

**GÜRÜLTÜLÜ DURUMLAR İÇİN RADAR MİKRO-DOPPLER  
SINIFLANDIRMA BAŞARIMININ İYİLEŞTİRİLMESİ**

**CESUR KARABACAK**

**YÜKSEK LİSANS TEZİ**

**ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ**

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ**

**FEN BİLİMLERİ ENSTİTÜSÜ**

**NİSAN 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

Cesur KARABACAK tarafından hazırlanan GÜRÜLTÜLÜ DURUMLAR İÇİN RADAR MİKRO-DOPPLER SINIFLANDIRMA BAŞARIMININ İYİLEŞTİRİLMESİ adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

---

Yrd. Doç. Dr. Sevgi Zübeyde GÜRBÜZ

Tez Danışmanı

Tez Jüri Üyeleri

Başkan : Doç. Dr. Ali Cafer GÜRBÜZ

Üye : Yrd. Doç. Dr. Sevgi Zübeyde GÜRBÜZ

Üye : Yrd. Doç. Dr. Mehmet Burak GÜLDOĞAN

## **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.

Cesur KARABACAK

**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 – Nisan 2015

**Cesur KARABACAK**

## **GÜRÜLTÜLÜ DURUMLAR İÇİN RADAR MİKRO-DOPPLER SINIFLANDIRMA BAŞARIMININ İYİLEŞTİRİLMESİ**

### **ÖZET**

Farklı hedef tipleri veya aynı hedefin farklı hareketleri için radar mikro-Doppler sinyalleri birbirinden farklı olmaktadır. Bu durum, radar mikro-Doppler sinyallerinin hedef sınıflandırması için kaynak olarak kullanılması fikrini doğurmuştur. Son 10 yılda mikro-Doppler tabanlı birçok sınıflandırma çalışması yayınlanmıştır. Bu çalışmalar, deneysel radar verileri kullanılarak yapıldığında genellikle yakın mesafelerden ve parazit yansımanın önemsiz olduğu durumlar için gerçekleştirilmektedir. Benzetim çalışmalarında da gürültü ve parazit yansıma etkileri çoğu zaman ihmal edilmektedir. Sınıflandırma başarımının gürültü ve parazit yansıma etkilerinin ihmal edildiği ideal durumlar için ölçülmesi, yapılan çalışmanın sonuçlarını gerçeklikten uzaklaştırmaktadır. Bu çalışmada, benzetim verileri kullanılarak mikro-Doppler imzaları üzerinden bir sınıflandırma çalışması gerçekleştirilmiştir. Hedeflere ait radar benzetim verileri oluşturulurken gürültü ve parazit yansıma etkileri de modellenmiştir. Gürültü ve parazit yansımaları verilerle elde edilen sınıflandırma başarımı, gürültüsüz durumda elde edilen ile karşılaştırılmıştır. Ayrıca, gürültülü durumda görüntü işleme teknikleri kullanılarak başarımı artırmak için bir yöntem önerilmiştir. Sonuçlar iki farklı sınıflandırıcı ile denenmiş ve önerilen yöntemin sınıflandırma başarımında %5 ile %15 arasında bir artış sağladığı görülmüştür.

**Anahtar Kelimeler:** Radar, Mikro-Doppler, Radar Hedef 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. – April 2015

**Cesur KARABACAK**

**ENHANCEMENT of RADAR MICRO-DOPPLER CLASSIFICATION  
PERFORMANCE IN NOISY CONDITIONS**

**ABSTRACT**

Micro-Doppler radar signals for different target types or different movements of a target are also different from each other. This leads to usage of micro-Doppler radar signals as a source of classifying targets. Many micro-Doppler based target classification studies have been published in the last ten years. The studies which are done using experimental radar data are usually carried out in situations where target is close to the radar and clutter effect is minimal. In simulation studies, noise and clutter effects are also ignored. Measurement of classification performance for idealistic conditions in which noise and clutter effects are not taken into account makes the outcomes of the study doubtful. In this thesis, a classification study of micro-Doppler based target signatures is carried out using simulation data. While generating radar simulation data of targets, noise and clutter effects are also modeled. Classification performance obtained from the data containing noise and clutter is compared to noise free data. In addition, a method is proposed to increase the performance in noisy situations using image processing techniques. The results are obtained with two different classifiers and the proposed method has made an increase from 5% to 15% in the classification performance.

**Keywords:** Radar, Micro-Doppler, Radar Target Classification

## TEŐEKKÜR

Çalıřmalarım boyunca tecrübelerini açık yüreklikle benimle paylaşan ve beni doğru yöne yönlendiren tez danışmanım Yrd. Doç. Dr. Sevgi Zübeyde GÜRBÜZ'e,

Yaşadığım sorunların ve cevaplandıramadığım soruların çözülmesinde hiçbir zaman yardımını esirgemeyen hocam Doç. Dr. Ali Cafer GÜRBÜZ'e,

Hayatım boyunca beni destekleyen aileme,

Yüksek lisans yaptığım süre boyunca birçok konuda yardımlarını esirgemeyen niřanlım Yasemin ŐAHİN'e,

Beraber çalışma şansına eriřtiğim hocam Mehmet Burak GÜLDOĞAN, arkadaşlarım Bürkan TEKELİ, Bahri ÇAĞLIYAN ve Barış EROL'a,

Bu günlere gelmemde büyük emekleri olduğuna gönülden inandığım TOBB Ekonomi ve Teknoloji Üniversitesi Elektrik-Elektronik Mühendisliđi ve Bilgisayar Mühendisliđi öğretim üyelerine,

Yüksek lisansa devam ettiğim süre boyunca BİDEB Bursu ile bana destek olan TÜBİTAK'a ve sağladığı Arařtırma Bursu için TOBB Ekonomi ve Teknoloji Üniversitesi'ne,

teőekkürü bir borç bilirim.

Bu çalışma, "Radar ile İnsan Sezimi, Tanıma ve Sınıflandırma" adlı 113E105 no.lu TÜBİTAK projesi ve Meteksan Savunma Sanayii A.Ő. tarafından desteklenmiştir.

# İÇİNDEKİLER

	Sayfa
TEZ BİLDİRİMİ .....	iii
ÖZET .....	iv
ABSTRACT .....	v
TEŞEKKÜR .....	vi
İÇİNDEKİLER .....	vii
ÇİZELGELERİN LİSTESİ .....	ix
ŞEKİLLERİN LİSTESİ .....	x
KISALTMALAR .....	xii
SEMBOL LİSTESİ .....	xiii
1. GİRİŞ .....	1
1.1 Motivasyon .....	1
1.2 Mikro-Doppler Etkisi .....	2
1.3 Literatür Araştırması .....	3
1.4 Tez Kapsamı .....	6
1.5 Organizasyon.....	7
2. HEDEF HAREKETLERİNİN RADAR BENZETİMİ .....	8
2.1 Hedef Hareketlerinin Modellenmesi .....	8
2.2 Radar Benzetim Çalışmaları .....	13
2.3 Hedef Veri Tabanının Oluşturulması .....	18
3. ÖZİNİTELİK ÇIKARMA ÇALIŞMALARI .....	29
4. ÖZİNİTELİK SEÇME ve SINIFLANDIRMA .....	42
4.1 Hedefin Doğrudan Radara Doğru Hareket Ettiği Durum İçin Sınıflandırma... 45	
4.1.1 Gürültü ve Parazit Yansıma Etkileri İhmal Edildiğinde Sınıflandırma 45	
4.1.2 Gürültü ve Parazit Yansıma Etkileri İhmal Edilmediğinde Sınıflandırma.....	50
4.2 Hedefin Radara Açılı Hareket Ettiği Durum İçin Sınıflandırma.....	53
4.2.1 Gürültü ve Parazit Yansıma Etkileri İhmal Edildiğinde Sınıflandırma 53	
4.2.2 Gürültü ve Parazit Yansıma Etkileri İhmal Edilmediğinde Sınıflandırma.....	56
4.3 Sınıflandırma Sonuçlarına Genel Bakış.....	57

5. SONUÇ .....	60
5.1 Yorumlar .....	60
5.2 Gelecek Çalışmalar .....	61
KAYNAKLAR .....	62
ÖZGEÇMİŞ .....	65



## ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1 Benzetim veri tabanındaki verilerin hedef tiplerine göre dağılımı .....	20
Çizelge 2.2 Farklı arazi tipleri için katsayı değerleri [40] .....	25
Çizelge 3.1 Çıkarılan özneliklerin listesi .....	40
Çizelge 4.1 En yüksek başarımın elde edildiği 6 öznelik (2, 10, 15, 19, 21 ve 22) ile En Yakın 3 Komşu sınıflandırıcısı kullanıldığında oluşan karışıklık matrisi .....	47
Çizelge 4.2 En yüksek başarımın elde edildiği 6 öznelik (3, 5, 8, 18, 22 ve 22) ile Sınıflandırma Ağacı sınıflandırıcısı kullanıldığında oluşan karışıklık matrisi .....	49
Çizelge 4.3 Açılı yürüme durumları da benzetime dâhil edildiğinde En Yakın 3 Komşu sınıflandırıcısı ile elde edilen maksimum performansa ait karışıklık matrisi .....	55
Çizelge 4.4 Açılı yürüme durumları da benzetime dâhil edildiğinde Sınıflandırma Ağacı sınıflandırıcısı ile elde edilen maksimum performansa ait karışıklık matrisi .....	56
Çizelge 4.5 Bu bölümde elde edilen sınıflandırma sonuçları .....	58

## ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1	Boulic Yürüme Modeli'nde kullanılan 17 hareket noktasının gösterimi 9
Şekil 2.2	İşaretçiler bağlanarak hareket yakalama sistemi ile veri kaydı yapılacak olan deneğin görüntüsü [36] ..... 10
Şekil 2.3	CMÜ verilerinden edilen veriler ve Boulic Modeli'nden elde edilen verilerin karşılaştırılması [33]..... 12
Şekil 2.4	Örnek bir hareket yakalama verisinden üretilen animasyonun farklı anlardaki kesitlerinin birleştirilmesi ile oluşturulmuş görüntü [33] ..... 13
Şekil 2.5	Dördül sezici (quadrature detector) ile Doppler kaymasının çıkarılması [1] ..... 14
Şekil 2.6	Hareket yakalama verileri kullanılarak elde edilen yürüyen insan spektrogramı üzerinde vücut parçalarının oluşturduğu imzaların gösterilmesi..... 17
Şekil 2.7	Yürüme, emekleme ve tekrar yürüme hareketlerinin radar benzetimi sonucu oluşan spektrogram [33] ..... 18
Şekil 2.8	(a) Yürüme hareketine ait animasyon görüntüsü (b) Yürüme hareketine ait spektrogram ..... 21
Şekil 2.9	(a) Koşma hareketine ait animasyon görüntüsü (b) Koşma hareketine ait spektrogram ..... 21
Şekil 2.10	(a) Emekleme hareketine ait animasyon görüntüsü (b) Emekleme hareketine ait spektrogram..... 22
Şekil 2.11	(a) Sürünme hareketine ait animasyon görüntüsü (b) Sürünme hareketine ait spektrogram ..... 22
Şekil 2.12	(a) Yan yana iki insan yürümesi hareketine ait animasyon görüntüsü (b) Yan yana iki insan yürümesi hareketine ait spektrogram ..... 23
Şekil 2.13	(a) Yan yana iki insan koşması hareketine ait animasyon görüntüsü (b) Yan yana iki insan koşması hareketine ait spektrogram..... 23
Şekil 2.14	(a) Araç hareketine ait animasyon görüntüsü (b) Araç hareketine ait spektrogram ..... 24
Şekil 2.15	Sıyırma açısının gösterimi ..... 25
Şekil 2.16	Örnek parazit yansıma spektrogramı ..... 27

Şekil 2.17	Parazit yansımalarının olduğu ortamda insan yürüme spektrogramı....	27
Şekil 2.18	Parazit yansıma içeren ve 24 dB SGO değerine sahip insan yürüme spektrogramı .....	28
Şekil 2.19	Bölümde yapılan çalışmaların özeti.....	28
Şekil 3.1	Sınıflandırma algoritmalarının genel yapısı.....	30
Şekil 3.2	(a) Alt uydurma (b) İdeal uydurma (c) Aşırı uydurma [43].....	30
Şekil 3.3	Parazit yansıma bastırma sonrası elde edilen spektrogram.....	32
Şekil 3.4	Yeniden ölçeklendirme işlemi sonucunda oluşan spektrogram.....	33
Şekil 3.5	(a) Doppler belirsizliği içeren insan koşması spektrogramı (b) Doppler belirsizliği çözümlenmiş spektrogram .....	34
Şekil 3.6	Görüntü histogramı üzerinde eşik değeri, nesne bölgesi ve arka bölgesinin temsili olarak gösterilmesi [44] .....	35
Şekil 3.7	(a) Eş veri eşikleme algoritmasına girdi olarak verilen spektrogram (b) Eş veri eşikleme algoritmasının çıktısı .....	36
Şekil 3.8	Gürültü temizleme işleminin ardından elde edilen spektrogram .....	36
Şekil 3.9	Spektrogram üzerinden çıkarılan zarfların gösterilmesi .....	38
Şekil 3.10	Parazit yansıma bastırma ve gürültü temizleme ön işleme aşamaları uygulanmadığında çıkarılan zarflar .....	39
Şekil 3.11	Bu bölümde yapılan çalışmaların özeti.....	41
Şekil 4.1	Ardışık İleri Yönlü Kayan Öznitelik Seçimi algoritmasının sözde kodu [48].....	43
Şekil 4.2	Süzgeç Metodu ile öznitelik seçme işlemi [50] .....	44
Şekil 4.3	Sargı Metodu ile öznitelik seçme işlemi [50] .....	44
Şekil 4.4	15 ve 19 numaralı özniteliklerin sınıflara göre dağılımı.....	46
Şekil 4.5	15 ve 23 numaralı özniteliklerin sınıflara göre dağılımı.....	48
Şekil 4.6	Farklı öznitelik sayıları ile elde edilen en iyi sınıflandırma başarımlarının grafiği.....	50
Şekil 4.7	(a) 34 dB SGO (b) 24 dB SGO (c) 14 dB SGO (d) 4 dB SGO için aynı verinin spektrogramı .....	51
Şekil 4.8	Görüş açısının gösterimi .....	53
Şekil 4.9	İnsan yürüme hareketinin radara göre açısı (a) 0° (b) 30° (c) 60° (d) 90° olduğunda elde edilen spektrogramları.....	54
Şekil 4.10	Bu bölümde yapılan çalışmaların özeti.....	59

## KISALTMALAR

### Kısaltmalar Açıklama

<b>AKD</b>	Ayrık Kosinüs Dönüşümü
<b>BZFA</b>	Birleşik Zaman-Frekans Analizi
<b>CMÜ</b>	Carnegie Mellon Üniversitesi
<b>EBGG</b>	Eklenebilir Beyaz Gauss Gürültüsü
<b>FD</b>	Fourier Dönüşümü
<b>KZFD</b>	Kısa Zaman Fourier Dönüşümü
<b>RF</b>	Radyo Frekansı
<b>RKA</b>	Radar Kesit Alanı
<b>SGO</b>	Sinyal Gürültü Oranı

## SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

<b>Simgeler</b>	<b>Açıklama</b>
$a$	Hedeften dönen sinyalin genliği
$c$	Işık hızı
$f_0$	Taşıyıcı frekansı
$f_{doppler}$	Doppler kayması
$G$	Anten kazancı
$L$	Atmosferik ve sistemden kaynaklı kayıplar
$P$	Radar çıkış gücü
$R$	Menzil
$S_{gürültü}$	Gürültü sinyali
$S_{ham}$	Ham radar verisi
$S_{insan}$	İnsandan elde edilen sinyal
$S_{parazit}$	Parazit yansımadan dönen sinyal
$S(m, \omega)$	Spektrogram
$t$	Zaman
$v$	Radyal hız
$w$	Pencere fonksiyonu (Blackman, Hamming vb.)
$X(m, \omega)$	KZFD uygulanmış sinyal
$\lambda$	Dalga boyu
$\sigma$	Radar kesit alanı (RKA)
$\sigma^{\circ}$	Metrekareye düşen RKA
$\sigma_{elipsoid}$	Elipsoidin RKA'sı
$\sigma_{küre}$	Kürenin RKA'sı
$\sigma_{parazit}$	Parazit yansımının RKA'sı
$\psi$	Sıyırma açısı
$\omega$	Açısal frekans

# 1. GİRİŞ

## 1.1 Motivasyon

Kaçakçılık, yasadışı göç ve terör saldırıları gibi faaliyetlerin önlenmesi için ülkelerin güvenlik birimleri, çevre, alan ve sınır güvenliği sistemlerine büyük yatırımlar yapmaktadır. Bu sistemlerin kazanılmasındaki temel amaç, tehdit kritik önemdeki noktalara ulaşmadan tespit edilerek gerekli önlemlerin en hızlı ve en erken biçimde alınmasının sağlanmasıdır. Günümüzde çevre, alan ve sınır koruması amacıyla oluşturulan güvenlik sistemlerinde optik, akustik, kızılötesi ve radyo frekansı (RF) gibi farklı algılayıcılar birlikte kullanılarak her bir algılayıcının güçlü olduğu özelliklerinden faydalanılmakta ve farklı algılayıcılardan gelen bilgilerin birleştirilmesi ile tehdit hakkında en doğru bilginin elde edilmesi sağlanmaktadır.

Optik ve kızılötesi algılayıcılar, ucuz olmaları ve çıktı olarak sundukları görüntülerin insan tarafından kolayca yorumlanabilmesi nedeniyle güvenlik sistemlerinde yoğun olarak kullanılmaktadır. Fakat optik algılayıcıların hava durumuna göre performanslarında yaşanan ciddi kayıplar ve hedefi konumlandırmadaki başarısızlıkları bu işlemleri başarı ile gerçekleştiren farklı bir algılayıcının kullanılmasını zorunlu hale getirmektedir. Aktif bir RF algılayıcısı olan radar, hedefin konumlandırılmasındaki başarısı, yağmur ve sis gibi kötü hava koşullarında dahi kayda değer bir performans sergilemesi ve gün ışığından bağımsız olarak çalışabilmesi sebebiyle son yıllarda güvenlik sistemlerinin önemli bir bileşeni haline gelmiştir.

Çevre ve alan güvenlik sistemlerinin en önemli sorunlarından biri, arazide tespit edilen hedefin saldırı için hazırlık yapan bir insan mı yoksa başıboş gezen bir hayvan mı olduğunun belirlenmesidir. Güvenlik için tehlike arz etmeyecek olan hayvanlar için yanlış alarm verilmesi iş gücü ve zaman kaybına neden olabilirken, emekleyerek yaklaşmakta olan bir saldırganın hayvan zannedilip göz ardı edilmesi can ve mal güvenliği için önemli sorunlar yaratabilmektedir. Bu nedenle, insanın diğer hedeflerden ayrılabilmesi için günümüzde yoğun çabalar sarf edilmektedir.

## 1.2 Mikro-Doppler Etkisi

Radar, gözlem yapılan bölgeye elektromanyetik dalga gönderdikten sonra hedefe çarpıp geri dönen dalganın üzerinde çeşitli sinyal işleme tekniklerini kullanarak hedef ile ilgili bilgiler sağlamaktadır. Örneğin, dalganın gönderilmesi ve alınması için geçen süre  $t$  ile, ışık hızı  $c$  ile ifade edilirse hedefin radara olan uzaklığı,

$$R = \frac{ct}{2} \quad (1.1)$$

formülü ile hesaplanabilmektedir. Eğer hedef hareket hâlindeyse Doppler etkisinden dolayı, hedeften alınan dalganın frekansında, gönderilen dalganın frekansına göre kaymalar oluşmaktadır. Bu frekans kayması miktarı,

$$f_{doppler} = \pm f_0 \frac{2v}{c} \quad (1.2)$$

formülü ile hesaplanabilmektedir. Burada  $f_{doppler}$  elektromanyetik dalganın taşıyıcı frekansında oluşan Doppler kaymasının miktarını,  $f_0$  elektromanyetik dalganın taşıyıcı frekansını ve  $v$  hedefin radara göre olan radyal hızını temsil etmektedir. Şayet hedef radardan uzaklaşıyorsa Doppler kaymasının değeri pozitif, hedef radara yaklaşıyorsa Doppler kaymasının değeri negatiftir.

Bazı durumlarda radarın incelemekte olduğu hedef, öteleme hareketine ek olarak dönme, titreme gibi hareketler yapmakta ya da bu hareketleri yapan kısımlara sahip olabilmektedir. Eğer hedefte bu tip hareketler yapan parçalar varsa, hedeften alınan sinyalde Doppler frekans kaymasının yanında bu hareketlerden kaynaklanan ek frekans kiplenmeleri de görülür. Öteleme hareketine ek olarak var olan bu mikro hareketlerin, radar sinyali üzerinde oluşturduğu etkiye mikro-Doppler etkisi [1-3] denilmektedir. Örneğin, helikopterin dönen pervaneleri, ilerleyen bir aracın motor titreşimleri, yürüyen bir insanın kollarının ve bacaklarının yaptığı salınımlar radara dönen sinyalde mikro-Doppler etkisi oluşturmaktadır. Mikro-Doppler etkisi, hedefin öteleme hareketinden kaynaklı oluşan Doppler kaymasına ek olarak, hedefin farklı bileşenlerinin oluşturduğu Doppler kaymalarının da görülebilmesini sağladığı için hedefin hareketine bağlı olarak adeta bir imza niteliği taşımaktadır.

