with radar”, *Radar Sonar Navig. IEE Proc. -*, c. 150, sayı 5, ss. 356–365, Eki. 2003.
- [19] B. Eroi, C. Karabacak, S. Z. Gurbuz, ve A. C. Gurbuz, “Radar simulation of different human activities via Kinect”, içinde *Signal Processing and Communications Applications Conference (SIU), 2014 22nd*, 2014, ss. 1015–1018.
- [20] I. Bilik ve J. Tabrikian, “Radar target classification using doppler signatures of human locomotion models”, *IEEE Trans. Aerosp. Electron. Syst.*, c. 43, sayı 4, ss. 1510–1522, Eki. 2007.
- [21] P. Molchanov, J. Astola, K. Egiazarian, ve A. Totsky, “Ground moving target classification by using DCT coefficients extracted from micro-Doppler radar signatures and artificial neuron network”, içinde *Microwaves, Radar and Remote Sensing Symposium (MRRS), 2011*, 2011, ss. 173–176.
- [22] P. Molchanov, J. Astola, K. Egiazarian, ve A. Totsky, “Classification of ground moving radar targets by using joint time-frequency analysis”, içinde *2012 IEEE Radar Conference (RADAR)*, 2012, ss. 0366–0371.
- [23] M. Otero, “Application of a continuous wave radar for human gait recognition”, sunulan *Signal Processing, Sensor Fusion, and Target Recognition XIV*, 2005, c. 5809, ss. 538–548.
- [24] Chen, Tahmoush, ve Miceli, “Micro-Doppler Signatures - Review, Challenges, and Perspectives”, içinde *Radar Micro-Doppler Signatures: Processing and Applications*, Miceli, Chen, ve Tahmoush, Ed. Institution of Engineering and Technology, 2014, ss. 1–25.
- [25] D. Tahmoush ve J. Silvius, “Radar micro-doppler for long range front-view gait recognition”, içinde *IEEE 3rd International Conference on Biometrics: Theory, Applications, and Systems, 2009. BTAS '09*, 2009, ss. 1–6.
- [26] Z. Zhang, P. Pouliquen, A. Waxman, ve A. G. Andreou, “Acoustic Micro-Doppler Gait Signatures of Humans and Animals”, içinde *41st Annual Conference on Information Sciences and Systems, 2007. CISS '07*, 2007, ss. 627–630.
- [27] S. Bjorklund, T. Johansson, ve H. Petersson, “Evaluation of a micro-Doppler classification method on mm-wave data”, içinde *2012 IEEE Radar Conference (RADAR)*, 2012, ss. 0934–0939.
- [28] A. W. Miller, C. Clemente, A. Robinson, D. Greig, A. M. Kinghorn, ve J. J. Soraghan, “Micro-Doppler based target classification using multi-feature integration”, içinde *IET Intelligent Signal Processing Conference 2013 (ISP 2013)*, 2013, ss. 1–6.

- [29] L. Pallotta, C. Clemente, A. De Maio, J. J. Soraghan, ve A. Farina, “Pseudo-Zernike moments based radar micro-Doppler classification”, içinde *2014 IEEE Radar Conference*, 2014, ss. 0850–0854.
- [30] L. Liu, M. Popescu, M. Skubic, M. Rantz, T. Yardibi, ve P. Cuddihy, “Automatic fall detection based on Doppler radar motion signature”, içinde *2011 5th International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth)*, 2011, ss. 222–225.
- [31] R. J. Javier ve Y. Kim, “Application of Linear Predictive Coding for Human Activity Classification Based on Micro-Doppler Signatures”, *IEEE Geosci. Remote Sens. Lett.*, c. 11, sayı 10, ss. 1831–1834, Eki. 2014.
- [32] B. G. Mobasseri ve M. G. Amin, “A time-frequency classifier for human gait recognition”, 2009, c. 7306, ss. 730628–730628–9.
- [33] J. Li, S. L. Phung, F. H. C. Tivive, ve A. Bouzerdoum, “Automatic classification of human motions using Doppler radar”, içinde *The 2012 International Joint Conference on Neural Networks (IJCNN)*, 2012, ss. 1–6.
- [34] B. Lyonnet, C. Ioana, ve M. G. Amin, “Human gait classification using microDoppler time-frequency signal representations”, içinde *2010 IEEE Radar Conference*, 2010, ss. 915–919.
- [35] G. Garreau, C. M. Andreou, A. G. Andreou, J. Georgiou, S. Dura-Bernal, T. Wennekers, ve S. Denham, “Gait-based person and gender recognition using micro-doppler signatures”, içinde *2011 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, 2011, ss. 444–447.
- [36] P. A. Eden, “The Search for Christian Doppler”, içinde *The Search for Christian Doppler*, Springer Vienna, 1992, ss. 1–4.
- [37] V. C. Chen, F. Li, S.-S. Ho, ve H. Wechsler, “Micro-Doppler effect in radar: phenomenon, model, and simulation study”, *IEEE Trans. Aerosp. Electron. Syst.*, c. 42, sayı 1, ss. 2–21, Oca. 2006.
- [38] C.-F. Chien ve L.-F. Chen, “Data mining to improve personnel selection and enhance human capital: A case study in high-technology industry”, *Expert Syst. Appl.*, c. 34, sayı 1, ss. 280–290, Oca. 2008.
- [39] E. Akçetin ve U. Çelik, “The Performance Benchmark of Decision Tree Algorithms for Spam e-mail Detection”, *J. Internet Appl. Manag.*, c. 5, sayı 2, ss. 43–56, 2014.
- [40] *Principal Component Analysis*. New York: Springer-Verlag, 2002.
- [41] Y. Saeys, I. Inza, ve P. Larrañaga, “A review of feature selection techniques in bioinformatics”, *Bioinforma. Oxf. Engl.*, c. 23, sayı 19, ss. 2507–2517, Eki. 2007.
- [42] S. S. Ram, Y. Li, A. Lin, ve H. Ling, “Doppler-based detection and tracking of humans in indoor environments”, *J. Frankl. Inst.*, c. 345, sayı 6, ss. 679–699, Eyl. 2008.
- [43] G. E. Smith, K. Woodbridge, C. J. Baker, ve H. Griffiths, “Multistatic micro-Doppler radar signatures of personnel targets”, *IET Signal Process.*, c. 4, sayı 3, ss. 224–233, Haz. 2010.
- [44] L. N. Traian Dogaru, “Computer Models of the Human Body Signature for Sensing Through the Wall Radar Applications.”