### 1.3 Literatür Araştırması

Radar sinyalinde oluşan mikro-Doppler etkisinin hedef hareketi için bir imza olarak görülebileceği teorisinden yola çıkılarak son yıllarda farklı hedeflerin ve aynı hedefin farklı hareketlerinin mikro-Doppler imzaları kullanılarak birbirinden otomatik olarak ayrılması üzerine literatürde birçok çalışma sunulmuştur [1-31]. Literatürdeki çalışmaların büyük çoğunluğu radar sinyalindeki mikro-Doppler etkisini analiz etmek için sinyalin üzerinde birleşik zaman-frekans analizi (BZFA) işlemleri uygulamaktadır. Gabor filtresi [1,3], Kısa Zaman Fourier Dönüşümü (KZFD) [1-6, 20] ve Wigner-Ville dağılımı [1] gibi farklı BZFD tekniklerinin kullanımına rastlansa da literatürde en sık kullanılan yöntemin KZFD olduğu görülmüştür. BZFA kullanmayıp doğrudan radar ham verisi üzerinden hedef sınıflandırması yapılan çalışmalara da literatürde rastlanmakla birlikte, bu çalışmaların sayısı daha azdır [5, 7, 11, 13].

Literatürdeki mikro-Doppler imzalarını kullanarak yapılan sınıflandırma çalışmaları incelendiğinde sınıflandırma işleminin insanın farklı hareketleri (yürüme, koşma, emekleme, sürünme, yüzme vb.) [3-6, 8-9, 12, 21-23, 26-28, 30], insan grubu [7, 10-11, 13, 18, 30], helikopter [3, 19], rüzgâr değirmeni [3], hayvan [17-18], otomobil [13-16, 18, 24-25, 30-31] ve paletli araç [14-16, 18] gibi farklı tip hedefler üzerinden gerçekleştirildiği görülmektedir. Literatürdeki çalışmaların çoğunluğunun insanın farklı hareketlerinin sınıflandırılması üzerine yoğunlaştığı görülmektedir. Bunun temel nedenleri, insanın küçük bir hedef olmasından dolayı çevre güvenlik sistemlerinde tespit edilmesinin zor olması ve bu konunun son yıllarda önemli bir araştırma alanı haline gelmesi, insanın nasıl hareket ettiğinin insanın niyeti hakkında önemli bir bilgi sunuyor olması ve insanları kullanarak kontrollü veri toplamanın diğer hedeflere nazaran çok daha kolay olmasıdır. Ayrıca, farklı insan hareketlerinin dahi radar verileri kullanılarak yüksek oranda ayrıştırılabildiğinin gösterilmesi, farklı hedef tiplerinin de rahatlıkla ayrıştırılabileceği konusunda bir ön bilgi sunmaktadır.

Mikro-Doppler imzalarını kullanarak hedef sınıflandırma sorununa literatürde önerilen çalışmalar, hedef tipleri, kullanılan veri seti, kullanılan öznitelik seti, kullanılan sınıflandırıcı tipi ve değerlendirme yapılan veri uzunluğu gibi birçok farklı noktada ayrılmaktadır. Bu nedenle bu çalışmaları birbiriyle karşılaştırıp en iyi



yöntemin seçilmesi mümkün olmamaktadır. [4] nolu çalışmada Kim ve Ling, 3 saniye süreli spektrogramlar üzerinde insanın koşma, yürüme, kol sallamadan yürüme, emekleme, boks, ileriye doğru hareket ederken boks ve sabit oturma hareketlerini incelemişlerdir. Toplamda 1008 tane olmak üzere 12 farklı insandan bu hareketler için veri toplama çalışması yürütmüşlerdir. Bu hareketlere ait spektrogramlar üzerinden gövdenin Doppler frekansı, Doppler sinyalinin toplam bant aralığı, toplam Doppler'in frekansta ötelemesi, mikro-Doppler olmadan spektrogramın bant aralığı, Doppler sinyal gücünün birimlenmiş standart sapması, ve ayak ve kol hareketlerinin dönemi olmak üzere toplam 6 öznitelik çıkarmışlardır. Yapay Sinir Ağları kullanarak yaptıkları sınıflandırma çalışmasında %82,7 doğru sınıflandırma başarımı elde etmişlerdir. Elde edilen başarımların değeri, sadece radara doğru yapılan hareketler içindir.

Literatürdeki bir diğer çalışma olan [5]'de ise hareket eden bir insan, hareket eden iki insan, hareket eden 3 insan ve çevresel yansıma hedefleri üzerinden sınıflandırma çalışması yapılmıştır. Öznitelik olarak Ayrık Kosinüs Dönüşümü (AKD) katsayıları kullanılmıştır. Sınıflandırıcı olarak Çok Katmanlı Algılayıcı (Multilayer Perceptron) kullanılmış ve 11 parçalı çapraz geçişleme uygulanmıştır. Veri uzunluğunun 128 ms, 256 ms, 512 ms, 1 s ve 2 s olduğu durumlar için algoritma denenmiş ve sırasıyla %63, %70, %76, %81 ve %86 doğru sınıflandırma başarımı elde edilmiştir. Bu çalışmada da elde edilen başarımların değeri sadece radara doğru yapılan hareketler içindir.

[11] nolu çalışmada ise 9 GHz frekansında çalışan düşük çözünürlüklü bir kara gözetleme radarı ile bir insan, iki insan, üç insan, paletli araç, tekerlekli araç, hayvan ve çevresel yansıma hedeflerine ait veriler 4 saniye uzunluğundaki veriler toplanarak bir veritabanı oluşturulmuştur. Öznitelik olarak Uyarlamalı Öngörücü Kodlama (Linear Prediction Coding) ve Cepstrum katsayıları kullanılmıştır. Sınıflandırıcı olarak Gauss Karışım Modeli'nin en büyük olasılık (maximum likelihood) ve çoğunluk seçimi (majority voting) karar kurallarını uygulayan biçimleri kullanılmış ve sırasıyla %88 ve %96 doğru sınıflandırma başarımı elde edilmiştir. Bu çalışmanın bir diğer önemli noktası, benzer bir sınıflandırma çalışmasını deneyimli radar operatörlerine yaptırmanın denenmiş olmasıdır. 20 farklı radar operatörü veri tabanındaki verileri 12 saniyelik ses dosyaları halinde dinlediğinde ortalama %37

dođru sınıflandırma ulaşabilmiştir. Bu sonuç, sınıflandırma işlemi için bilgisayar kullanmanın radar operatörü kullanmaktan çok daha etkili olacağını açıkça göstermektedir.

[13] nolu çalışmada 9,72 GHz frekansında çalışan radar ile toplanan bir insan, iki insan, üç insan, kamyon, otomobil ve çevresel yansıma hedeflerine ait 10 saniyelik veriler üzerinden sınıflandırma işlemi gerçekleştirilmiştir. Öznitelik olarak Mel frekans katsayıları, Uyarlamalı Öngörücü Kodlama ve Cepstrum katsayıları kullanılmış ve sınıflandırıcı olarak karar aşamasında maksimum sonsal dağılım kullanan Gauss Karışım Modeli kullanılmıştır. Öznitelikler BZFD matrisleri üzerinden değil, radar ham verisi üzerinden çıkarılmıştır. Elde edilen dođru sınıflandırma başarımı %99,08'dir.

[16] nolu çalışmada araştırmacılar, Thales tarafından üretilen MSTAR radarı ile tekerlekli araç, peletli araç ve insan hedefleri için 100 ms uzunluğunda veri toplamışlardır. Öznitelik olarak Fourier Dönüşümü (FD) katsayılarının birimlenmiş logaritmasını çıkarmış ve bu veri uzayını küçültmek için üzerinde Temel Bileşen Analizi (Principal Component Analysis) uygulamışlardır. Sınıflandırıcı olarak ise Fisher Doğrusal Ayırıcı (Fisher Linear Discriminator) kullanmışlardır. Yapılan saha testlerinde %90 ve üstünde dođru sınıflandırma başarımı elde etmişlerdir.

[17] nolu çalışmada ise ultrasonik bir algılayıcı yardımıyla benzer bir çalışma yapılmıştır. İnsan, at ve çevresel yansıma hedeflerinden düşük ve yüksek Sinyal Gürültü Oranı (SGO) olan ortamlar için veriler toplanmıştır. Düşük SGO içeren verilerin sınıflandırması ile yüksek SGO içeren verilerin sınıflandırılması kendi içlerinde ayrı ayrı yapılmıştır. Düşük SGO verileri için frekans bantlarında toplanan enerji miktarı öznitelik olarak kullanılırken yüksek SGO verileri için hareket periyodu, ortalama Doppler değeri ve gecikme zamanı (lag time) öznitelikleri kullanılmıştır. Yüksek SGO verileri için kendi tasarladıkları bir karar ağacını sınıflandırıcı olarak kullanıp %100 dođru sınıflandırma başarımı elde etmişlerdir. Düşük SGO verileri için ise Çok Değişkenli Gauss Sınıflandırıcısı kullanarak %88,1 dođru sınıflandırma başarımı elde etmişlerdir.

[19] nolu çalışmada X bantta çalışan bir radar ile kuş, helikopter ve farklı tipte insansız hava araçlarının verileri toplanmıştır. Bu verilerin 0,5 saniyelik dilimleri sınıflandırma çalışmaları için kullanılmıştır. Eldeki verilerin ilk beş özvektörünün Fourier Dönüşümü ve ilk beş özdeğeri hesaplanarak öznitelik vektörleri oluşturulmuştur. Doğrusal Destek Vektör Makinesi (Linear Support Vector Machine), Doğrusal Olmayan Destek Vektör Makinesi (Nonlinear Support Vector Machine) ve Naive Bayes olmak üzere üç farklı sınıflandırıcı kullanılarak sırasıyla %94,91, %95,39 ve %93,6 doğru sınıflandırma başarımları elde edilmiştir.

Yukarıda özetlenen çalışmalar, farklı tip radar verileri üzerinden gerçekleştirildiği için aralarında kıyaslama yaparak en iyi çalışmayı seçmek mümkün değildir. Bazı çalışmalarda hedefin sadece radara doğru hareket ederken olan hareketleri dikkate alındığı için sınıflandırma başarımları oldukça iyidir. Birçok çalışma genellikle kısa mesafelerden veri toplanarak yapıldığı için hedef sinyali gürültü tabanının çok üstünde güç değerlerine ulaşmaktadır. Bu durum da sınıflandırma başarımlarında kayda değer artışlara neden olmaktadır. Literatürdeki çalışmalar genellikle birkaç öznitelik önererek bunlar üzerinden sınıflandırma çalışması yürütmektedir. Hangi öznitelik sınıflandırma için daha yüksek öneme sahip olduğu ya da hangi öznitelikler seçilirse daha iyi başarımlar elde edileceği üzerine geniş kapsamlı bir çalışma bulunmamaktadır.

#### **1.4 Tez Kapsamı**

Bu çalışmada mikro-Doppler tabanlı sınıflandırma işlemlerinin gerçekleştirilebilmesi için hareket yakalama verileri kullanılarak farklı insan hareketleri ve araç hareketi için geniş bir veritabanı oluşturulmuştur. 23 farklı öznitelik çıkarılarak 2 farklı sınıflandırıcı üzerinden sınıflandırma çalışmaları icra edilmiştir.

Literatürdeki pek çok çalışmada dikkate alınmayan hedefin radara açılı hareket durumları da göz önünde bulundurularak açılı hareket durumları için de sınıflandırma yapılmıştır. Yine literatürde genellikle ihmal edilen gürültü durumuna bağlı performans için incelemeler yapılmıştır. Gürültünün radar sinyali üzerindeki etkilerini görüntü işleme teknikleri kullanarak azaltmak için bir yöntem önerilmiş ve bu yöntemin sınıflandırıcı başarımlarına olan etkisi incelenmiştir. Literatürde ihmal

edilen bir diğerkonu olan öznitelik seçimi de tez kapsamında ele alınan bir diğerkonu önemli konudur.

## **1.5 Organizasyon**

Bu çalışma, toplam beş bölümden oluşmaktadır. Bölüm 2, tez kapsamında gerçekleştirilen hedef hareketlerinin radar benzetimi faaliyetlerinin literatürdeki benzer çalışmaları da dikkate alarak açıklandığı bölümdür. Bu bölümde, hedef hareketlerinin modellenmesi, radar benzetiminin gerçekleştirilmesi, gürültü ve parazit yansıma etkilerinin benzetime dâhil edilmesi ve verileri incelemek için BZFA tekniklerinin kullanılması konularına değinilmektedir. Ayrıca, bu çalışma kapsamında oluşturulan hedef veritabanı ayrıntılı olarak tanıtılmaktadır.

Bölüm 3, oluşturulan radar imzalarından öznitelik çıkarma hesaplamalarının nasıl yapıldığının anlatıldığı bölümdür. Öznitelik çıkarma öncesinde ön işleme yapılarak gürültü ve parazit yansımanın sınıflandırma başarımına olan etkisini azaltmak amacıyla geliştirilen metot tanıtılmıştır. Ayrıca, spektrogram üzerinden hareketi tanımlayan zarfların çıkarılması ve bu zarflar üzerinden özniteliklerin hesaplanması anlatılmıştır.

Bölüm 4, çıkarılan özniteliklerden daha yüksek sınıflandırma başarımı sunan öznitelik altkümesinin seçilmesi çalışmalarının ve elde edilen sınıflandırma sonuçlarının sunulduğu bölümdür. Hedefin radara doğru farklı açılarda hareket ettiği durumların ve gürültünün sınıflandırma başarımına etkisi irdelenmiştir. Ayrıca, Bölüm 3'de önerilen parazit yansıma bastırma ve gürültü temizleme tekniklerinin sınıflandırma başarımı üzerindeki etkisi de incelenmiştir.

Bölüm 5, tez çalışması kapsamında elde edilen sonuçların yorumlandığı ve çalışmayı ileri taşımak için gelecekte yapılabilecek faaliyetlerin belirtildiği bölümdür.

## 2. HEDEF HAREKETLERİNİN RADAR BENZETİMİ


### 2.1 Hedef Hareketlerinin Modellenmesi

Literatürde, insan hareketlerinin radar mikro-Doppler imzaları kullanılarak yapılan sınıflandırma çalışmalarında deneysel verilerin yanı sıra benzetim verilerinden de sıklıkla yararlanılmaktadır [1-3, 8, 22, 32]. Deneysel verilerin bulunamadığı veya eldeki kısıtlı miktardaki deneysel verinin yeterli miktarda genelleştirmenin sağlandığı bir sınıflandırma algoritması geliştirmek için yetersiz olduğu durumlarda benzetim verilerinin bulunması, çalışma açısından büyük kolaylık sağlamaktadır. Ayrıca, benzetimlerin oluşturulma süreci, deneysel verilerde görülen etki ve sonuçların kavranması için önemli bir adımdır.

Mikro-Doppler etkisinden yararlanılarak insan hareketlerinin sınıflandırması ile ilgili çalışmalarda Boulic tarafından geliştirilen yürüme modeli, simülasyon verisi olarak sıklıkla kullanılmaktadır [1-3]. Bu model, farklı insanlardan alınan deneysel veriler kullanılarak insan vücudu üzerindeki 17 referans noktasının konumunun zamana bağlı olarak değişimi incelenerek oluşturulmuştur. Söz konusu 17 referans noktası, Şekil 2.1’de görülmekte olan baş üst noktası, boyun eklemi, sağ omuz eklemi, sol omuz eklemi, sağ kol dirseği, sol kol dirseği, sağ el ucu, sol el ucu, omurga alt noktası, sağ kalça kemiği, sol kalça kemiği, sağ diz eklemi, sol diz eklemi, sağ topuk noktası, sol topuk noktası, sağ ayak ucu ve sol ayak ucudur. Model, sadece yürüme hareketi için geçerlidir ve bu 17 noktanın bir yürüme döngüsünün (sağ ve sol olmak üzere iki adım) farklı zaman değerlerindeki konumlarının hesaplanmasını sağlayan kinematik denklemlerden oluşmaktadır. Boulic Modeli kullanılarak bir yürüme döngüsü boyunca hareketi tanımlamada kritik öneme sahip olan 17 eklem ve uç noktasının hangi zamanda nerede bulunduğu hesaplanabilmektedir. Model, girdi olarak insanın boy uzunluğunu ve hareket hızını almaktadır.

Boulic Modeli, radar mikro-Doppler imzasının incelenmesi için en yaygın kullanılan insan hareket modelidir [1-3]. Fakat bu modelin sadece yürüme hareketi için bir model sunuyor olması, sınıflandırma çalışmalarında kol sallayarak ve kol sallamadan yürüme durumlarının ayrımı dışında kullanılamamasına sebep olmaktadır.

İnsan hareketlerinin radar benzetiminin yapılması için kullanılacak bir diğer kaynak ise hareket yakalama verileridir [32-33]. Hareket yakalama verileri, insan vücudunda hareketi tanımlamak için kritik öneme sahip olan eklem noktalarına yerleştirilen işaretçilerin uzaydaki konum bilgilerinin zamana bağlı olarak kaydedilmesiyle oluşturulmaktadır. Genellikle animasyon film ve bilgisayar oyunu sektörlerinde daha gerçekçi insan hareketi efektleri üretmek için kullanılmaktadırlar. Hareket yakalama sistemleri bir hayli pahalı olsa da araştırmacıların kullanabilmesi için ücretsiz insan hareket yakalama verileri sunan veri tabanları da mevcuttur [34-37].



Şekil 2.1 Boulic Yürüme Modeli'nde kullanılan 17 hareket noktasının gösterimi

Hareket yakalama verileri, son yıllarda özellikle sinema ve bilgisayar oyunu sektörleri tarafından daha gerçekçi modellemeler yapmak amacıyla yoğun olarak kullanılmaktadır. Temel olarak, Şekil 2.2'de görüldüğü gibi hareketin algılanması için kritik olduğu düşünülen noktalarda üzerine işaretçiler yerleştirilen deneğin yaptığı hareketlerin, bu işaretçilerin zaman içindeki konumlarının belirlenerek kayıt altına alınması ile oluşturulmaktadır. İşaretçilerin yerleştirildiği kritik noktaların konumlarına ait verilerden yararlanarak da hareketlerin modellemeleri yapılabilmektedir.

Hareket yakalamasının popürlüğünün son yıllarda giderek artması, üniversitelerde bu konu ile ilgili arařtırmaları artırmıřtır. Carnegie Mellon Üniversitesi (CMÜ) Grafik Laboratuvarı, tüm dünyada bu konu üzerinde çalıřma yapacak insanların kullanması için ücretsiz bir veritabanını kullanıma sunmuřtur. Veritabanı içinde yürüme, kořma, tırmanma, sürünme, zıplama, sportif aktiviteler gibi birçok farklı insan hareketinin, farklı denekler ile kaydedilmiş verileri bulunmaktadır. Veriler insan vücuduna yerleřtirilen 41 iřaretçi yardımıyla, 12 kızılötesi kamera kullanılarak 120 Hz frekansında kaydedilmiřtir. Veritabanında 112 farklı deneye ait toplam 2605 adet hareket verisi bulunmaktadır.



řekil 2.2 İřaretçiler bağlanarak hareket yakalama sistemi ile veri kaydı yapılacak olan denegin görüntüsü [36]

CMÜ hareket yakalama veritabanındaki her bir veri, ASF ve AMC dosya çifti şeklinde oluşturulmuřtur. ASF dosyası iskelet bilgisi dosyası olarak adlandırılır ve insan vücudunda belirlenmiş olan 30 parçanın uzunluklarını ve yönlerini içerir. Bu parçalar, kök noktasından başlayarak bir ağaç hiyerarřisi ile oluşturulmuřtur. Veritabanındaki her bir denek için denegin kemik uzunluklarını belirten bir ASF dosyası bulunmaktadır. AMC dosyaları ise hareket bilgisinin kayıtlı olduđu dosyalardır. Kemiklerin zaman içindeki dönme ve yön bilgileri bu dosyadaki veriler

kullanılarak hesaplanır. Her bir hareket için veri tabanında bir adet AMC dosyası bulunmaktadır.

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

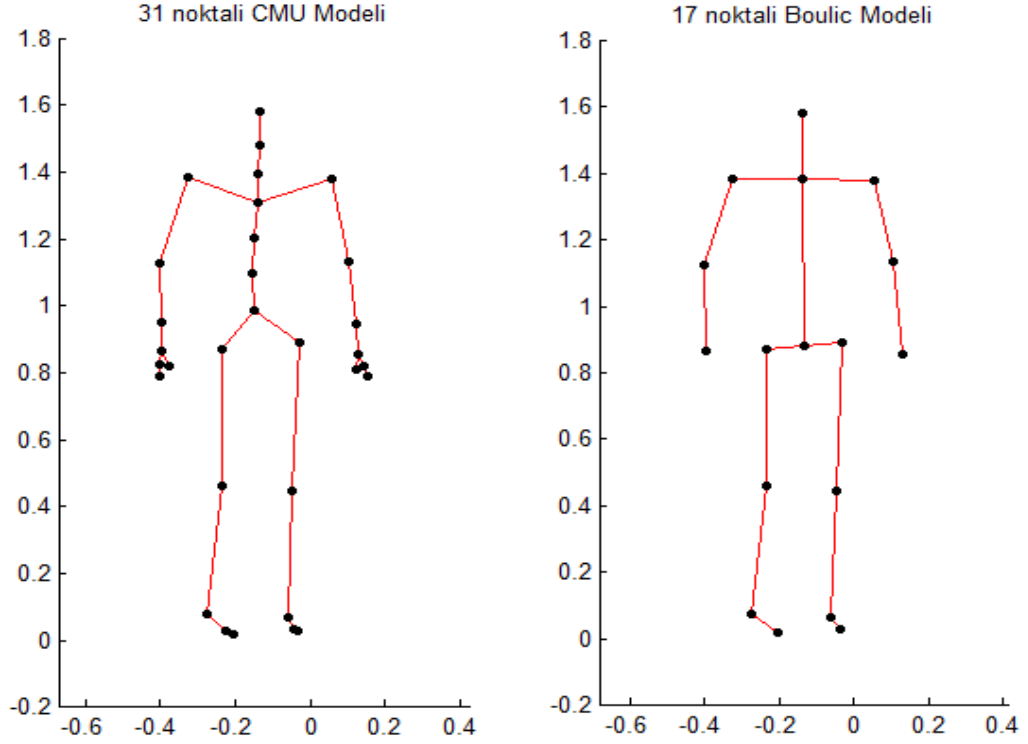
Hareket yakalama verilerinin sınıflandırma çalışmaları için kullanılmasını sağlayabilmek için öncelikli olarak CMÜ veritabanının sunduğu ASF ve AMC dosyalarından kök noktası ve vücut parçalarına ait 30 nokta olmak üzere toplam 31 noktanın kartezyen koordinat sisteminde zamana göre konumlarının hesaplanması gerekmektedir. Bu işlemi gerçekleştirmek için Neil Lawrence tarafından hazırlanan MATLAB Motion Capture Toolbox [38] kütüphanesi kullanılabilir. Bu kütüphane, ASF-AMC çifti veya BVH formatında verilen hareket yakalama verilerini okuyup, 31 referans noktasının zaman içindeki konumlarını hesaplayıp kullanıcıya sunan MATLAB fonksiyonlarını içermektedir.

CMÜ hareket yakalama veritabanı verileri, Şekil 2.3'de de görülebileceği üzere radar çalışmalarında benzetim amacıyla kullanılan Boulic Modeli'ne göre daha ayrıntılı bir iskelet yapısı sunmaktadır. Örneğin, Boulic Modeli'nde kol, alt ve üst olmak üzere iki parçadan oluşurken, CMÜ hareket yakalama verilerinde altı parçadan oluşmaktadır. Daha önce Boulic Modeli ile yapılan radar benzetim çalışmalarında [1-3] bu modelin başarısı görüldüğünden ve fazla verinin hesaplamalarda getireceği yükü azaltmak amacıyla eldeki 31 noktalı modelden 14 nokta atılarak 17 referans noktası içeren Boulic Modeli'ne geçilip hareket yakalama verileri Boulic Modeli'nin çıktısı ile özdeş hâle getirilebilmektedir [32-33].

CMÜ hareket yakalama veritabanından elde edilen veriler, saniyede 120 görüntü alınarak oluşturulmuştur. Veritabanındaki verilerin bir kısmı 2 ile 3 saniye arasında değişen kısa süreli verilerdir. Nokta sayısının az olması, eldeki veriden radar sinyalinin oluşturulması aşamasında, beklenenden daha düşük kalitede sonuçlar alınmasına neden olmaktadır. Dolayısıyla bu gibi kısa süreli veriler içeren




dosyalardaki verilerde, peş peşe gelen iki konum arasında kübik eğri ara değerlendirme yöntemiyle yeni noktalar oluşturulup veri noktası sayısı artırılarak daha kaliteli sonuçlar elde edilmesi sağlanabilir.



Şekil 2.3 CMÜ verilerinden edilen veriler ve Boulic Modeli'nden elde edilen verilerin karşılaştırılması [33]

Veri noktası sayısının az olduğu veriler için ara değerlendirme ile yeni veri noktaları oluşturulduktan sonra, incelenen hareketin animasyonu çizdirilebilir. Animasyondaki insan vücudu, modelden gelen 17 noktanın arasında kalan 12 parçadan oluşmaktadır. Bu parçalar baş, gövde, üst kollar, alt kollar, üst bacaklar, alt bacaklar ve ayaklardır. Örneğin, yürüme, emikleme ve yürüme hareketlerinin yapıldığı bir hareket yakalama verisinin animasyonunun farklı anlarında alınan kesitlerin birleştirilmesi ile oluşan görüntü Şekil 2.4'de görülmektedir.

Hareket yakalama verileri yürüme, koşma gibi ana hareketlerin modellenmesinden insan yüzündeki mimiklerin ve insan elindeki parmak hareketlerinin modellenmesine kadar olan geniş bir yelpazede kullanılmaktadır. Hatta hayvan hareketlerinin modellenmesi dahi hareket yakalama sistemleri kullanılarak yapılabilmektedir [32].



Şekil 2.4 Örnek bir hareket yakalama verisinden üretilen animasyonun farklı anlardaki kesitlerinin birleştirilmesi ile oluşturulmuş görüntü [33]

## 2.2 Radar Benzetim Çalışmaları

İnsan hareketlerinin radar benzetimi gerek Boulic Modeli [1-3] gerekse de hareket yakalama verileri [32-33] kullanılarak literatürde daha önce yapılmıştır. İnsan hareketlerinin radar benzetimi yapılırken insan vücudundaki 12 parçaya ait 17 noktanın konum bilgileri hareket yakalama verileri kullanılarak elde edildikten sonra, her bir parça radar kesit alanı daha önce literatürde formüle edilmiş geometrik şekiller ile modellenmektedir. Bu amaçla, gerçek şekillerine benzerlikleri nedeniyle kafa küre olarak, diğer tüm vücut parçaları ise elipsoidler ile modellenebilir [2]. Küre şeklindeki bir cismin radar kesit alanı kürenin yarıçapı  $r$  olmak üzere

$$\sigma_{küre} = \pi r^2 \quad (2.1)$$

formülü ile hesaplanabilmektedir [1]. Elipsoidin radar kesit alanı ise üç farklı eksendeki yarıçap değerleri  $a$ ,  $b$  ve  $c$  ile, radar ile elipsoid arasındaki görüş açısı  $\theta$  ile ve elipsoidin yalpa (roll) açısı  $\phi$  ile temsil edilmek üzere

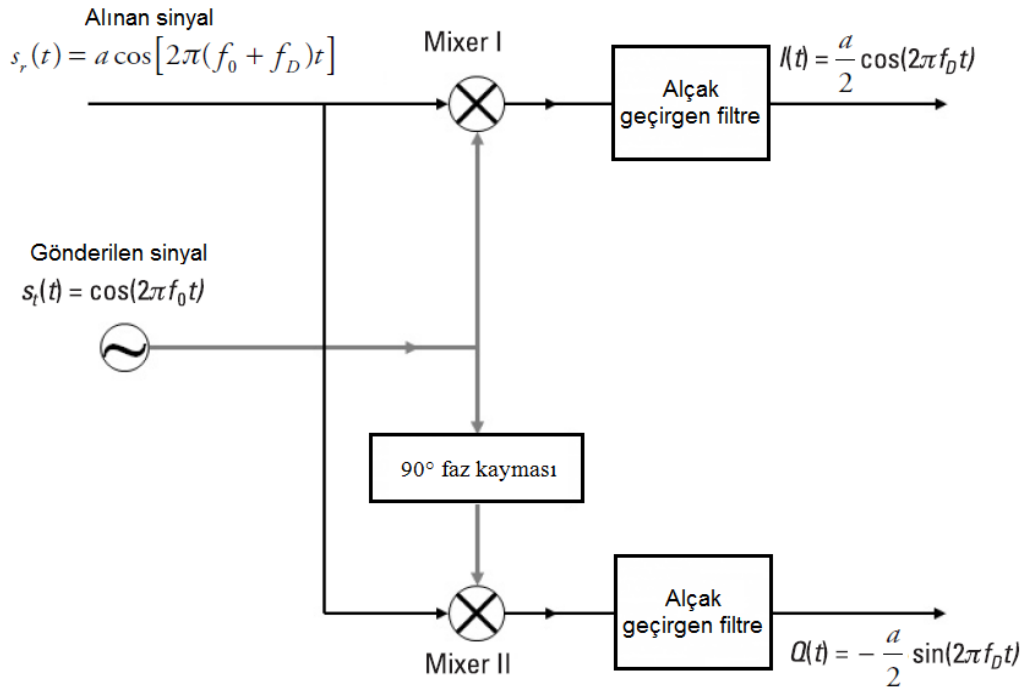
$$\sigma_{elipsoid} = \frac{\pi a^2 b^2 c^2}{\left( a^2 (\sin \theta)^2 (\cos \varphi)^2 + b^2 (\sin \theta)^2 (\sin \varphi)^2 + c^2 (\cos \theta)^2 \right)^2} \quad (2.2)$$

formülü ile hesaplanabilmektedir [1].

Kullanılan radarın Şekil 2.5’de görüldüğü gibi  $f_0$  frekanslı bir sabit kosinüs dalgası göndermesi durumunda radar dördül sezicisinin çıkışında

$$s_r(t) = I(t) + jQ(t) = \frac{a}{2} \exp(-j2\pi f_{doppler} t) \quad (2.3)$$

formülü ile ifade edilebilecek karmaşık bir sinyal elde edilmektedir [1]. Bu formülde  $a$  değeri sinyalin genlik değerini,  $f_{doppler}$  ifadesi (1.2)’de belirtilen hedefin neden olduğu Doppler kayması miktarını ve  $t$  zamanı ifade etmektedir.



Şekil 2.5 Dördül sezici (quadrature detector) ile Doppler kaymasının çıkarılması [1]

Hedeften dönen sinyalin genlik değeri  $a$ , radar menzil denklemi kullanılarak

$$a = \frac{G\lambda\sqrt{P\sigma}}{(4\pi)^{1.5} R^2 \sqrt{L}} \quad (2.4)$$

şeklinde hesaplanabilmektedir. Bu denklemde  $G$  anten kazancını,  $\lambda$  dalga boyunu,  $P$  radarın çıkış gücünü,  $\sigma$  hedefin radar kesit alanı değerini,  $R$  hedefin radara olan uzaklığını,  $L$  sistemden ve atmosferik etkilerden kaynaklanan tüm kayıpları temsil etmektedir. Benzetimlerde farklı darbeler için  $G$ ,  $\lambda$ ,  $P$  ve  $L$  değerlerinin değişmeyeceği varsayılarak (2.4)'de verilen ifade kısaltılarak

$$a = \frac{\sqrt{\sigma}}{R^2} \quad (2.5)$$

şeklinde kullanılabilir [1]. Benzetimlerde insan vücudunu oluşturmak için kullanılan 12 parçanın radar kesit alanı değerleri (2.1) ve (2.2) kullanılarak hesaplandıktan sonra hedefin radara olan uzaklığı da kullanılarak her bir darbe için insandan dönen sinyal

$$s_{insan}(t) = \sum_{i=1}^{12} \frac{\sqrt{\sigma_i}}{2R_i^2} \exp\left(-j2\pi f_c \frac{2R_i}{c}\right) \quad (2.6)$$

formülü ile ifade hesaplanabilmektedir [1]. Bu formülde temel olarak 12 parçadan yansıyan sinyaller hesaplanarak toplanmakta ve bir darbe için insandan elde edilen karmaşık sinyal oluşturulmaktadır. Hedefin hareketi devam ederken farklı darbeler için ilgili geometrik şekillerin radar kesit alanı, menzil ve sebep olacağı Doppler kayması miktarı farklı olacağı için hedefin hareketindeki farklılıklar radar imzasında gözlemlenebilecektir.

Benzetim çalışmaları gerçekleştirilirken insanın hareketi boyunca gönderilen her bir darbe için vücuttaki 12 parçaya çarparak dönen radar sinyalleri ayrı ayrı hesaplanır. Bu 12 sinyal toplanarak o darbe için insanın radar cevabı (2.6)'da verilen ifade ile elde edilir. Hareket yakalama verisinin süresi bitene kadar bu işleme devam edilerek oluşan hedefin radar cevabı

$$x[n] = [I_1 + jQ_1, I_2 + jQ_2, \dots, I_n + jQ_n] \quad (2.7)$$

şeklinde bir karmaşık sayı dizisi halinde elde edilir.

Mikro-Doppler etkisini ham radar verisinden gözlemlemek mümkün değildir. Bu nedenle gelen verinin Fourier Dönüşümü (FD) alınarak frekans uzayına geçilir ve hedefin hareketinden kaynaklanan frekans kayması bu şekilde görülebilir. Ancak FD ile frekans uzayına geçildiğinde de zaman bilgisi kaybolmaktadır. Zaman ve frekans bilgisini aynı anda görebilmek için daha önce de bahsedildiği üzere BZFA teknikleri literatürde yaygın olarak kullanılmaktadır. BZFA ile oluşturulan yapılarda hangi zamanda ne kadar frekans kayması olduğunu görmek mümkündür. Bu da radar verileri incelenirken hareketin farklı anlarındaki kayma miktarı değişimlerinin doğrudan görülebilmesini sağlar. Hareketin farklılaştığı noktaların gözlemlenebilmesi de söz konusu harekete ait örüntüyü kullanarak bu hareketin başka hareketlerden ayrılmasına olanak vermektedir. Örneğin, insana ait yürüme ve emekleme hareketlerinin radar BZFA örüntüleri birbirinden oldukça farklı olduğu için bu hareketlerin insan gözüyle ya da bilgisayar yardımı ile ayrılmaları mümkün hale gelmektedir. Literatürde radar mikro-Doppler imzalarını incelemek için en sık kullanılan BZFA tekniği daha önce de bahsedildiği üzere KZFD'dir. KZFD,  $x[n]$  ile ifade edilen radar verisi üzerinden

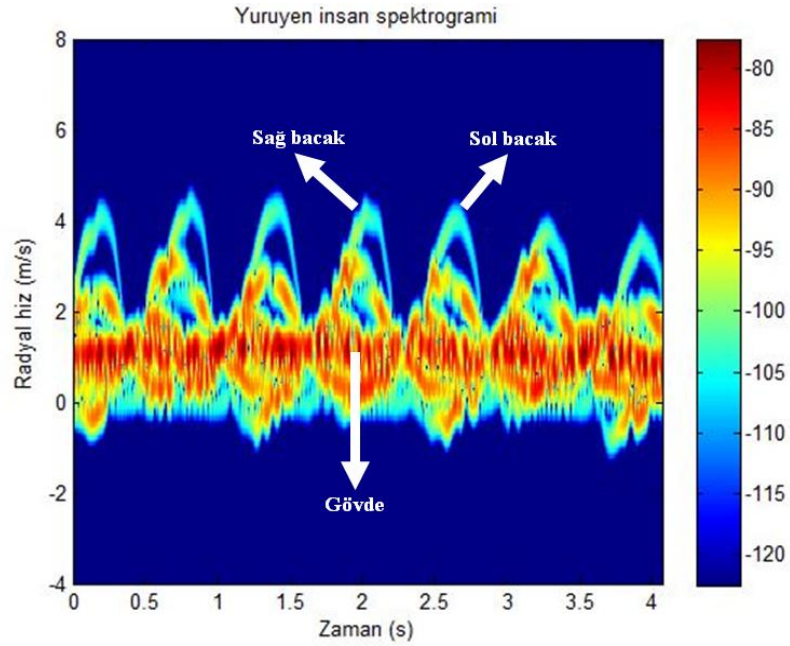
$$X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n-m]e^{-j\omega n} \quad (2.8)$$

formülü ile hesaplanabilmektedir [1]. Bu formülde  $w[n]$  Hamming, Hanning, Blackman, dikdörtgen vb. bir pencere fonksiyonunu temsil etmektedir. (2.8)'de elde edilen ifadenin üzerinde

$$s(m, \omega) = |X(m, \omega)|^2 \quad (2.9)$$

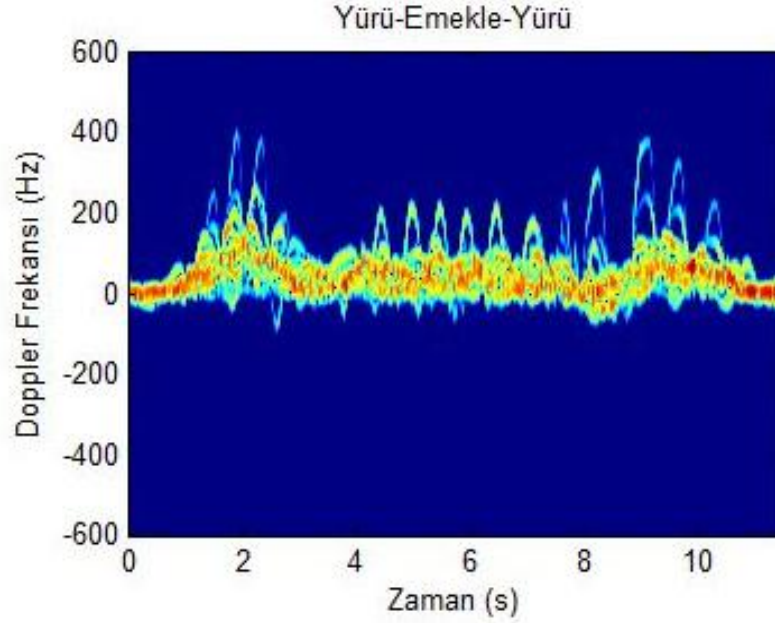
formülü uygulanarak spektrogram oluşturulmakta ve bu spektrogram öznetelik çıkarma algoritmalarına girdi olarak verilmektedir. Örneğin, yürüyen bir insanın hareket yakalama verileri kullanılarak gerçekleştirilen radar benzetimi sonucu oluşan spektrogram Şekil 2.6'da görülmektedir. Spektrogramın yatay eksenini zamanı, dikey eksenini radyal hız değerini ve renklendirme ise dönen radar sinyalinin gücünü temsil etmektedir. Spektrogramda işaretlendiği üzere hedefin sağ ve sol bacaklarından gelen sinyaller rahatlıkla ayrıştırılabilmektedir. Ayrıca, insanın radar kesit alanı değeri en yüksek değere sahip vücut parçası olan gövdenin oluşturduğu sinyal de diğer vücut

parçalarından dönen sinyallere oranla daha güçlü olduğu için spektrogram üzerinde ayrıştırılabilmektedir.



Şekil 2.6 Hareket yakalama verileri kullanılarak elde edilen yürüyen insan spektrogramı üzerinde vücut parçalarının oluşturduğu imzaların gösterilmesi

Şekil 2.4'de sunulan görüntünün radar benzetimi sonucu oluşan spektrogramı Şekil 2.7'de görülmektedir. Şekilde de görülebileceği üzere spektrogramın ilk 3 saniyesinde ve son 3 saniyesinde insan yürürken gelen Doppler kayması miktarı, 4. ve 8. Saniyeler arasında gerçekleşen emekleme hareketinin oluşturduğu Doppler kayması miktarından daha yüksektir. Bunun nedeni, yürüyen insanın kol ve bacaklarının emekleyen insanın kol ve bacaklarından çok daha hızlı salınımlar yapmasıdır. Ayrıca, hareket değiştikçe spektrogramda kırmızı renk ile görülen insan gövdesinden gelen sinyalin oluşturduğu Doppler kaymasında da önemli değişimler yaşanmaktadır. Bu da yürüme ve emekleme hareketlerini yaparken hedefin hızında önemli miktarda değişim oluştuğunu göstermektedir.



Şekil 2.7 Yürüme, emekleme ve tekrar yürüme hareketlerinin radar benzetimi sonucu oluşan spektrogram [33]

### 2.3 Hedef Veri Tabanının Oluşturulması

Bu çalışma kapsamında literatürdeki çalışmalar da örnek alınarak hareket yakalama verileri ile insan hareketlerinin radar imzası oluşturulmuştur. Ücretsiz hareket yakalama verisi sunan 3 farklı veri tabanından [34-36] alınan veriler kullanılarak yürüme, koşma, emekleme ve sürünme hareketleri için hareket yakalama verileri toplandı. ASF-AMC dosya çiftini okumak için [38]'de sunulan kütüphane kullanılarak insan vücuduna ait noktaların zamana bağlı konumları hesaplandı. Farklı veri tabanlarındaki veriler, insan vücudundaki farklı sayıda noktanın konum bilgisini içermektedir. Benzetimlerde bu farklılıklara bağlı olarak farklı sonuçlar oluşmasını engellemek için Boulic Modeli esas alınarak 17 noktalı insan modelinde yer alan noktaların dışında kalan noktalar kullanılmadı. 17 noktalı model kullanılarak insan vücudu 12 parça halinde modellendi.