- [45] R. Boulic, N. M. Thalmann, ve D. Thalmann, “A global human walking model with real-time kinematic personification”, *Vis. Comput.*, c. 6, sayı 6, ss. 344–358, Kas. 1990.
- [46] S. Z. Gürbüz, W. L. Melvin, ve D. B. Williams, “Spectrogram-Based Methods for Human Identification in Single-Channel SAR Data”, içinde *Signal Processing and Communications Applications, 2007. SIU 2007. IEEE 15th*, 2007, ss. 1–4.
- [47] S. S. Ram ve H. Ling, “Simulation of human microDopplers using computer animation data”, içinde *IEEE Radar Conference, 2008. RADAR '08*, 2008, ss. 1–6.
- [48] C. Karabacak, S. Z. Gurbuz, ve A. C. Gurbuz, “Radar simulation of human micro-Doppler signature from video motion capture data”, içinde *Signal Processing and Communications Applications Conference (SIU), 2013 21st*, 2013, ss. 1–4.
- [49] A. V. Oppenheim ve R. W. Schafer, “From frequency to quefrequency: a history of the cepstrum”, *IEEE Signal Process. Mag.*, c. 21, sayı 5, ss. 95–106, Eyl. 2004.
- [50] M. S. Andric, D. M. Bujakovic, B. P. Bondzulich, ve B. M. Zrnic, “Cepstrum-based analysis of radar Doppler signals”, içinde *2011 10th International Conference on Telecommunication in Modern Satellite Cable and Broadcasting Services (TELSIKS)*, 2011, c. 2, ss. 575–578.
- [51] D. A. Reynolds, “An overview of automatic speaker recognition technology”, içinde *2002 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, 2002, c. 4, ss. IV–4072–IV–4075.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : EROL Barış
Uyruğu : Türkiye
Doğum tarihi ve yeri : 01.12.1990 İran/Tahran
Medeni hali : Bekar
Telefon : 05549887832
e-mail : bariserol1990@gmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	TOBB ETÜ/Elektrik-Elektronik Müh.	2014
Yüksek Lisans	TOBB ETÜ/Elektrik-Elektronik Müh.	2015

İş Deneyimi

Yıl	Yer	Görev
2014	TOBB ETÜ	Proje Bursiyeri (TÜBİTAK)
2014	TOBB ETÜ	Burslu Yüksek Lisans Öğrencisi

Yabancı Dil

İngilizce
Almanca

Yayınlar

Dergi Yayınları

1. **Erol, B.;** Gurbuz, S.Z., "A kinect-based human micro-doppler simulator," *Aerospace and Electronic Systems Magazine, IEEE* , vol.30, no.5, pp.6,17, May 2015
2. Gurbuz S. Z., **Erol B.**, Cagliyan B., Tekeli B., "Operational Assessment and Adaptive Feature Selection of Micro-Doppler Features", *IET Radar, Sonar & Navigation (Accepted with Major Revision)*.

Konferans Bildirileri

1. **Erol, B.;** Cagliyan, B.; Tekeli, B.; Gurbuz, S.Z., "Data-dependent micro-Doppler feature selection," *Signal Processing and Communications Applications Conference (SIU), 2015 23th* , vol., no., pp.1566,1569, 16-19 May 2015.
2. **Erol, B.;** Karabacak, C.; Gurbuz, S.Z.; Gurbuz, A.C., "Simulation of human micro-Doppler signatures with Kinect sensor," *Radar Conference, 2014 IEEE* , vol., no., pp.0863,0868, 19-23 May 2014

3. **Erol, B.;** Karabacak, C.; Gurbuz, S.Z.; Gurbuz, A.C., "Radar simulation of different human activities via Kinect," *Signal Processing and Communications Applications Conference (SIU), 2014 22nd* , vol., no., pp.1015,1018, 23-25 April 2014
4. **Erol, B.;** "Linear Predictive Coding Model for Speech Signals", Audio Technologies for Music and Media 3rd International Conference, Ankara, Turkey, 12 November 2014.