Hareket yakalama verilerinin frekansı genelde 30 Hz ve 120 Hz arasında değişen düşük değerlerdir. Bu değerler radar benzetimi yapmak için çok düşük kaldığından elde edilen verilerin frekansı 3000 Hz olacak şekilde kübik eğri ara değerlendirme işlemi uygulanarak veriler radar benzetimi için hazır hâle getirildi.

Hedef sınıflandırma çalışması için veritabanı oluşturulurken kara gözetleme radarı konsepti düşünülerek farklı hedef tipleri belirlendi. Literatürdeki çalışmalarda kullanılan kara hedefleri insan, insan grubu, tekerlekli araç, paletli araç ve hayvandır. Veri tabanı oluşturulurken insanın yürüme, koşma, emekleme, sürünme olmak üzere 4 farklı hareketinin benzetimi hareket yakalama verileri kullanılarak gerçekleştirildi. Literatürde yapılan araştırmada insan grubu için özel bir modele rastlanmadı. Bu amaçla, hareket yakalama verilerinden alınan farklı insan dosyalarının aynı menzil hücresi içinde eş zamanlı hareket ettirilmesi ile insan grubu benzetiminin yapılması kararlaştırıldı. Bu şekilde yan yana yürüyen iki insan ve yan yana koşan iki insan için radar imzaları oluşturuldu.

Araç modellemesi için ise literatürde araştırma yapıldığında nokta hedef modellemesi yönteminin kullanıldığı görüldü [39]. Bunun nedeni, araçların gövdelerinden dönen sinyalin oldukça güçlü olması ve mikro-Doppler kaynaklı sinyallerin gövdeden gelen yansıma göre oldukça düşük olmasıdır. Gerçekleştirilen benzetimlerde aracın modellenmesi nokta hedef modelleme yöntemi ile yapıldı. Aracın radar kesit alanı değeri  $10 \text{ m}^2$  olarak alınarak sabit hızlı ve ivmeli hareketlere ait farklı araç verileri oluşturuldu.

Yapılan araştırmada hayvan hareketlerinin modellenmesi için literatürde doğruluğu kabul görmüş bir modele rastlanmamıştır. Hareket yakalama sistemleri hayvan hareketlerinin kaydedilmesi için kullanılıyor olsa da [32] internette yapılan aramalarda ücretsiz hayvan verisi sunan bir hareket yakalama veri tabanına rastlanmamıştır. Dolayısıyla benzetime hayvan verileri eklenememiştir.

Ücretsiz hareket yakalama verileri incelendiğinde özellikle insan koşması verilerinin sürelerinin 0,7 saniye ile 1,5 saniye arasında değiştiği ve daha uzun verilerin bulunmadığı görülmüştür. Bu nedenle diğer hareketlere ait veriler de en fazla 1,5 saniye olacak şekilde parçalara ayrılarak kullanılmıştır.

Benzetimlerde kullanılan radar, darbe Doppler prensibi ile çalışmaktadır. Taşıyıcı frekansı 35 GHz, menzil çözünürlüğü 3 metre, darbe tekrarlama sıklığı 3000 Hz olarak seçilmiştir. Her bir benzetim verisinin maksimum uzunluğu 1,5 saniyedir ve hedefin hareketine başlama noktası radara 1000 metre uzaklıktadır. KZFD

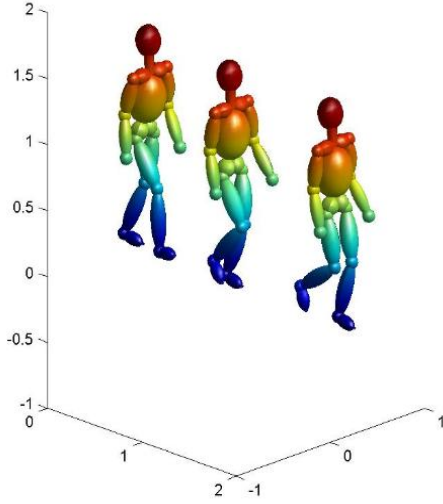


hesaplamaları yapılırken 256 uzunluğunda Blackman pencereleri kullanılmış ve pencere her adımda 64 nokta kaydırılmıştır. Oluşturulan veri tabanında toplam 560 adet veri bulunmaktadır. Bu verilerin sınıflara göre dağılımı Çizelge 2.1’de görülmektedir.


Çizelge 2.1 Benzetim veri tabanındaki verilerin hedef tiplerine göre dağılımı

	Yürüme	Koşma	Emekleme	Sürünme	İki İnsan Yürüme	İki İnsan Koşma	Araç
Veri Sayısı	195	71	73	38	70	70	43

Oluşturulan veri tabanındaki hareket dosyalarının doğruluğunun kontrolü için hedef modellerinin animasyonu ve spektrogramları çıkarıldı. Yürüme hareketi için elde edilen örnek animasyon görüntüsü Şekil 2.8 (a)’da, örnek spektrogram görüntüsü ise Şekil 2.8 (b)’de; koşma hareketine ait örnek animasyon görüntüsü Şekil 2.9 (a)’da, örnek spektrogram ise Şekil 2.9 (b)’de; emekleme hareketine ait örnek animasyon görüntüsü Şekil 2.10 (a)’da, spektrogram ise Şekil 2.10 (b)’de; sürünme hareketine ait örnek animasyon görüntüsü Şekil 2.11 (a)’da, spektrogram ise Şekil 2.11 (b)’de; 1.5 metre mesafe ile yan yana yürüyen iki insan yürümesi için örnek animasyon görüntüsü Şekil 2.12 (a)’da, spektrogramı Şekil 2.12 (b)’de; 1.5 metre mesafe ile yan yana koşan iki insan koşması için örnek animasyon görüntüsü Şekil 2.13 (a)’da, spektrogramı Şekil 2.13 (b)’de; araç hareketine ait örnek animasyon görüntüsü Şekil 2.14 (a)’da, spektrogram ise Şekil 2.14 (b)’de görülmektedir. Sunulan tüm spektrogramlar hedefin doğrudan radara doğru hareket ettiği durum için çizdirilmiştir.

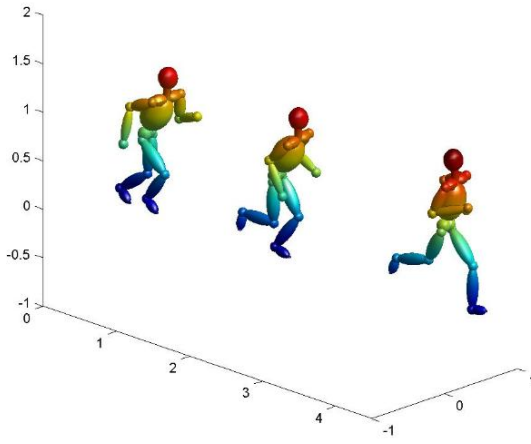


(a)




(b)

Şekil 2.8 (a) Yürüme hareketine ait animasyon görüntüsü (b) Yürüme hareketine ait spektrogram

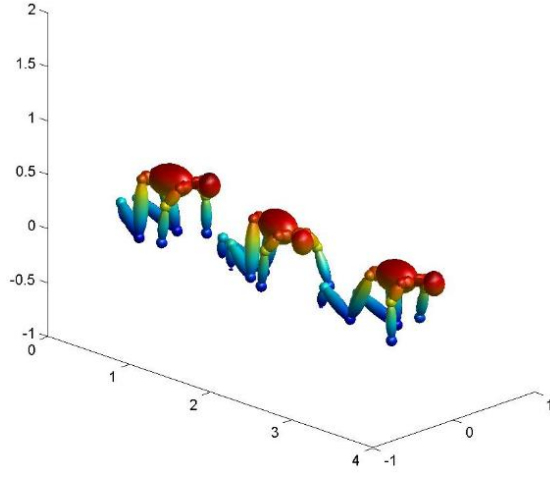


(a)




(b)

Şekil 2.9 (a) Koşma hareketine ait animasyon görüntüsü (b) Koşma hareketine ait spektrogram

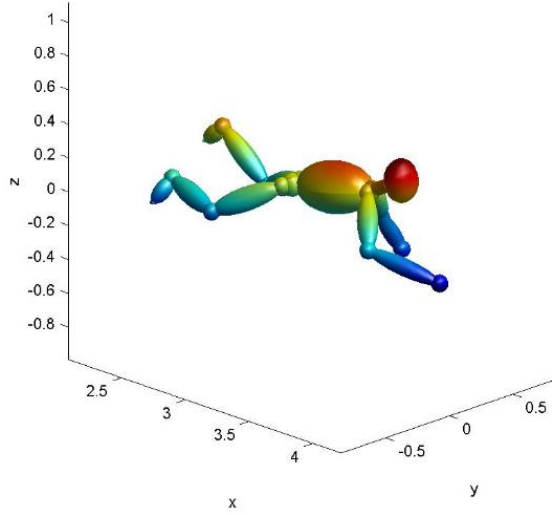


(a)




(b)

Şekil 2.10 (a) Emekleme hareketine ait animasyon görüntüsü (b) Emekleme hareketine ait spektrogram




(a)

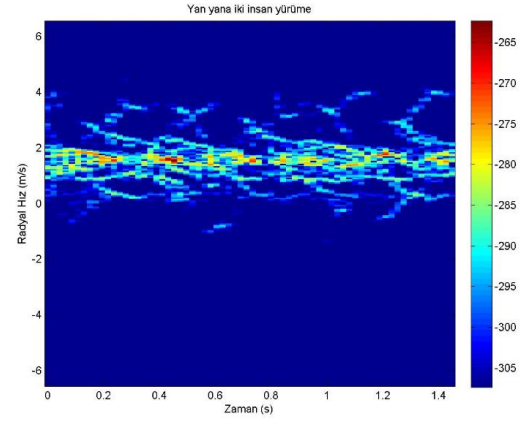


(b)

Şekil 2.11 (a) Sürünme hareketine ait animasyon görüntüsü (b) Sürünme hareketine ait spektrogram

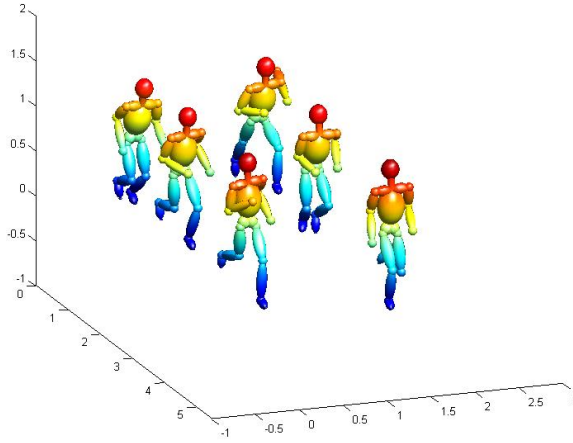


(a)

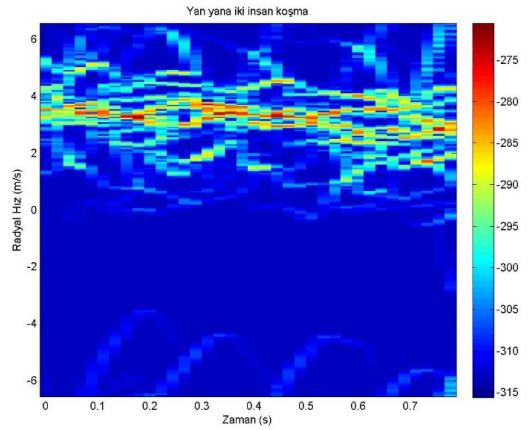


(b)

Şekil 2.12 (a) Yan yana iki insan yürütmesi hareketine ait animasyon görüntüsü (b) Yan yana iki insan yürütmesi hareketine ait spektrogram




(a)



(b)

Şekil 2.13 (a) Yan yana iki insan koşması hareketine ait animasyon görüntüsü (b) Yan yana iki insan koşması hareketine ait spektrogram



Şekil 2.14 (a) Araç hareketine ait animasyon görüntüsü (b) Araç hareketine ait spektrogram

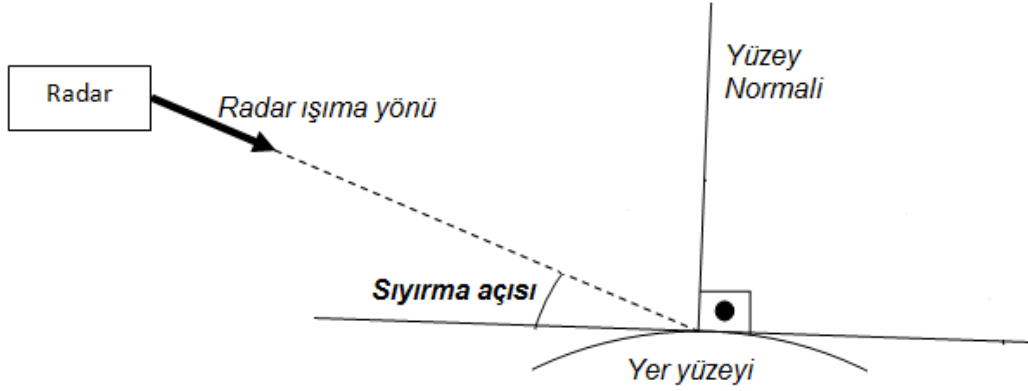
Bu çalışma için oluşturulan hareket veritabanı hedefin radara  $0^\circ$ ,  $30^\circ$ ,  $60^\circ$  ve  $90^\circ$  görüş açıları ile hareket ettiği veriler içermektedir. Ayrıca, deneysel verilere olan yakınlığın artırılması için parazit yansımaya modellemesi ve gürültü de benzetime ilave edilmiştir. MATLAB programı ortamında geliştirilen gürültü ekleme ve parazit yansımaya ekleme fonksiyonları sayesinde farklı parazit yansımaya ve SGO durumları için radar verileri oluşturulabilmektedir.

Gürültü için hedeften dönen radar sinyalinin gücü hesaplanarak istenen SGO değerini sağlayacak olan karmaşık Eklenebilir Beyaz Gauss Gürültüsü (EBGG) oluşturuldu ve (2.7) ile elde edilen hedefin radar cevabı verisine eklendi. Parazit yansımaya modellemesi için ise [40] nolu kaynakta sunulan parazit yansımaya modellerinden bir tanesi kullanılmıştır. Kullanılan model 3-100 GHz arasındaki frekanslarda ve sıyrma açısı (grazing angle) değerinin 30 dereceden küçük olduğu durumlar için geçerliliğini korumaktadır. Modelin çıktısı metrekareye düşen parazit yansımaya miktarıdır ( $\sigma^0$ ) ve hesaplanması

$$\sigma^0(dB) = A_1 + A_2 \log_{10}(\psi / 20) + A_3 \log_{10}(f_0 / 10) \quad (2.10)$$

formülü ile yapılmaktadır. Burada  $f_0$  GHz cinsinden taşıyıcı frekansını,  $\psi$  derece cinsinden sıyrma açısı değerini temsil etmektedir. Sıyrma açısı, Şekil 2.15'de

görüldüğü üzere radar hüzmesinin yeryüzü ile yaptığı açığı ifade etmektedir. Formülde yer alan  $A_1$ ,  $A_2$  ve  $A_3$  katsayıları ise arazi özelliklerine göre Çizelge 2.2'deki gibi seçilmektedir.



Şekil 2.15 Sıyırma açısının gösterimi

Çizelge 2.2 Farklı arazi tipleri için katsayı değerleri [40]

Arazi Tipi	$A_1$	$A_2$	$A_3$
Beton	-49	32	20
Tarım arazisi	-37	18	15
Kar	-34	25	15
Yaprak döken ağaçlardan oluşan orman, yaz	-20	10	6
Yaprak döken ağaçlardan oluşan orman, kış	-40	10	6
Uzunluğu 0,5 metreden fazla olan otlak	-21	10	6
Uzunluğu 0,5 metreden az olan otlak	-(25-30)	10	6
Kentsel bölgeler (kasaba ve köy binaları)	-8.5	5	3

(2.10) ve Çizelge 2.2 kullanılarak elde edilen metrekareye düşen parazit yansıma büyüklüğü radarın yer yüzeyinde oluşturduğu iz bölgesi ile çarpılarak parazit yansımanın RKA değeri belirlenmekte ( $\sigma_{\text{parazit}}$ ) ve parazit yansımadan dönen radar sinyali

$$s_{\text{parazit}}(t) = \frac{\sqrt{\sigma_{\text{parazit}}}}{2R^2} \exp\left(-j2\pi f_c \frac{2R}{c}\right) \quad (2.11)$$

ile hesaplanmaktadır. Hesaplanan parazit yansıma sinyali, (2.7) ile ifade edilen hedefin radar cevabı ve oluşturulan EBGG ile


$$s_{ham}(t) = s_{hedef}(t) + s_{parazit}(t) + s_{gürültü}(t) \quad (2.12)$$

şeklinde toplanarak radar ham verisi elde edilmektedir [1].

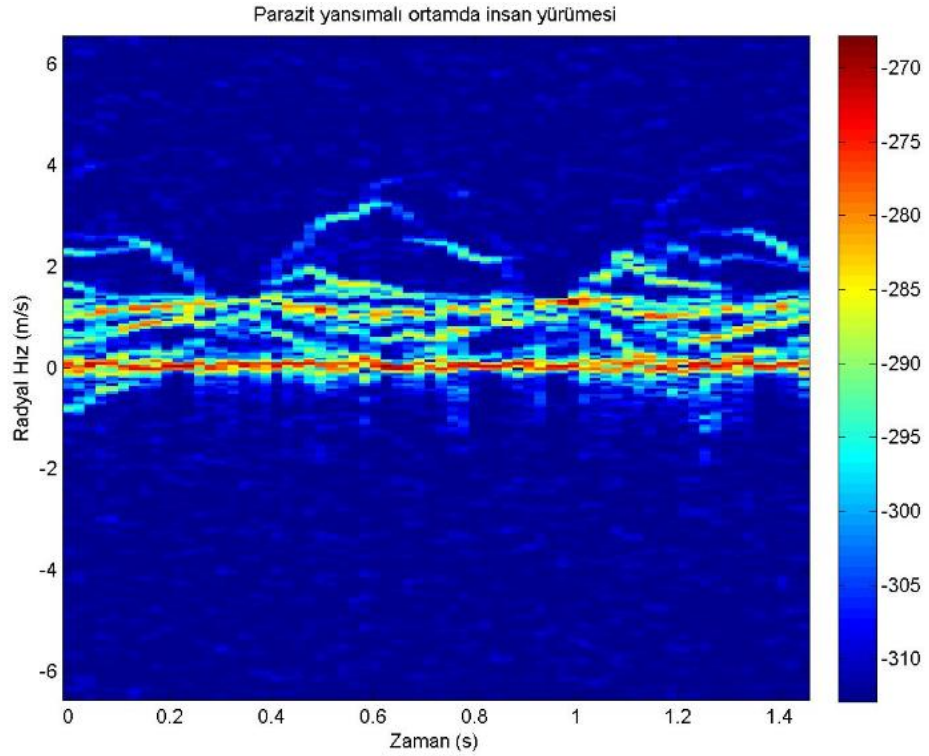
Benzetimlerde parazit yansıma tipi olarak karasal hedeflerin en fazla görülebileceği ortam olan uzunluğu 0,5 metreden az olan otlak seçilmiştir. Benzetimler sonucu elde edilen örnek bir parazit yansıma sinyalinin spektrogramı Şekil 2.16'daki gibidir. Spektrogramda da görülebileceği üzere parazit yansıma sinyali sadece 0 m/sn değerindeki Doppler hücrelerinde değil bu hücrelerin etrafındaki hücelere de bir miktar yayılım göstermiştir. Fakat parazit yansımanın en güçlü bileşenleri 0 m/s civarında görülmektedir.

Elde edilen parazit yansıma sinyalinin Şekil 2.8 (b)'de sunulan insan yürümesi verisine eklenmesi ile elde edilen spektrogram ise Şekil 2.17'de görülmektedir. Bu spektrogramda da görülebileceği gibi parazit yansıma sinyali insanın gövdesinden gelen sinyalden daha güçlüdür. Spektrogramda insan gövdesinden dönen sinyalden daha güçlü bir sinyalin varlığı, hedef sınıflandırma algoritmalarının başarımını olumsuz yönde etkileyebilir [2].

Parazit yansıma sinyali eklenmiş hedef verisine SGO değeri 24 dB olacak şekilde EBGG de eklenirse elde edilen spektrogram Şekil 2.18'de görüldüğü gibi oluşmaktadır. Spektrogramda da görülebileceği üzere parazit yansımanın aksine gürültü bütün Doppler hücrelerine yayılmıştır. Gürültünün varlığı hedef tespitini zorlaştırdığı gibi sınıflandırma üzerinde de önemli derecede olumsuz etkiler oluşmaktadır [1, 11, 17].




Şekil 2.16 Örnek parazit yansıma spektrogramı




Şekil 2.17 Parazit yansımalarının olduğu ortamda insan yürüme spektrogramı





Şekil 2.18 Parazit yansıma içeren ve 24 dB SGO değerine sahip insan yürüme spektrogramı

Bu bölümde gerçekleştirilen çalışmalar Şekil 2.19’da özetlenmiştir. Hedef modelleme çalışmalarında insan hareketlerinin modellenmesi için hareket yakalama verilerinden faydalanılmıştır. Araç hareketlerinin modellenmesi için ise nokta hedef modeli kullanılmıştır. Radar benzetimi çalışmalarında darbe Doppler prensibi ile çalışan bir radar modellenerek hedefin radar cevabı oluşturulmuştur. Ayrıca, benzetimleri deneysel verilere daha yakın hâle getirmek için parazit yansıma ve gürültü etkileri de modellenmiştir. Daha sonra ham radar verisi üzerinde KZFD alınarak radar sinyalinin spektrogramı oluşturulmuştur.

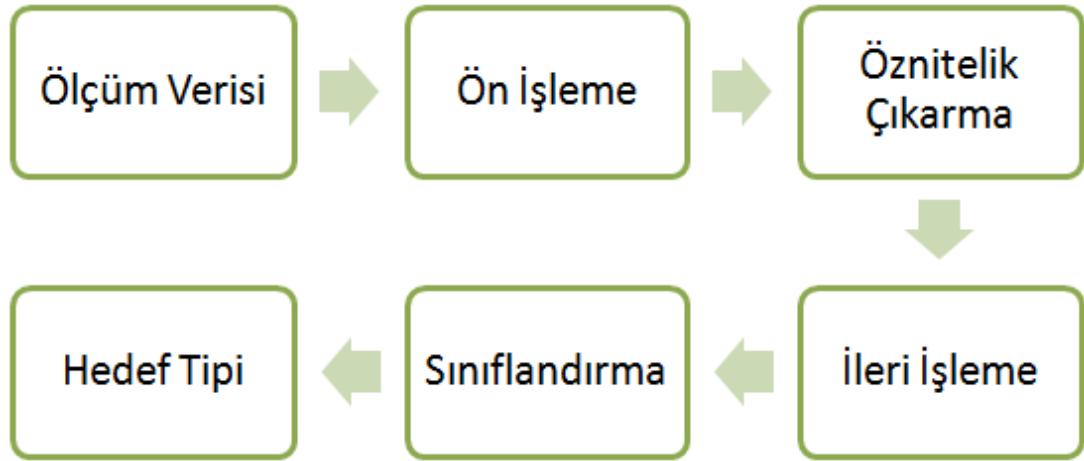


Şekil 2.19 Bölümde yapılan çalışmaların özeti


### 3. ÖZNETELİK ÇIKARMA ÇALIŞMALARI

Sınıflandırma algoritmaları genel olarak ölçüm verilerinin elde edilmesi, veriler üzerinde ön işleme çalışmalarının yapılması, özniteliklerin çıkarılması, çıkarılan öznitelikler üzerinde ileri işleme tekniklerinin uygulanması ve bir sınıflandırıcı yardımıyla verinin tipinin belirlenmesi aşamalarından oluşmaktadır [41]. Ölçüm verileri genellikle bir algılayıcının çıktısı olarak sunulan içinde gürültü de barındıran verilerdir. Örneğin termometreden okunan sıcaklık değerleri ya da kamera ile kaydedilen bir video görüntüsü birer ölçüm verisidir. Ön işleme aşamasında ölçüm verileri üzerinde gürültü temizleme ve aykırı değerlerin bulunup çıkarılması gibi sınıflandırma performansını artırmaya yönelik çalışmalar uygulanmaktadır. Öznitelik çıkarma aşamasında ön işlemeden geçen ölçüm verileri üzerinden bu veriyi temsil edecek istatistikî özellikler hesaplanmaktadır. Örneğin bir fotoğraftaki nesnelerin kaç piksel yer kapladığı bilgisi, radardan elde edilen verideki Doppler kayması değeri ve termometreden okunan sıcaklık değerlerinin standart sapması birer öznitelik örneğidir. İleri işleme aşamasında hesaplanan öznitelik değerleri üzerinde öznitelik uzayının boyutunu azaltmaya yönelik işlemler uygulanmaktadır. Bu amaçla literatürde Asal Bileşen Analizi, Tekil Değer Ayrışımı ve Ardışık İleri Yönlü Öznitelik Seçimi gibi farklı yöntemler bulunmaktadır [42]. Öznitelik uzayının boyutunun küçültülmesi hem sınıflandırıcının işlem yükünün azaltılması için önemlidir hem de birbiri ile ilintili özniteliklerin çıkarılarak sınıflandırma performansının artırılması için gereklidir [42]. Sınıflandırma aşamasında küçültülmüş öznitelik uzayındaki verilerin bir kısmı sınıflandırıcıyı eğitmek, bir kısmı ise sınıflandırıcıyı test etmek için kullanılmaktadır. Sınıflandırıcı olarak literatürde En Yakın k Komşu, Destek Vektör Makinesi, Gauss Karışım Modeli, Yapay Sinir Ağları ve Karar Ağaçları gibi pek çok yapı kullanılmaktadır [42]. Sınıflandırıcının performansını ölçmek için literatürde birçok yöntem mevcut olsa da en sık kullanılanlar doğru sınıflandırma başarımı yüzdesi ve karışıklık matrisleridir. Bir sınıflandırıcıdan beklenen temel özellik, genelleştirmenin uygun şekilde yapılmasıdır. Sınıflandırıcı, eğitim aşamasında öznitelik uzayında farklı sınıfları ayırmakta kullanacağı eğrileri belirler. Bu eğri belirleme işleminde verilerin uzaydaki dağılımdan yola çıkarak eğri uydurma (curve fitting) işlemini uygular. Eğri uydurma işlemi aşamasında aşırı uydurma (overfitting) veya alt uydurma (underfitting) olması durumunda sınıflandırıcı genelleştirme işlemini yeterince

gerçekleştiremez ve performans kayıpları oluşur. Aşırı uydurma, alt uydurma ve ideal uydurma örneği Şekil 3.2’de görülmektedir. Bu tip eğri uydurma sorunlarından kaçınmak ve bu sorunların varlığı durumunda tespitini sağlamak amacıyla k parçalı çapraz geçерleme yöntemi uygulanmaktadır [41-42]. Çapraz geçерleme yapılırken öncelikle eldeki veri seti k adet eşit büyüklükte parçaya ayrılır. Bu k veri setinin her biri sırasıyla bir kez test aşamasında kullanılır. Test için kullanılmayan (k-1) adet veri seti ise sınıflandırıcının eğitim aşamasında kullanılır. Genel performans ise k adet sınıflandırma işleminin ortalaması alınarak hesaplanır [42]. Çapraz geçерleme, eldeki tüm verilerin hem eğitim hem de test aşamasında kullanılmasını sağladığı için eldeki veritabanı farklı şekillerde eğitim ve test olarak ikiye ayrıldığında performansta ne denli deęişim gerçekleştiğinin görülmesini sağlar [42].



Şekil 3.1 Sınıflandırma algoritmalarının genel yapısı



Şekil 3.2 (a) Alt uydurma (b) İdeal uydurma (c) Aşırı uydurma [43]

Bu bölümde, bir önceki bölümde üretilen radar benzetim verileri üzerinden ön işleme öznitelik çıkarma ve öznitelik seçme çalışmaları gerçekleştirilmiştir. Literatürde


sunulan radar hedef sınıflandırma algoritmaları genellikle 3 temel aşamadan oluşmaktadır. Bu aşamalar, ham veriye bir BZFA tekniğinin uygulanması, BZFA verisinden çeşitli özniteliklerin çıkarılması ve bu öznitelikler üzerinden sınıflandırma algoritmasının çalıştırılmasıdır. Şekil 3.1’de belirtilen aşamalardan ön işleme ve ileri işleme literatürdeki radar çalışmalarında genellikle ihmal edilmektedir.

Önceki bölümlerde de ayrıntıları verildiği üzere literatürde en sık kullanılan BZFA çıktısı, ham radar verisi üzerinde KZFD uygulanarak elde edilen spektrogramlardır. Ön işleme aşamasında öznitelik çıkarma öncesi spektrogram üzerinde gürültü temizleme, parazit yansıma bastırma gibi performans artırıcı çalışmalar yapılabilir. Öznitelik çıkarma aşaması, incelenen veriyi temsil eden istatistikî bilginin spektrogramdan çıkarıldığı aşamadır. İnsanın yürüme hareketine ait bir verinin spektrogramından hedefin radara göre hareket hızı, yürüme frekansı ve hedeften dönen sinyalin maksimum Doppler kayması gibi bilgiler öznitelik olarak çıkarılabilmektedir. İleri işleme aşaması, çıkarılan özniteliklerden en fazla başarıyı veren öznitelik alt kümesinin tespit edildiği aşamadır. Sınıflandırma aşaması, eldeki veri setinin eğitim ve test olarak iki parçaya ayrılarak sınıflandırıcının performansının ölçüldüğü aşamadır.

Önceki bölümde parazit yansıma ve gürültü de içeren ham radar verisine KZFD uygulanarak spektrogramlar elde edilmişti. Bu bölümde elde edilen spektrogramlar üzerinde ön işleme ve öznitelik çıkarma çalışmaları gerçekleştirilmiştir. Ön işleme aşaması, parazit yansıma bastırma, yeniden ölçeklendirme, Doppler belirsizliği çözümlemesi, bölütleme ve gürültü temizleme aşamalarını içermektedir. Öznitelik çıkarma aşaması ise hareketi temsil eden eğrilerin spektrogram üzerinden hesaplanması ve bu eğrilerin üzerinden istatistikî hesaplamalar yapılarak özniteliklerin elde edilmesi çalışmalarını kapsamaktadır.

Ön işleme aşamasının ilk adımı spektrogram üzerindeki parazit yansımaların bastırılmasıdır. Önceki bölümde de gözlenildiği üzere parazit yansımanın güçlü bileşenleri 0 m/s değerine karşılık gelen Doppler hücrelerine ve etrafındaki birkaç hücreye yayılmaktadır. Parazit yansıma verileri üzerinde yapılan incelemede parazit yansıma sinyalinin gücünün %95’den fazlasının genellikle  $\pm 0,4$  m/s bandında yer aldığı görülmüştür. Spektrogram üzerinde  $\pm 0,4$  m/s bandı filtrelenerek parazit

yansıma sinyalinin spektrogram üzerindeki etkisi kaldırılmıştır. Şekil 2.17’de görülen spektrograma parazit yansıma bastırma işlemi uygulandıktan sonra elde edilen spektrogram Şekil 3.3’de görülmektedir.




Şekil 3.3 Parazit yansıma bastırma sonrası elde edilen spektrogram

Yeniden ölçeklendirme, spektrogramdaki piksel değerlerinin (0-255) değer aralığına eşleştirilmesidir. Spektrogram üzerinde görüntü işleme tekniklerinin sorunsuz kullanılabilmesi için yapılması gerekmektedir. Yeniden ölçeklendirme yapılırken öncelikle spektrogram verisindeki minimum ve maksimum genlik değerleri (min ve max) belirlenir. Daha sonra yeniden ölçeklendirme sonucunda minimum değerinin 0, maksimum değerinin 255 olması için spektrogramdaki her bir p pikselinin üzerinde

$$P_{yeni} = \frac{255(p - \min)}{\max - \min} \quad (3.1)$$


formülü uygulanarak yeniden ölçeklendirme işlemi gerçekleştirilir. Şekil 3.3’de verilen spektrograma yeniden ölçeklendirme işleminin uygulanması ile edilen spektrogram Şekil 3.4’de görüldüğü gibidir.



Şekil 3.4 Yeniden ölçeklendirme işlemi sonucunda oluşan spektrogram

Hedeften yansıyarak dönen sinyalde radarın maksimum ölçülebilir Doppler değerinin üzerinde bileşenler varsa bu bileşenler katlanarak olması gerekenden farklı Doppler hücrelerine düşerler. Bu duruma Doppler belirsizliği denilmektedir [1]. Şekil 3.5 (a)'da Doppler belirsizliği içeren insana ait koşma verisinin spektrogramı görülmektedir. Şekilde insan koşarken bacakların hareketinin çok hızlı olması nedeniyle belirsizlik oluşmuş ve bacaklardan dönen bileşenler negatif frekanslara katlanmıştır. Öznitelik çıkarmada yanlış sonuçlar alınmasına yol açabileceği için bu belirsizliğin olabildiğince kaldırılması gerekmektedir. Bu nedenle, Doppler belirsizliğinin çözülmesi için bir yöntem geliştirildi. Öncelikle spektrogram üzerinde negatif ve pozitif hızlardaki toplam güç değeri hesaplandı. Şayet pozitif hızlardaki toplam güç daha fazla ise hedefin ana bileşenlerinin pozitif frekanslarda olduğu ve negatif frekanslardaki bileşenlerin katlanma sonucu olduğu varsayımı kuruldu. Spektrogramın negatif enerjilerden oluşan kısmı kesilerek pozitif enerjilerden oluşan kısmın üzerine eklendi ve dikey eksen için yeniden numaralandırma işlemi gerçekleştirildi. Şayet negatif hızlardaki toplam güç daha fazla ise pozitif hızlara denk gelen spektrogram parçası kesilip negatif hızların altına eklendi ve dikey eksen uygun şekilde yeniden numaralandırıldı. Özetle, spektrogram üzerinde basit bir kaydırma yapılarak Doppler belirsizliği çözümü işlemi

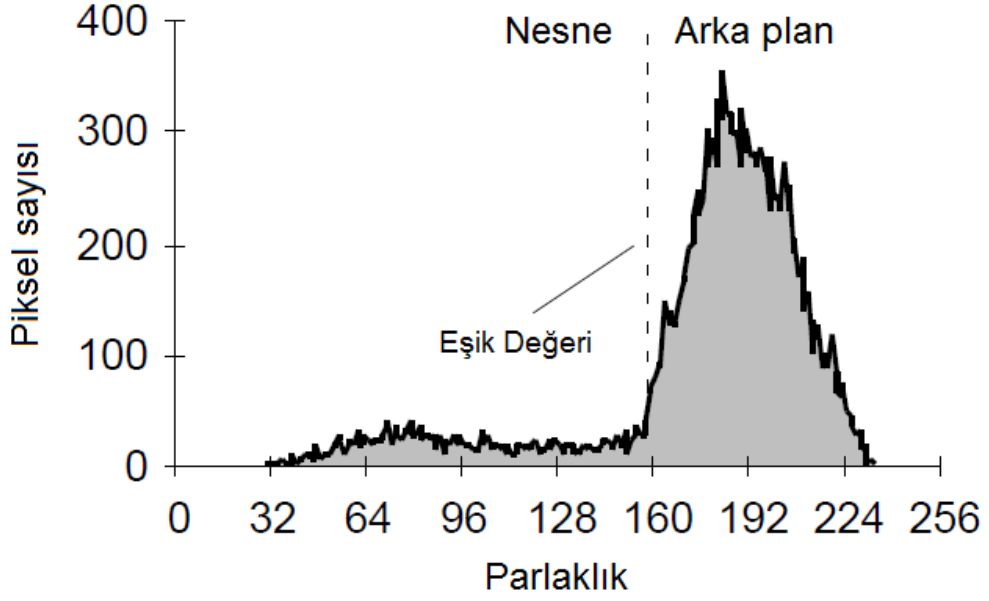
gerçekleştirildi. Şekil 3.5 (b)'de Doppler belirsizliği çözümü işleminin sonucu gösterilmektedir.



Şekil 3.5 (a) Doppler belirsizliği içeren insan koşması spektrogramı (b) Doppler belirsizliği çözümlenmiş spektrogram

Doppler belirsizliğinin giderilmesinin ardından elde edilen spektrogram üzerinde bölütleme işlemi uygulanmıştır. Bölütleme, spektrogram üzerinde hedeften gelen yansımanın ve diğer yansımaların ayrıldığı aşamadır. Görüntü işleme alanında nesne tespit algoritmalarında sıklıkla kullanılan bir yöntemdir. Bölütleme algoritmaları farklı yöntemlerle çalışsa da genellikle görüntünün histogramını inceleyerek arka plan ve nesnenin ayrılabilmesi için bir eşik değeri belirlerler. Bu eşik değeri, Şekil 3.6'da da görüldüğü gibi nesne ve arka planın ayrılmasını sağlayan pikselin değeridir.

Bu çalışma kapsamında otomatik eşik değeri bulma yöntemlerinin en sık kullanılanlarından biri olan eş veri eşikleme (isodata thresholding) metodu kullanılmıştır [44]. Bu metod, başlangıçta (0-255) aralığının orta noktası olan 128 değerini ilk eşik değeri olarak atar. İlk eşik değerinden büyük olan pikseller arka plan pikseli, küçük olan pikseller ise nesneye ait olan pikseller olarak kabul edilir. Daha



Şekil 3.6 Görüntü histogramı üzerinde eşik değeri, nesne bölgesi ve arka bölgesinin temsili olarak gösterilmesi [44]


sonra arka plan bölgesindeki tüm piksel değerlerinin ortalaması ve nesne bölgesindeki tüm piksel değerlerinin ortalaması hesaplanır. Yeni eşik değeri olarak bu iki ortalamanın ortalaması atanır. Aynı işlemler yeni eşik değeri ile tekrardan yapılır. Yeni hesaplanan eşik değeri bir önceki turda hesaplanan değer ile aynı çıkana kadar bu döngü tekrarlanır. Eşik değeri bulunduktan sonra, eşik değerinin altında kalan pikseller nesne, üstünde kalan pikseller ise arka plan olarak kabul edilir.

Eş veri eşikleme algoritmasına girdi olarak Şekil 3.7 (a)'da görülen spektrogram girildiğinde algoritmadan elde edilen çıktı Şekil 3.7 (b)'de görülmektedir. Algoritmanın çıktısı ikili (binary) bir görüntü olup hedef hareketine ait pikseller 0, arka plana ait pikseller ise 1 değeri ile gösterilmiştir. Bu görüntüde de görülebileceği üzere hedef hareketi arka plandan başarılı şekilde ayrılmıştır fakat bir miktar gürültü de hedef olarak belirlenmiştir.

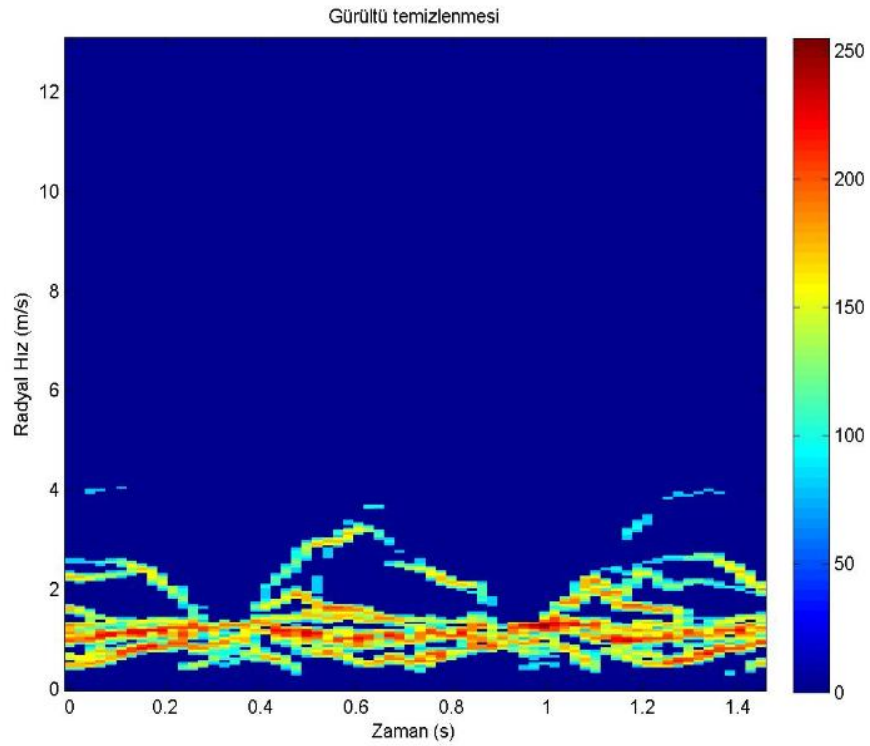
Eş veri eşikleme sonrası spektrogram üzerinde kalan gürültüyü temizlemek için spektrogram yatayda 16 satırlık parçalara bölünerek her bir parçaya düşen toplam güç miktarının spektrogram üzerindeki toplam güce oranı hesaplanmıştır. Bu oran şayet (1/16) değerinden küçük ise o parçadaki tüm piksel değerleri 0'a çekilmiş, büyük ise bir işlem uygulanmamıştır. Geliştirilen bu basit gürültü temizleme



yöntemi, Şekil 3.7 (b)'de görülen görüntüye uygulandığında elde edilen sonuç Şekil 3.8'de görülmektedir. Yöntemin bölütleme sonrası gürültüleri temizlemede oldukça etkili olduğu görülmüştür.



Şekil 3.7 (a) Eş veri eşiklemesi algoritmasına girdi olarak verilen spektrogram (b) Eş veri eşikleme algoritmasının çıktısı




Şekil 3.8 Gürültü temizleme işleminin ardından elde edilen spektrogram

Ön işleme aşaması ile spektrogram üzerinde performans artırmaya yönelik işlemler yapıldıktan sonra öznitelik çıkarma işlemine geçilmektedir. Öznitelik çıkarma, verinin üzerinden veriyi temsil edecek istatistikî bilgilerin çıkarılmasıdır. Öznitelik çıkarma sayesinde veri kendi boyutundan çok daha küçük olan öznitelik uzayı ile temsil edilebilir. Sınıflandırma fonksiyonları da bu küçük öznitelik uzayı üzerinde çalışacağı için işlem yükü oldukça azalır. Literatürde yapılan incelemede mikro-Doppler temelinde sınıflandırma yapan birçok çalışmada hareketi temsil eden zarfların öznitelik hesaplamasında kullanıldığı görüldü. İnsan için bu zarflar genellikle ana gövdenin hareketini temsil eden gövde eğrisi, kol ve bacakların ileri doğru ve geriye doğru hareketlerini temsil eden alt zarf ve üst zarftır [3-4, 45-46]. Bu çalışma kapsamında da öncelikle spektrogramlar üzerinden bu üç zarfın çıkarılması hedeflendi. Bu zarfların hesaplanması için literatürde önerilen metotlardan [45] nolu kaynakta sunulan yüzdellikler (percentiles) metodunun zarfların çıkarılması için uygulanması kararlaştırıldı. Bu metot, spektrogram üzerinde sütun sütun gezerek her bir zarfın o sütundaki elemanını hesaplar. Bu elemanların hesaplanabilmesi için her bir sütunun birikimli genlik dağılımı

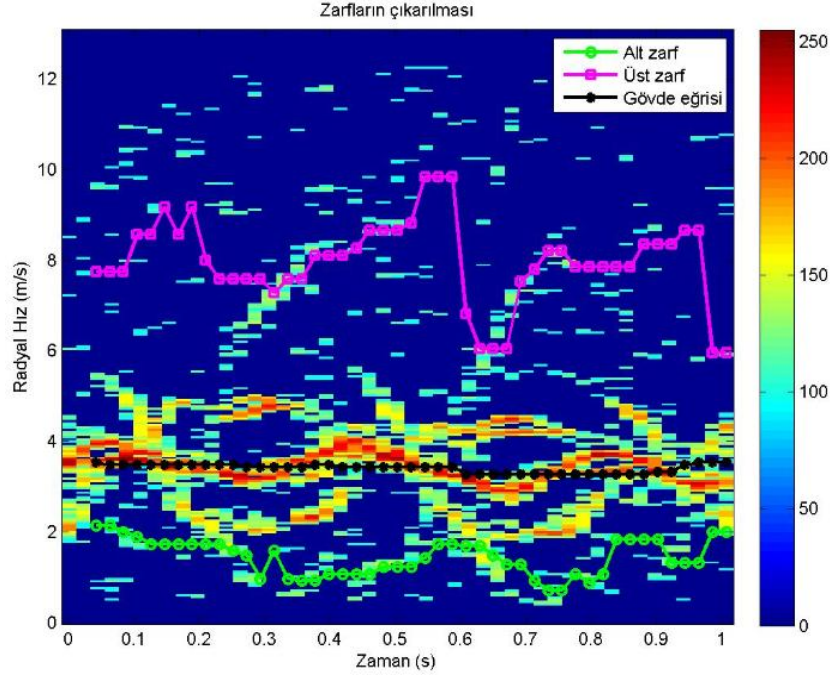
$$P(v,t) = \frac{\sum_{v=v \min}^v s(v,t)}{\sum_{v=v \min}^{v \max} s(v,t)} \quad (3.2)$$

formülüyle hesaplanabilmektedir. Formülde  $v$  radyal hız değerini,  $t$  zamanı ve  $s$  spektrogramdaki güç değerlerini tutan matrisi temsil etmektedir.  $v_{\min}$  ifadesi spektrogramın dikey eksenindeki minimum hız değerini,  $v_{\max}$  ifadesi ise spektrogramın dikey eksenindeki maksimum hız değerini belirtmektedir. Her bir sütun için  $P(u(t),t) = 0.97$  değeri üst zarfı;  $P(m(t),t) = 0.5$  değeri merkez zarfı (gövde eğrisini);  $P(a(t),t) = 0.03$  değeri alt zarfı temsil eden noktayı hesaplamak için kullanılmaktadır. Şekil 3.9'da parazit yansıma ve ön işleme çalışmaları yapıldığında elde edilen üç zarf görülmektedir.



Şekil 3.9 Spektrogram üzerinden çıkarılan zarfların gösterilmesi

Şekil 3.9’da çıkarılan zarflar incelendiğinde zarfların hareketi büyük oranda doğru takip ettiği göze çarpmaktadır. Şayet ön işleme kısmında yapılan işlemlerden parazit yansıma bastırma ve gürültü temizleme çalışmaları yapılmazsa elde edilen zarflar Şekil 3.10’da görülmektedir. Şekilde de görülebileceği gibi zarflar hedef salınımlarını tam olarak takip edememiş ve sapmalar oluşmuştur. Bu durum, zarflar üzerinden hesaplanacak özniteliklerin değerlerinde de sapmalar oluşturacağından sınıflandırma performansını düşürecektir. Bu nedenle, ön işleme aşamasında yapılan işlemlerin doğru seçilmesi ve uygulanması son derece önemlidir.



Şekil 3.10 Parazit yansıma bastırma ve gürültü temizleme ön işleme aşamaları uygulanmadığında çıkarılan zarflar

Alt zarf, üst zarf ve gövde eğrisinin hesaplanmasının ardından bu zarflar üzerinden istatistikî hesaplamalar yapılarak öznitelikler çıkarıldı. Bu çalışma kapsamında çıkarılan öznitelikler Çizelge 3.1’de sunulmuştur. Çizelgede sunulan özniteliklerin bir kısmı daha önce literatürde yer alan çalışmalarda da kullanılmıştır [3-4, 45-46].


Çizelgedeki ilk 20 öznitelik doğrudan üst zarf, alt zarf ve gövde eğrisi kullanılarak hesaplanmaktadır. 21 numaralı öznitelik olan Doppler sinyal gücünün birimlenmiş standart sapması, ön işleme sonucu elde edilen spektrogramda hedefe ait piksellerin güç değerinin standart sapmasının ortalamasına bölünmesi sonucu elde edilmektedir. 22 numaralı öznitelik olan hareket sıklığını hesaplamak için üst zarftan kendi ortalaması çıkarıldıktan sonra Fourier Dönüşümü hesaplandı. Fourier Dönüşümü’nün en yüksek genliğe ulaştığı frekans değeri hareketin sıklığı olarak alındı. Son öznitelik ise spektrogramda gövde eğrisi üzerinde bulunan piksellerin toplamının görüntüdeki tüm piksellerin toplamına bölümü ile hesaplandı.

Çizelge 3.1 Çıkarılan özniteliklerin listesi

Öznitelik No	Öznitelik İsmi
1	Üst zarfın ortalaması
2	Üst zarfın değişintisi
3	Alt zarfın ortalaması
4	Alt zarfın değişintisi
5	Gövde eğrisinin ortalaması
6	Gövde eğrisinin değişintisi
7	(Üst zarf – Alt zarf) ortalaması
8	(Üst zarf – Alt zarf) değişintisi
9	(Üst zarf – Gövde eğrisi) ortalaması
10	(Üst zarf – Gövde eğrisi) değişintisi
11	(Gövde eğrisi – Alt zarf) ortalaması
12	(Gövde eğrisi – Alt zarf) değişintisi
13	(Üst zarf + Alt zarf) ortalaması
14	(Üst zarf + Alt zarf) değişintisi
15	(Üst zarf + Gövde eğrisi) ortalaması
16	(Üst zarf + Gövde eğrisi) değişintisi
17	(Gövde eğrisi + Alt zarf) ortalaması
18	(Gövde eğrisi + Alt zarf) değişintisi
19	Toplam bant aralığı değeri (maksimum(Üst zarf) – minimum(Alt zarf))
20	Mikro-Doppler etkileri ihmal edildiğinde bant toplam bant aralığı değeri (minimum(Üst zarf) – maksimum(Alt zarf))
21	Doppler sinyal gücünün birimlenmiş standart sapması
22	Hareketin sıklığı
23	Gövde eğrisinin enerjisinin toplam enerjiye oranı

Bu bölümde gerçekleştirilen çalışmaların özeti Şekil 3.11’de sunulmuştur. Ön işleme kısmında spektrogramdan öznitelik değerlerinin daha doğru hesaplanmasını sağlamak için gürültü temizleme, Doppler belirsizliği çözümlemesi gibi spektrogram üzerinde iyileştirme ve düzeltme çalışmaları yapılmıştır. Öznitelik çıkarma kısmında ise literatürde de daha önce kullanılmış olan hareketi tanımlayan zarfların

ıkarılmasının ardından bu zarflar zerinden istatistik hesaplamalar yapılarak znelikler oluřturulmuřtur. Her bir veriden 23 adet znelik hesaplanarak verinin artık bu vektr ile temsil edilmesi saėlanmıřtır.



řekil 3.11 Bu blmde yapılan alıřmaların zeti

#### 4. ÖZNETELİK SEÇME ve SINIFLANDIRMA

Bir önceki bölümde gerçekleştirilen öznitelik çıkarma aşamasının tamamlanması ile her bir veriyi temsilen 23 adet ondalıklı sayıdan oluşan öznitelik vektörü elde edildi. Bu özniteliklerin hangilerinin kullanılmasının sınıflandırmada maksimum oranda performans sağlayacağını belirlemek için öznitelik seçme aşamasının çalışmaya dâhil edilmesi uygun görülmüştür.

Öznitelik uzayının boyutu arttıkça sınıflandırma algoritmalarının başarımının bir noktaya kadar artarken bu nokta sonrasında azalması literatürde çokça deneyimlenmiş bir durumdur [41-42]. Bu durumun literatürde bilinen ismi boyutun lanetidir (curse of dimensionality) ve sabit sayıdaki ölçüm uzayında öznitelik uzayının boyutu arttıkça sınıflandırıcının doğru tahmin kabiliyetinin düşeceğini belirtir [42]. Sadece öznitelik uzayının boyutunun artması değil, öznitelik uzayında birbiriyle yüksek ilintili özniteliklerin bulunması da sınıflandırma performansını düşürmektedir [42]. Bu nedenle, öznitelik seçme, sınıflandırma performansı için son derece kritik bir adımdır. Bu çalışmada, öznitelik seçme için literatürde sıkça kullanılan yöntemlerden biri olan Ardışık İleri Yönlü Kayan Öznitelik Seçimi metodu [47-48] kullanılmıştır. Literatürde yapılan araştırmada Ardışık İleri Yönlü Kayan Öznitelik Seçimi metodunun öznitelik seçme metotları içinde en yüksek başarıma sahip olan metotlardan biri olduğu görülmüştür [49]. Bu metot, mevcut öznitelik uzayı içinden belirlenen bir değerlendirme kıstasına göre en iyi öznitelik altkümesini seçmektedir. Ardışık İleri Yönlü Kayan Öznitelik Seçimi algoritmasının sözde kodu Şekil 4.1’de sunulmuştur [48]. Algoritma girdi olarak öznitelik uzayının büyüklüğünü ( $n$ ) ve sınıflandırma algoritmasını ( $J$ ) almaktadır. Çıktı olarak ise 1’den  $n$ ’e kadar olan alt küme uzunlukları için bulunan en iyi öznitelik altkümelerini ( $B$ ) dönmektedir.


Öznitelik seçme, seçim algoritmasının değerlendirme kıstasına göre iki farklı şekilde yapılabilir. Süzgeç (Filter) Metodu olarak bilinen ilk yöntemde değerlendirme kıstası kullanılacak olan sınıflandırıcıdan bağımsızdır ve uzaklık temelli (Öklit, Bhattacharya, Gini indeksi vb.), bilgi kuramı bazlı (entropi, bilgi kazancı vb.),

<b>function</b> SFFS( $n, J$ )	<i>Farklı uzunluklar için en iyi öznelik altkümelerini döner (<math>B</math>)</i>
<b>begin</b>	
$S := \overbrace{(0, \dots, 0)}^n$ ;	<i>Boş küme ile başla</i>
$k := 0$ ;	
$B := \emptyset$ ;	<i>B yapısının tanımlanması</i>
<b>while</b> $k < n$	<i>Farklı uzunlukların tamamı bitirilene kadar devam et</i>
$R := \emptyset$ ;	<i>Farklı dalların değerlendirme sonuçlarının tutulduğu yapının tanımlanması</i>
<b>for each</b> $\{j \mid S_j = 0\}$	<i>Her bir olası dal için tekrarla</i>
$S' := S$ ;	
$S'_j := 1$ ;	<i><math>j</math> numaralı değişkenin eklenmesi</i>
$R(j) := J(S')$ ;	<i>Bu dalın değerlendirilmesi</i>
<b>end</b> ;	
$k := k + 1$ ;	
$j := \operatorname{argmin} R(\cdot)$ ;	<i>En iyi dalın bulunması</i>
<b>if</b> $R(j) \geq J(B(k))$	<i>Bu dal, bu boyutta bulunan en iyi dal mı?</i>
$S := B(k)$ ;	<i>Hayırsa, daha önce bulunan en iyi dala dön</i>
<b>else</b>	
$S_j := 1$ ;	<i>Evetse, bu dalı al</i>
$B(k) := S$ ;	<i>Yeni bulunan altkümeyi kaydet</i>
$t := 1$ ;	
<b>while</b> $k > 2 \wedge t = 1$	<i>Daha iyi bir altküme bulunana kadar geriye doğru arama yap</i>
$R := \emptyset$ ;	<i>Farklı dalların değerlendirme sonuçlarının tutulduğu yapının tanımlanması</i>
<b>for each</b> $\{j \mid S_j = 1\}$	<i>Her bir olası dal için tekrarla</i>
$S' := S$ ;	
$S'_j := 0$ ;	<i><math>j</math> numaralı dalı kes</i>
$R(j) := J(S')$ ;	<i>Bu dalın değerlendirilmesi</i>
<b>end</b> ;	
$j := \operatorname{argmin} R(\cdot)$ ;	<i>En iyi dalın bulunması</i>
<b>if</b> $R(j) < J(B(k - 1))$	<i>(<math>k-1</math>) boyutunda daha iyi bir altküme bulunmuş muydu?</i>
$k := k - 1$ ;	<i>Evetse, geriye dönük arama yap</i>
$S_j := 0$ ;	
$B(k) := S$ ;	<i>Yeni bulunan altkümeyi kaydet</i>
<b>else</b>	
$t := 0$ ;	<i>Hayırsa, geriye dönük aramayı durdur</i>
<b>end</b> ;	
<b>end</b> ;	
<b>end</b> ;	
<b>return</b> $B$ ;	
<b>end</b> ;	

Şekil 4.1 Ardışık İleri Yönlü Kayan Öznelik Seçimi algoritmasının sözde kodu [48]



bağımlılık kaynaklı (ilinti, fazlalık derecesi vb.) veya tutarlılık ölçütü (minimum öznitelik eğilimi vb.) gibi değerlendirme metrikleri kullanılarak öznitelik seçimi yapılmaktadır [50]. Süzgeç Metodu'nun adımlarını gösteren akış diyagramı Şekil 4.2'de görülmektedir.



Şekil 4.2 Süzgeç Metodu ile öznitelik seçme işlemi [50]

Sargı (Wrapper) Metodu olarak bilinen diğer yöntem ise kullanılması planlanan sınıflandırıcının performansını baz alarak öznitelik seçim işlemini gerçekleştirmektedir. Sargı Metodu'nda farklı öznitelik altkümeleri için sınıflandırıcının doğru sınıflandırma yüzdesi hesaplanarak en iyi sonucun alındığı öznitelik altkümesi seçilmektedir. Sargı Metodu'nun adımlarını gösteren akış diyagramı Şekil 4.3'de görülmektedir.



Şekil 4.3 Sargı Metodu ile öznitelik seçme işlemi [50]

Süzgeç Metodu, sınıflandırıcının kullanmakta olduğu modeli içinde barındırmadığı için Sargı Metodu'na oranla daha kötü performans vermektedir [42, 50]. Sargı Metodu ise her seferinde sınıflandırıcı ile eğitim ve test aşamalarını tekrarladığından hesaplama maliyeti Süzgeç Metodu'na göre daha yüksektir. Bu çalışmada, daha başarılı sonuç vermesinden dolayı Süzgeç Metodu'nun kullanılması tercih edilmiştir. Değerlendirme kıstası olarak sınıflandırma algoritmasının doğru sınıflandırma yüzdesi kullanılmıştır.

Öznitelik seçiminin yapılmasının ardından seçilen özniteliklerin performansının değerlendirilmesi için sınıflandırma aşamasına geçilmektedir. Literatürde sınıflandırma için Yapay Sinir Ağı, Destek Vektör Makinesi, En Yakın k Komşu ve

Gauss Karışım Modeli gibi birçok farklı teknik kullanılmaktadır [41-42]. Bu çalışmada sınıflandırma için En Yakın 3 Komşu ve Sınıflandırma Ağacı olmak üzere iki farklı sınıflandırıcı kullanılmıştır. Veri setinin %50'si sınıflandırıcının eğitimi %50'si ise testi için kullanılmıştır. Ayrıca, genelleştirmenin doğru yapılabildiğini kontrol etmek için de k parçalı çapraz geçiş yapılmıştır [42]. Çapraz geçişlemenin k değeri literatürdeki çalışmalarda genellikle 10 alınmaktadır [41]. Ancak bu çalışmada veri seti 10 parçaya bölüldüğünde test için araç ve sürünme sınıflarında 4 veri kalmaktadır. Sadece 4 veri üzerinden yapılan sınıflandırmadan güvenilir sonuçlar elde etmenin mümkün olmamasından dolayı bu çalışmada 5 parçalı çapraz değerlendirme yapılarak sonuçlar elde edilmesi kararlaştırılmıştır. Bu durumda, veri seti 110 veriden oluşan 5 parçaya ayrılmış ve sırasıyla parçalardan biri test için diğer dördü sınıflandırma için kullanılarak 5 farklı sınıflandırma sonucu elde edilmiştir.


Bu çalışma kapsamında, sınıflandırma performansının hedefin hareket açısına, SGO'ya ve sınıflandırıcı tipine göre değişimi değerlendirilmiştir. İnsan koşma verilerinin genellikle 0,7 saniye ve 1,5 saniye arası bir uzunlukta olması nedeniyle veri süresine bağlı değerlendirme yapılamamıştır. Çünkü 1,5 saniyeden daha kısa süreli veriler, emekleme ve sürünme hareketleri için hareketi tanımlayan salınımların görülemediği durumlara denk gelebilmektedir. Salınımların olmaması, hareketin tipi ile ilgili elde bilginin olmadığı duruma karşılık geldiği için bu veriler üzerinden sınıflandırma çalışmaları yapmak doğru olmayacaktır. Veritabanındaki en uzun süreli koşma verisinin 1,5 saniye olması sebebiyle bu sürenin tüm veriler için üst limit olması uygun görülmüştür. 1,5 saniyeden uzun veriler 1,5 saniyelik parçalara bölünerek kullanılmıştır.

## **4.1 Hedefin Doğrudan Radara Doğru Hareket Ettiği Durum İçin Sınıflandırma**

### **4.1.1 Gürültü ve Parazit Yansıma Etkileri İhmal Edildiğinde Sınıflandırma**

Gürültünün olmadığı, hedefin doğrudan radara doğru hareket ettiği ve En Yakın 3 Komşu algoritmasının uygulandığı durum için 2 adet öznitelik kullanıldığında (15 ve 19) doğru sınıflandırma başarımı %85,97 olmaktadır. Bu durum için özniteliklerin sınıflara göre dağılımı Şekil 4.4'de görüldüğü gibidir. Şekilden de görülebileceği

üzere yürüme ve iki insan yürüme sınıfları birbirine oldukça yakın konumdadır ve sınıflandırma esnasında karışma ihtimalleri vardır. Aynı durum, koşma ve iki insan koşma sınıfları için de geçerlidir. Sürünme ve emekleme sınıfları da yine birbirine oldukça yakın konumlanmıştır. Araç sınıfı ise diğer sınıflardan bağımsız bir dağılım göstermektedir.



Şekil 4.4 15 ve 19 numaralı özniteliklerin sınıflara göre dağılımı

Maksimum doğru sınıflandırma performansına 6 öznitelik (2, 10, 15, 19, 21 ve 22) kullanıldığı durumda ulaşılmaktadır ve doğru sınıflandırma başarımı değeri %90,65'dir. Maksimum başarımın elde edildiği durum için karışıklık matrisi Çizelge 4.1'de sunulmuştur. Matris incelendiğinde sınıfların büyük oranda doğru şekilde ayrıldığı görülmektedir. İki insan koşma ve koşma sınıfı hedefleri ile iki insan yürüme ve yürüme sınıflarına ait hedeflerde bir miktar karışmanın söz konusu olduğu görülmektedir. Temelde aynı hareketlerden türetilmelerinden dolayı buradaki karışmanın normal olduğu söylenebilir.


Çizelge 4.1 En yüksek başarımın elde edildiği 6 öznitelik (2, 10, 15, 19, 21 ve 22) ile En Yakın 3 Komşu sınıflandırıcısı kullanıldığında oluşan karışıklık matrisi

	Yürüme	Koşma	Emekleme	Sürünme	İki insan yürüme	İki insan koşma	Araç
Yürüme	97	0	0	0	0	0	0
Koşma	1	28	0	1	0	5	0
Emekleme	0	0	35	0	1	0	0
Sürünme	0	0	5	14	0	0	0
İki insan yürüme	7	0	0	0	28	0	0
İki insan koşma	0	3	0	0	0	32	0
Araç	0	0	0	3	0	0	18

Sınıflandırıcıda aşırı uydurma olup olmadığını anlamak için maksimum performansın alındığı 6 öznitelik kullanılan durum için 5 parçalı çapraz geçişleme yapılmıştır. Bu durumda elde edilen doğru sınıflandırma başarımları %82,73, %89,09, %85,45, %92,73 ve %90,91'dir. Ortalamada %88,18 doğru sınıflandırma başarımına ulaşılmıştır. Buradan da görüldüğü gibi çapraz geçişleme sonucu ortalama elde edilen sonuç ile veri seti ikiye ayrılarak sınıflandırma yapıldığında elde edilen sonuç birbirine oldukça yakındır. Bu da söz konusu öznitelikler ile sınıflandırıcı eğitildiğinde genelleştirmenin başarılı şekilde yapıldığını göstermektedir.

Gürültünün olmadığı ve hedefin doğrudan radara doğru hareket ettiği durum için En Yakın 3 Komşu sınıflandırıcısı yerine Sınıflandırma Ağacı yöntemi kullanılarak sınıflandırma yapılırsa 2 adet öznitelik kullanıldığında (15 ve 23) doğru sınıflandırma başarımı %83,45 olmaktadır. Bu durum için özniteliklerin sınıflara göre dağılımı Şekil 4.5'de görüldüğü gibidir. Şekilden de görülebileceği üzere sürünme ve emekleme verileri 15 numaralı öznitelik ile doğrudan ayrılabilir. Yürüme ile iki insan yürüme ve koşma ile iki insan koşma sınıfları ise daha çok 23

numaralı öznitelik yardımıyla birbirinden ayrılabilir. Araç sınıfı ise sadece 23 numaralı öznitelik kullanılarak neredeyse diğer tüm sınıflardan ayrılabilir.



Şekil 4.5 15 ve 23 numaralı özniteliklerin sınıflara göre dağılımı

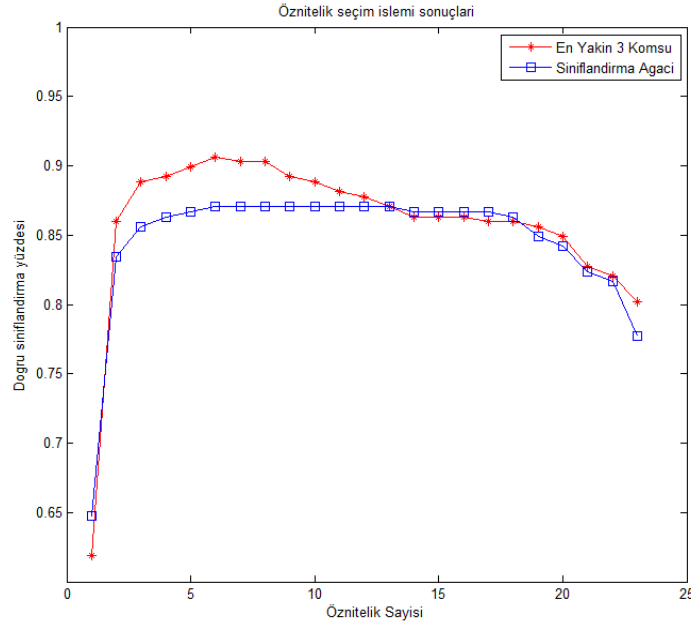
Maksimum başarıma ise yine 6 öznitelik (3, 5, 8, 18, 22 ve 23) kullanıldığı durumda ulaşılmaktadır ve doğru sınıflandırma başarımları %87,05'dir. Bu durum için karışıklık matrisi Çizelge 4.2'de sunulmuştur. Matris incelendiğinde sınıfların büyük oranda doğru şekilde ayrıldığı görülmektedir. En yakın komşu algoritmasında yapılarına benzer şekilde 5 parçalı çapraz geçiş sınıflandırma ağacı algoritmasına da uygulandığında doğru sınıflandırma başarımları değerleri %76,36, %87,27, %83,64, %92,73 ve %90 olarak elde edildi. Ortalamada elde edilen doğru sınıflandırma başarımları %86'dır ve yukarıda elde edilen %87,05 değerine oldukça yakındır. Bu da kullanılan özniteliklerin sınıflandırma ağacı için iyi derecede genelleştirme sağladığını göstermektedir.

Çizelge 4.2 En yüksek başarımın elde edildiği 6 öznitelik (3, 5, 8, 18, 22 ve 22) ile Sınıflandırma Ağacı sınıflandırıcısı kullanıldığında oluşan karışıklık matrisi

	Yürüme	Koşma	Emekleme	Sürünme	İki insan yürüme	İki insan koşma	Araç
Yürüme	95	0	1	0	0	0	1
Koşma	1	19	0	1	0	14	0
Emekleme	0	0	36	0	0	0	0
Sürünme	0	0	3	16	0	0	0
İki insan yürüme	6	0	0	0	29	0	0
İki insan koşma	1	5	0	0	0	28	1
Araç	0	0	1	1	0	0	19

Sınıflandırma Ağacı sınıflandırıcısı ile elde edilen sonuçlar En Yakın 3 Komşu sınıflandırıcısında elde edilenlere benzer olsa da seçilen öznitelikler değişiklik göstermektedir. Bu da sınıflandırıcıların kullandığı değerlendirme metriğinin farklı olmasından dolayı beklenen bir durumdur. En Yakın 3 Komşu sınıflandırıcısı Öklit Mesafesi'ni karşılaştırarak tahmin yaparken Sınıflandırma Ağacı sınıflandırıcısı düğüm (node) ayırma kistası olarak Gini'nin Çeşitlilik İndeksi'ni (Gini's Diversity Index) kullanmaktadır. İki sınıflandırıcının tahmin için farklı metrikleri kullanması, farklı öznitelikleri seçmelerine neden olmaktadır. Sınıflandırma Ağacı, En Yakın 3 Komşu sınıflandırıcısında en iyi performansın elde edildiği 6 öznitelik (2, 10, 15, 19, 21 ve 22) ile çalıştırıldığında doğru sınıflandırma performansı %74,82 olmaktadır. En Yakın 3 Komşu sınıflandırıcısı, Sınıflandırma Ağacı'nda en iyi performansın elde edildiği 6 öznitelik (3, 5, 8, 18, 22 ve 23) ile çalıştırılırsa doğru sınıflandırma performansı %68,71 olmaktadır. Buradan da görülebileceği üzere farklı sınıflandırıcılar farklı metrikler üzerinden çalıştığı için en iyi çalışacakları öznitelikler birbirinden farklı olabilmektedir.

Öznelik seçme işlemi sırasında farklı öznelik altkütmesi boyutları için en iyi performans değerleri hesaplanmaktadır. En Yakın 3 Komşu ve Sınıflandırma Ağacı sınıflandırıcıları için elde edilen öznelik sayısına göre sınıflandırma başarımı grafiği Şekil 4.6’da görülmektedir. Grafik incelendiğinde en büyük performans sıçramasının her iki sınıflandırıcı için de iki öznelik kullanılması durumuna geçerken yaşandığı görülmüştür. Bu nedenle, iki öznelik kullanılması durumu için sınıflandırma sonuçları ve grafikleri bu çalışma kapsamında sunulmuştur. Maksimum sınıflandırma performansına ise iki sınıflandırıcı da 6 öznelik kullanması durumunda ulaşmaktadır. Maksimum performansın elde edildiği durumlar için de çıktılar bu çalışma kapsamında yukarıda detaylı olarak sunulmuştur. Grafikten de görülebileceği üzere öznelik sayısı 6’dan fazla olduğunda eklenen yeni öznelikler performansta iyileşme meydana getirmemiştir. Öznelik uzayının boyutu 18 ve üzerine çıktığında ise yeni eklenen özneliklerin başarımı düşürmeye başladığı gözlemlenmiştir.




Şekil 4.6 Farklı öznelik sayıları ile elde edilen en iyi sınıflandırma başarımlarının grafiği

#### 4.1.2 Gürültü ve Parazit Yansıma Etkileri İhmal Edilmediğinde Sınıflandırma

Gürültü, radar sinyal işlemede tespit performansını kısıtlayan en önemli etkenlerden biridir. Gürültünün sınıflandırma performansı üzerindeki etkisini incelemek için Şekil 4.7’de aynı verinin 34 dB, 24 dB, 14 dB ve 4 dB SGO değerleri için elde edilen

spektrogramları sunulmuştur. 34 dB ve 24 dB verileri incelendiğinde hedeften dönen sinyalin spektrogramda hâlâ görülebildiği göze çarpmaktadır. 14 dB ve 4 dB verilerinde ise hedefin gövde eğrisi dışında kalan bileşenleri seçilemez hale gelmiştir. Bu çalışma kapsamında 14 dB, 24 dB ve 34 dB verileri üzerinden sınıflandırma çalışmaları yapılmıştır. 4 dB verisinde hedefin imzası tamamen seçilemez hale geldiği için bu veri üzerinde değerlendirme yapılmamıştır. Örnek spektrogramlardan da görülebileceği üzere 14 dB ve 4 dB gürültülü spektrogramlar, mikro-Doppler bazlı sınıflandırma yapmak için çok uygun değildir.



Şekil 4.7 (a) 34 dB SGO (b) 24 dB SGO (c) 14 dB SGO (d) 4 dB SGO için aynı verinin spektrogramı

Ön işleme aşamasında uygulanan ve sınıflandırma performansını artırması hedeflenen yöntemlerden parazit yansımaya bastırma ve gürültü temizleme işlemlerinin etkisini ölçmek için önceki bölümde gürültüsüz veriler ile yapılan sınıflandırma işlemleri öncelikle 34 dB SGO değerine sahip veriler üzerinden denendi. 34 dB'lik



verilerde parazit yansıma bastırma ve gürültü eleme işlemleri iptal edilirse bir önceki bölümde En Yakın 3 Komşu sınıflandırıcısının maksimum başarımının elde edildiği 6 öznitelik (2, 10, 15, 19, 21 ve 22) içeren durumda sınıflandırma başarımı %79,14 olarak elde edilmektedir. Aynı durum için gürültü eleme ve parazit yansıma bastırma işlemleri uygulandığında ise başarımın %86,33 olduğu görülmüştür. Benzer çalışma sınıflandırma ağacı için tekrarlandığında daha önceki bölümde maksimum başarımın elde edildiği 6 öznitelik (3, 5, 8, 18, 22 ve 23) için parazit yansıma bastırma ve gürültü eleme işlemleri iptal edilirse doğru sınıflandırma başarımı %72,66 olmaktadır. Aynı durum için gürültü eleme ve parazit yansıma bastırma işlemleri uygulandığında ise başarım %82,01'e çıkmaktadır.

24 dB SGO değeri için aynı işlemler yapıldığında En Yakın 3 Komşu sınıflandırıcısında parazit yansıma bastırma ve gürültü eleme işlemleri iptal edildiğinde sınıflandırma başarımı %73,74 olurken, iptal edilmediğinde %85,61 olduğu görülmüştür. Sınıflandırma Ağacı sınıflandırıcısında ise başarımın parazit yansıma bastırma ve gürültü eleme uygulanmadığında %71,94, uygulandığında %81,29 olduğu görülmüştür.

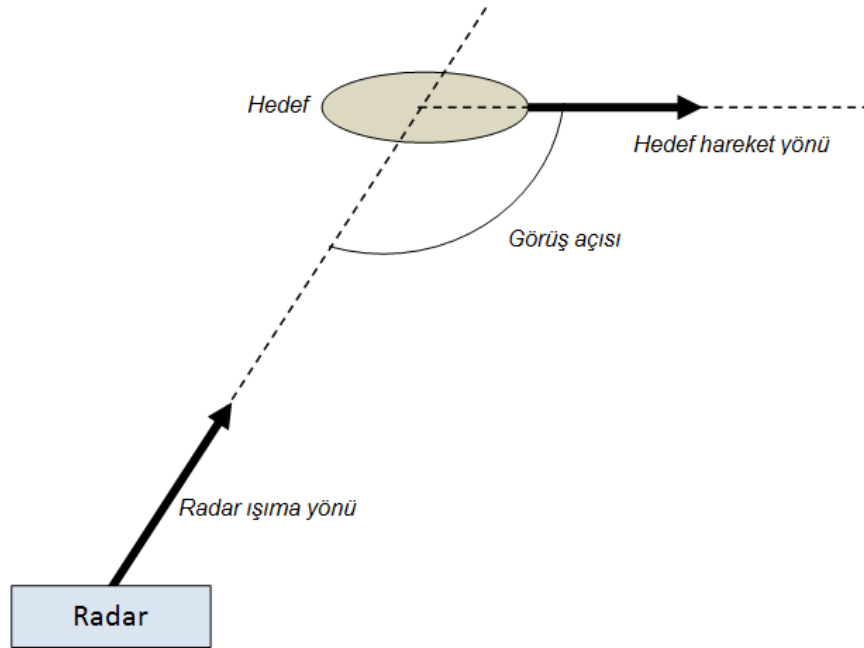
14 dB SGO için işlemler tekrarlandığında En Yakın 3 Komşu algoritmasında parazit yansıma ve gürültü temizleme işlemleri ihmal edildiğinde başarımın %53,96, ihmal edilmediğinde ise %65,47 olduğu görülmüştür. Sınıflandırma ağacında ise başarımın parazit yansıma bastırma ve gürültü temizleme işlemlerinin uygulanması ile %52,52'den %66,19'a çıkmıştır.

Bu bölümde elde edilen sonuçlarda da görülebileceği üzere ön işleme aşamasında yapılan çalışmalar sayesinde sinyal üzerinde gürültünün olduğu durumda da sınıflandırma performansında önemli bir iyileştirme elde edilmiştir. Öznitelik çıkarılırken gürültülü durumlarında dikkate alınarak daha gürbüz öznitelik çıkarma yapılması, sınıflandırma başarımında yaşanacak performans kaybını önemli miktarda azaltabilmektedir.

## 4.2 Hedefin Radara Açılı Hareket Ettiği Durum İçin Sınıflandırma


### 4.2.1 Gürültü ve Parazit Yansıma Etkileri İhmal Edildiğinde Sınıflandırma

Hedefin radara göre hareket açısının değişmesi görüş açısının değişmesine dolayısıyla hedefin Doppler imzasının değişmesine neden olmaktadır. Görüş açısı, Şekil 4.8’de de görülebileceği üzere hedefin hareket yönü ile radarın ışıma yönü arasındaki açıdır. Hedefin radara göre hareketinin radyal bileşeni küçüldükçe hedefin Doppler imzası, hareket hakkında daha az bilgi sunar hâle gelmektedir. Hedefin radara açılı hareketler de yapabileceğini göz önünde bulundurarak veri tabanındaki hedeflerin Şekil 4.9’da bir veri için örneği görüldüğü gibi radara göre  $0^\circ$ ,  $30^\circ$ ,  $60^\circ$  ve  $90^\circ$  açılar ile hareket ettiği durumlar için de benzetimler oluşturuldu. Spektrogramlarda görülebileceği üzere  $30^\circ$ ’den daha büyük açılı hareketlerde hedefin mikro-Doppler salınımlarında önemli kayıplar yaşanmaktadır.



Şekil 4.8 Görüş açısının gösterimi

Açılı durumların benzetime dâhil edilmesi için 4 farklı açıdaki benzetimler yapıldığından veri tabanının büyüklüğü 4 katına çıktı. Bu benzetim verileri üzerinden sınıflandırma çalışmaları yapılırken yine eldeki verinin %50’si eğitim %50’si ise test amacıyla kullanılmak üzere ayrıldı.



Şekil 4.9 İnsan yürüme hareketinin radara göre açısı (a)  $0^\circ$  (b)  $30^\circ$  (c)  $60^\circ$  (d)  $90^\circ$  olduğunda elde edilen spektrogramları

Sınıflandırıcı olarak En Yakın 3 Komşu kullanıldığı durumda 2 öznitelik (15 ve 19) kullanılması durumunda %68,17 doğru hedef sınıflandırma başarımına ulaşıldı. En iyi sınıflandırma başarımına ise 8 öznitelik (4, 8, 10, 12, 13, 15, 18 ve 19) kullanılması ile ulaşıldı ve %72,48 oranında sınıflandırma başarımı elde edildi. Bu durumu gösteren karışıklık matrisi Çizelge 4.3’de sunulmuştur. Karışıklık matrisi incelendiğinde koşma sınıfı ile iki insan koşma sınıfı arasındaki karışma miktarının arttığı göze çarpmaktadır. Açılı hareketlerde sürünme ve emekleme sınıfları da daha az ayırt edilebilir hâle gelmiştir. Sınıflandırıcıda aşırı uydurma etkilerinin olup olmadığını incelemek için 5 parçalı çapraz geçiş yapıldığında %71,36, %81,82, %76,59, %74,09 ve %70,68 sınıflandırma başarımı elde edildiği görüldü. Ortalamada elde edilen değer %74,91 olup %72,48 değerine oldukça yakındır.

Çizelge 4.3 Açılı yürüme durumları da benzetime dâhil edildiğinde En Yakın 3 Komşu sınıflandırıcısı ile elde edilen maksimum performansa ait karışıklık matrisi

	Yürüme	Koşma	Emekleme	Sürünme	İki insan yürüme	İki insan koşma	Araç
Yürüme	335	10	18	12	10	2	1
Koşma	19	47	4	6	4	58	2
Emekleme	15	2	113	12	1	1	0
Sürünme	2	5	32	34	2	0	1
İki insan yürüme	37	8	1	0	91	3	0
İki insan koşma	7	11	4	0	9	109	0
Araç	0	1	1	2	2	1	77

Sınıflandırıcı olarak sınıflandırma ağacı kullanıldığı durumda ise yine aynı 2 öznitelik (15 ve 19) olması durumunda %67,99 sınıflandırma başarımı elde edildi. Maksimum sınıflandırma başarımına ise 7 öznitelik (1, 5, 7, 19, 21, 22 ve 23) kullanılması durumunda ulaşıldı ve %74,19 oranında hedefler doğru sınıflandırıldı. Bu duruma karşılık gelen karışıklık matrisi Çizelge 4.4’de görülmektedir. Karışıklık matrisi incelendiğinde hedefin doğrudan radara doğru hareket ettiği durumlarda birbirine karışmayan yürüme ve emekleme hareketlerinde birbirine karışmalar olduğu gözlemlendi. Bunun nedeni, yüksek açılardaki yürüme verilerinin düşük açılardaki emekleme verilerine bir hayli benziyor olmasıdır. Diğer hedef sınıflarındaki karışmaların benzer durumları açılı hareketlerde de görülmektedir. Daha önceki bölümlerde olduğu gibi 5 parçalı çapraz geçişleme ile sonuçlar oluşturulduğunda doğru sınıflandırma başarımı olarak %68,86, %80, %77,73, %75,23 ve %76,24 sınıflandırma başarımı elde edildi. Ortalamada elde edilen değer ise %75,59’dur ve bulunan %74,19 değerine oldukça yakındır.

Çizelge 4.4 Açılı yürüme durumları da benzetime dâhil edildiğinde Sınıflandırma Ağacı sınıflandırıcısı ile elde edilen maksimum performansa ait karışıklık matrisi

	Yürüme	Koşma	Emekleme	Sürünme	İki insan yürüme	İki insan koşma	Araç
Yürüme	294	3	56	18	17	0	0
Koşma	11	75	5	8	2	38	1
Emekleme	15	0	114	8	4	1	1
Sürünme	1	2	29	41	1	2	0
İki insan yürüme	21	2	8	7	102	0	0
İki insan koşma	0	15	3	2	2	118	0
Araç	0	0	3	0	0	0	81

#### 4.2.2 Gürültü ve Parazit Yansıma Etkileri İhmal Edilmediğinde Sınıflandırma

Açılı hareketler için de önceki bölümdekine benzer şekilde gürültü ve parazit yansımaların ihmal edilmediği durum için sınıflandırma işlemleri tekrarlandı. En Yakın 3 Komşu sınıflandırıcısı ile 34 dB SGO değerine sahip veriler üzerinden (4, 8, 10, 12, 13, 15, 18 ve 19) numaralı özniteliklerden oluşan öznitelik alt kümesi ile sınıflandırma çalışmaları tekrarlandı. Şayet gürültü temizleme ve parazit yansıma bastırma işlemleri uygulanmazsa elde edilen sınıflandırma başarımı, %64,12'dir. Aynı durumda önerilen gürültü ve parazit yansıma teknikleri uygulandığında ise elde edilen doğru sınıflandırma başarımı %68,88 olmaktadır. Benzer bir işlem gürültüsüz durumda en iyi sınıflandırma performansının elde edildiği (1, 5, 7, 19, 21, 22 ve 23) numaralı özniteliklerden oluşan öznitelik alt kümesi için Sınıflandırma Ağacı sınıflandırıcısı kullanılarak tekrarlandı. Parazit yansıma bastırma ve gürültü eleme ihmal edildiğinde doğru sınıflandırma başarımının %62,86 olduğu, ihmal edilmediğinde ise %69,15'a yükseldiği görüldü.

24 dB SGO deęerine sahip veriler üzerinden aynı alıřma tekrarlandığında řayet gürültü temizleme ve parazit yansımaya bastırma işlemleri uygulanmazsa En Yakın 3 Komşu sınıflandırıcısı ile elde edilen sınıflandırma başarımı %54,59'dur. Aynı durumda önerilen gürültü ve parazit yansımaya teknikleri uygulandığında ise elde edilen doğru sınıflandırma başarımı %67,81 olmaktadır. Sınıflandırma Ağacı sınıflandırıcısında ise önerilen düzeltme yöntemi uygulanmazsa doğru sınıflandırma başarımı %53,24, uygulanırsa %70,05 olmaktadır.

SGO deęeri 14 dB olan veriler ile benzer bir alıřma yapıldığında ise En Yakın 3 Komşu sınıflandırıcısında önerilen ön işleme yöntemleri kullanılmadığında doğru sınıflandırma başarımı %38,85'e kadar düşmektedir. Önerilen parazit yansımaya bastırma ve gürültü temizleme işlemleri uygulandığında ise başarımlar %52,34 olmaktadır. Benzer şekilde Sınıflandırma Ağacı sınıflandırıcısında ise başarımlar önerilen yöntem kullanılmadığında %36,96, kullanıldığında ise %48,56 olmaktadır.


### **4.3 Sınıflandırma Sonuçlarına Genel Bakış**

Bu bölümde elde edilen sınıflandırma başarımı sonuçları Çizelge 4.5'de özetlenmiştir. Sonuçlar incelendiğinde ön işleme aşamasında önerilen metodun sınıflandırma performansında %5 ile %15 arasında iyileştirmeler meydana getirdiđi görülmüştür. Ön işleme aşamasında uygulanan performans artırıcı teknikler sayesinde 24 dB gürültü olan veriler ile gürültü içermeyen verilerin sınıflandırma performansı arasındaki fark %5-%6 civarındadır. Bu deęerin gürültülü durumlar için performansta yaşanacak kayıp adına kabul edilebilir olduđu söylenebilir.

Bu bölümde yapılan alıřmalar, Şekil 4.10'da özetlenmiştir. Bir önceki bölümde elde edilen özniteliklerden Ardışık İleri Yönlü Kayan Öznitelik Seçimi metodu ile en iyi sınıflandırma performansını veren öznitelik altkümesi seçilmiştir. Sınıflandırma işleminde En Yakın 3 Komşu ve Sınıflandırma Ağacı olmak üzere iki farklı sınıflandırıcı kullanılmıştır. Sınıflandırma, gürültünün olduđu ve olmadığı durumlar için ve hedefin açılı hareketlerinin olup olmadığı durumlar için yapılmıştır. Ayrıca, ön işleme aşamasında sunulan iyileştirme ve düzeltme tekniklerinin sınıflandırma başarımına olan etkileri de incelenmiştir.

Çizelge 4.5 Bu bölümde elde edilen sınıflandırma sonuçları

	Sadece radara doğru olan hareketler için sınıflandırma yapılırsa		Radara 0°, 30°, 60° ve 90° açılar ile olan hareketler için sınıflandırma yapılırsa	
	En Yakın 3 Komşu Sınıflandırıcısı	Sınıflandırma Ağacı Sınıflandırıcısı	En Yakın 3 Komşu Sınıflandırıcısı	Sınıflandırma Ağacı Sınıflandırıcısı
Gürültü ve parazit yansıma olmayan veriler	%90,65	%87,05	%72,48	%74,19
34 dB SGO değerine sahip veride ön işleme aşaması uygulanmazsa	%79,14	%72,66	%64,12	%62,86
34 dB SGO değerine sahip veride ön işleme aşaması uygulanırsa	%86,33	%82,01	%68,88	%69,15
24 dB SGO değerine sahip veride ön işleme aşaması uygulanmazsa	%73,74	%71,94	%54,59	%53,24
24 dB SGO değerine sahip veride ön işleme aşaması uygulanırsa	%85,61	%81,29	%67,81	%70,05
14 dB SGO değerine sahip veride ön işleme aşaması uygulanmazsa	%53,96	%52,52	%38,85	%36,96
14 dB SGO değerine sahip veride ön işleme aşaması uygulanırsa	%65,47	%66,19	%52,34	%48,56



Şekil 4.10 Bu bölümde yapılan çalışmaların özeti



## 5. SONUÇ

### 5.1 Yorumlar

Bu çalışma kapsamında, mikro-Doppler tabanlı hedef sınıflandırma için benzetim tabanlı bir yöntem önerilmiştir. Çalışma kapsamında hedef modelleme, radar benzetimi, ön işleme, öznelik çıkarma, öznelik seçme ve sınıflandırma adımlarının tamamı gerçekleştirilmiştir. Radar benzetimi yapılırken literatürde ihmal edilen parazit yansıma bastırma ve gürültü bileşenleri de göz önünde bulundurulmuştur. Ön işleme aşamasında ise sınıflandırma başarımını artırmak için görüntü işleme tabanlı iyileştirme ve düzeltme teknikleri önerilmiştir. Öznelik seçme ve sınıflandırma performansları En Yakın 3 Komşu ve Sınıflandırma Ağacı sınıflandırıcıları üzerinden denenmiştir. Sınıflandırma performansı gürültüsüz durum için, gürültülü olup ön işleme yapılmayan durum için ve gürültü olup ön işleme yapılan durum için sunulmuştur. Ayrıca, hedefin tek açılı hareketlerinin yanı sıra farklı açılardaki hareketleri için de sonuçlar sunulmuştur.

Literatürdeki mikro-Doppler tabanlı sınıflandırma çalışmalarında genellikle ön işleme ve öznelik seçme adımları ihmal edilmektedir. Bu çalışmada önerilen ön işleme tekniklerinin sınıflandırma performansında %5 ile %15 arasında iyileştirme meydana getirebileceği görülmüştür. Gürültünün sınıflandırma başarımı üzerindeki etkilerinin son derece önemli olduğu da çıkarılan önemli sonuçlardan bir tanesidir. Bu nedenle, öznelikler hesaplanırken gürültülü durumlarında dikkate alınarak daha gürbüz öznelik hesaplama yöntemlerinin geliştirilmesi, sınıflandırma başarımında yaşanacak performans kaybını azaltabilmektedir.

Farklı iki sınıflandırıcı kullanılarak yapılan çalışmalar göstermiştir ki sınıflandırıcıların en iyi sonucu verdiği öznelik alt kümesi birbirinden farklı olabilmektedir. Sınıflandırıcıların farklı değerlendirme metriklerini kullanarak tahmin yapmaları bunun temel nedeni olarak öne çıkmaktadır. Bu nedenle, öznelik seçimi yapılırken sınıflandırıcının kullandığı modelin göz önünde bulundurulması büyük önem arz etmektedir.

## 5.2 Gelecek Çalışmalar

Bu çalışmada, mikro-Doppler bazlı sınıflandırma için benzetim tabanlı bir yöntem önerildi. Hedefin mikro-Doppler imzasının bir miktar da olsa görülebilmesi için gürültülü durumlarda 34 dB, 24 dB ve 14 dB SGO değeri üzerinden değerlendirmeler yapıldı. Bu çalışmanın devamında, mikro-Doppler imzalarının belirginliğini yitirdiği ancak hedefin gövdesinden dönen sinyalin hâlâ görülebildiği daha düşük SGO değerine sahip sinyaller için de sınıflandırma çalışmaları yapılabilir. Bu tip veriler için çıkarılabilecek öznelilikler incelenerek mikro-Doppler tabanlı olmasa da bir hedef sınıflandırma sistemi geliştirilebilir.

Radar ölçümlerinde genellikle elde edilen sinyalin SGO değeri bilinmektedir. Bu nedenle, öznelilik çıkarma ve sınıflandırma işlemleri sinyalin SGO değerine göre uyarlamalı olarak yapılabilir. Farklı SGO değerleri için farklı sınıflandırma algoritmaları geliştirilerek gelen sinyalin SGO değerine uygun sınıflandırıcı üzerinden hedef tipi belirlenebilir. SGO değerine göre sınıflandırmanın uyarlamalı yapılması literatürde dikkat çekmemiş önemli bir konudur.

Teknolojinin gelişmesi ve hareket yakalama sistemlerinin daha da yaygın olarak kullanılması ile hayvan hareketleri için de ücretsiz hareket yakalama verilerinin bulunabilmesi beklenmektedir. Hayvan hareketlerinin de radar benzetiminin yapılarak hedef veritabanının genişletilmesi, burada yapılan çalışmayı daha da etkili hale getirecektir.

## KAYNAKLAR

- [1] Chen, Victor, *The micro-Doppler effect in radar*, Artech House, 2011.
- [2] P. van Dorp, and F.C.A. Groen, Human walking estimation with radar, *IEE Proc. on Radar, Sonar, and and Navigation*, Vol. 150, Issue 5, October 2003, pp. 356-365.
- [3] Chen, Victor C., Tahmoush, David, Miceli, William J., *Radar Micro-Doppler Signature: Processing and Applications*, IET Digital Library, 2014.
- [4] Kim, Youngwook, and Hao Ling. "Human activity classification based on micro-Doppler signatures using an artificial neural network." *Antennas and Propagation Society International Symposium*, 2008. AP-S 2008. IEEE. IEEE, 2008.
- [5] Bryan, Jacob, and Youngwook Kim. "Classification of human activities on UWB radar using a support vector machine." *Antennas and Propagation Society International Symposium (APSURSI), 2010 IEEE*. IEEE, 2010.
- [6] Kim, Youngwook, and Hao Ling. "Human activity classification based on micro-Doppler signatures using a support vector machine." *Geoscience and Remote Sensing, IEEE Transactions on* 47.5 (2009): 1328-1337.
- [7] Molchanov, Pavlo, P., Astola, J., Egiazarian, K., Totsky, A., "Ground moving target classification by using DCT coefficients extracted from micro-Doppler radar signatures and artificial neuron network." *Microwaves, Radar and Remote Sensing Symposium (MRRS)*, 2011. IEEE, 2011
- [8] Raj, R. G., V. C. Chen, and R. Lipps. "Analysis of radar human gait signatures." *Signal Processing, IET* 4.3 (2010): 234-244.
- [9] Bryan, J. D., Kwon, J., Lee, N., Kim, Y., Application of ultra-wide band radar for classification of human activities, *IET Radar, Sonar & Navigation* 6.3 (2012): 172-179.
- [10] Molchanov, Pavlo O., P. O., Astola, J. T., Egiazarian, K. O., Totsky, A. V., Classification of ground moving targets using bicepstrum-based features extracted from Micro-Doppler radar signatures, *EURASIP Journal on Advances in Signal Processing* 2013.1 (2013): 1-13.
- [11] Bilik, Igal, Joseph Tabrikian, and Arnon Cohen. "GMM-based target classification for ground surveillance Doppler radar." *Aerospace and Electronic Systems, IEEE Transactions on* 42.1 (2006): 267-278.
- [12] Bjorklund, S., Tommy Johansson, and Henrik Petersson. "Evaluation of a micro-Doppler classification method on mm-wave data." *Radar Conference (RADAR), 2012 IEEE*. IEEE, 2012.
- [13] Yessad, Dalila, Amrouche, A., Debyeche, M., Djeddou, M., *Micro-Doppler classification for ground surveillance radar using speech recognition tools*, Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. Springer Berlin Heidelberg, 2011. 280-287.
- [14] Jahangir, M., K. M. Ponting, and J. W. O'loghlen. "A robust Doppler classification technique based on hidden Markov models." (2002): 162-166.
- [15] Smith, Graeme E., Karl Woodbridge, and Chris J. Baker. "Naïve Bayesian radar micro-Doppler recognition." *Radar, 2008 International Conference on*. IEEE, 2008.
- [16] Stove, A. G., and S. R. Sykes. "A Doppler-based automatic target classifier for a battlefield surveillance radar." (2002): 419-423.

- [17] Damarla, Thyagaraju, Bradley, M., Mehmood, A., Sabatier, J. M., Classification of animals and people ultrasonic signatures, *Sensors Journal*, IEEE 13.5 (2013): 1464-1472.
- [18] Bilik, Igal, Joseph Tabrikian, and Arnon Cohen. "Target classification using Gaussian mixture model for ground surveillance Doppler radar." *Radar Conference, 2005 IEEE International*. IEEE, 2005.
- [19] Molchanov, Pavlo, Harmanny, R. I., de Wit, J. J., Egiazarian, K., Astola, J., Classification of small UAVs and birds by micro-Doppler signatures, *International Journal of Microwave and Wireless Technologies* 6.3-4 (2014): 435-444.
- [20] Otero, Michael. "Application of a continuous wave radar for human gait recognition." *Defense and Security*. International Society for Optics and Photonics, 2005.
- [21] Yang, Yinan, Wenxue Zhang, and Chao Lu. "Classify human motions using micro-Doppler radar." *SPIE Defense and Security Symposium*. International Society for Optics and Photonics, 2008.
- [22] Fei, Li, Binke, H., Hang, Z., & Hao, D., "Human gait recognition using micro-doppler features." *Millimeter Waves (GSMM), 2012 5th Global Symposium on*. IEEE, 2012.
- [23] Orović, Irena, Srdjan Stanković, and Moeness Amin. "A new approach for classification of human gait based on time-frequency feature representations." *Signal Processing* 91.6 (2011): 1448-1456.
- [24] Nanzer, Jeffrey A., and Robert L. Rogers. "Bayesian classification of humans and vehicles using micro-Doppler signals from a scanning-beam radar." *Microwave and Wireless Components Letters, IEEE* 19.5 (2009): 338-340.
- [25] Liaqat, S., Khan, S. A., Ihsan, M. B., Asghar, S. Z., Ejaz, A., & Bhatti, A., Automatic recognition of ground radar targets based on target RCS and short time spectrum variance, *Innovations in Intelligent Systems and Applications (INISTA), 2011 International Symposium on*. IEEE, 2011.
- [26] Tivive, Fok Hing Chi, Abdesselam Bouzerdoum, and Moeness G. Amin. "A human gait classification method based on radar Doppler spectrograms." *EURASIP Journal on Advances in Signal Processing* 2010 (2010): 10.
- [27] Li, Jingli, et al. "Automatic classification of human motions using Doppler radar." *Neural Networks (IJCNN), The 2012 International Joint Conference on*. IEEE, 2012.
- [28] Balleri, A., K. Chetty, and K. Woodbridge. "Classification of personnel targets by acoustic micro-Doppler signatures." *IET radar, sonar & navigation* 5.9 (2011): 943-951.
- [29] Zhang, Zhaonian, and Andreas G. Andreou. "Human identification experiments using acoustic micro-Doppler signatures." *Micro-Nanoelectronics, Technology and Applications, 2008. EAMTA 2008. Argentine School of*. IEEE, 2008.
- [30] Molchanov, Pavlo, Astola, J., Egiazarian, K., & Totsky, A., Classification of ground moving radar targets by using joint time-frequency analysis, *2012 IEEE Radar Conference (RADAR)*. 2012.
- [31] Molchanov, Pavlo, Vinel, A., Astola, J., & Egiazarian, K., Radar frequency band invariant pedestrian classification, *Radar Symposium (IRS), 2013 14th International*. Vol. 2. IEEE, 2013.

- [32] Sundar Ram, Shobha, Radar Simulation of Human Activities in Non Line-of-Sight Environments, *Doktora Tezi, The University of Texas at Austin*, 2009.
- [33] Karabacak, C.; Gurbuz, S.Z.; Gurbuz, A.C., "Radar simulation of human micro-Doppler signature from video motion capture data," Signal Processing and Communications Applications Conference (SIU), 2013 21st , vol., no., pp.1,4, 24-26 April 2013
- [34] <http://mrl.snu.ac.kr/~mdb/session/>, Erişim tarihi: 04/03/2014
- [35] [http://accad.osu.edu/research/mocap/mocap\\_data.htm](http://accad.osu.edu/research/mocap/mocap_data.htm), Erişim tarihi: 04/03/2014
- [36] <http://mocap.cs.cmu.edu>, Erişim tarihi: 04/03/2014
- [37] <http://motion.cs.bilkent.edu.tr>, Erişim tarihi: 04/03/2014
- [38] Lawrence, N. D., Mocap toolbox for matlab, *Available on-line at http://www.cs.man.ac.uk/neill/mocap* (2011)
- [39] Dilsaver, Benjamin W., Experiments with GMTI Radar Using Micro-Doppler, *Doktora Tezi, Brigham Young University*, 2013.
- [40] Kulemin, Gennadiĭ Petrovich, and David Knox Barton, Millimeter-wave radar targets and clutter, *Artech House*, 2003.
- [41] Dougherty, Geoff. Pattern recognition and classification: an introduction, *Springer Science & Business Media*, 2012.
- [42] Theodoridis S., and K. Koutroumbas, Pattern Recognition, *Academic Press*, New York (1999).
- [43] [http://msrt.njust.edu.cn/staff/rxia/ml/slides/Lec11\\_generative\\_discriminative.pdf](http://msrt.njust.edu.cn/staff/rxia/ml/slides/Lec11_generative_discriminative.pdf)
- [44] Young, Ian T., Jan J. Gerbrands, and Lucas J. Van Vliet, Fundamentals of Image Processing, *Delft, The Netherlands: Delft University of Technology*, 1998.
- [45] Van Dorp, P., and F. C. A. Groen, Feature-based human motion parameter estimation with radar, *Radar, Sonar & Navigation, IET 2.2* (2008): 135-145.
- [46] Karabacak, Cesur, Sevgi Zubeyde Gurbuz, and Ali Cafer Gurbuz, Automatic human activity classification using radar, *Signal Processing and Communications Applications Conference (SIU), 2014 22nd. IEEE*, 2014.
- [47] Pudil, Pavel, Jana Novovicová, and Josef Kittler, Floating search methods in feature selection, *Pattern recognition letters 15.11* (1994): 1119-1125
- [48] Guyon, Isabelle, ed. Feature extraction: foundations and applications. Vol. 207. Springer, 2006.
- [49] Jain, A., Zongker, D., Feature selection: evaluation, application, and small sample performance, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol.19, no.2, pp.153, 158, Feb 1997
- [50] Rajeev Srivastava, S. K. Singh, K. K. Shukla (Editors). *Research Developments in Computer Vision and Image Processing: Methodologies and Applications*. IGI Global, USA, (Expected Publication: September' 2013).

## ÖZGEÇMİŞ

Soyadı, adı : KARABACAK, Cesur  
Uyruđu : T.C.  
Dođum tarihi ve yeri : 1988, Çorum  
Medeni hali : Bekar  
Telefon : -  
Faks : -  
e-mail : cesurkarabacak@gmail.com

### Eđitim

Derece	Eđitim Birimi	Mezuniyet tarihi
Lisans	TOBB ETÜ Elektrik-Elektronik Mühendisliđi	Ađustos 2012
Lisans	TOBB ETÜ Bilgisayar Mühendisliđi	Kasım 2013

### İş Deneyimi

Yıl	Yer	Görev
08.2012-11.2013	TOBB ETÜ	Yüksek Lisans Öğrencisi
11.2013-	Meteksan Savunma	RF Sistem Mühendisi

### Yabancı Dil

İngilizce

## YAYINLAR

- Karabacak, C., Gürbüz, S. Z., Guldogan, M. B., Gürbüz, A. C., "Multi-aspect angle classification of human radar signatures." *SPIE Defense, Security, and Sensing*. International Society for Optics and Photonics, 2013.
- Gurbuz, Sevgi Zubeyde, Tekeli, B., Yuksel, M., Karabacak, C., Gurbuz, A. C., Guldogan, M. B., "Importance ranking of features for human micro-Doppler classification with a radar network." *Information Fusion (FUSION), 2013 16th International Conference on*. IEEE, 2013.
- Karabacak, Cesur, S. Z. Gurbuz, and A. C. Gurbuz. "Radar simulation of human micro-Doppler signature from video motion capture data." *Signal Processing and Communications Applications Conference (SIU), 2013 21st*. IEEE, 2013.
- Gurbuz, S. Z., Tekeli, B., Karabacak, C., Yuksel, M., "Feature selection for classification of human micro-Doppler." *Microwaves, Communications, Antennas and Electronics Systems (COMCAS), 2013 IEEE International Conference on*. IEEE, 2013.
- Erol, Baris, Karabacak, C., Gurbuz, S. Z., Gurbuz, A. C., "Simulation of human micro-Doppler signatures with Kinect sensor." *Radar Conference, 2014 IEEE*. IEEE, 2014.
- Cagliyan, Bahri, Cesur Karabacak, and Sevgi Zubeyde Gurbuz. "Human activity recognition using a low cost, COTS radar network." *Radar Conference, 2014 IEEE*. IEEE, 2014
- Karabacak, Cesur, Sevgi Zubeyde Gurbuz, and Ali Cafer Gurbuz. "Automatic human activity classification using radar." *Signal Processing and Communications Applications Conference (SIU), 2014 22nd*. IEEE, 2014
- Cagliyan, Bahri, Cesur Karabacak, and Sevgi Zubeyde Gurbuz. "Indoor human activity recognition using BumbleBee radar." *Signal Processing and Communications Applications Conference (SIU), 2014 22nd*. IEEE, 2014.
- Erol, Baris, 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*. IEEE, 2014.