

**RADARLA İNSAN HAREKET SINIFLANDIRMA İÇİN
BİLGİ-KURAMSAL TABANLI ÖZNİTELİK SEÇİMİ**

BÜRKAN TEKELİ

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ**

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

ARALIK 2014

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

Bürkan TEKELİ tarafından hazırlanan RADARLA İNSAN HAREKET SINIFLANDIRMA İÇİN BİLGİ-KURAMSAL TABANLI ÖZNİTELİK SEÇİMİ adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

Yrd. Doç. Dr. Sevgi Zübeyde GÜRBÜZ

Tez Danışmanı

Tez Jüri Üyeleri

Başkan : Yrd. Doç. Dr. Ayşe Melda YÜKSEL TURGUT _____

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.

Bürkan TEKELİ

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 – Aralık 2014

Bürkan TEKELİ

**RADARLA İNSAN HAREKET SINIFLANDIRMA İÇİN BİLGİ-KURAMSAL
TABANLI ÖZNETELİK SEÇİMİ**

ÖZET

Hareketli bir hedefin parçalarının salınımı ve titreşiminden kaynaklanan mikro-Doppler izleri, sadece araçlar, tanklar, helikopterler, hatta hayvanlar gibi değişik tip hedeflerin sınıflandırılması ve ayırt edilmesi için değil aynı zamanda insan hareket tiplerinin tespiti ve ayırt edilmesi içinde kullanılmaktadır. Bu amaçla mikro-Doppler izlerinin sınıflandırılması ile ilgili yapılan çalışmalarda birçok öznetelik çıkarılarak önerilmiştir. Ancak önerilen özneteliklerin tamamının sınıflandırma işlemi için kullanılması optimum başarımlar elde edilmesini garantilememektedir. Yüksek bir başarımlar tüm öznetelikler arasından özneteliklerin bir kısmının seçimi ile oluşturulan bir küme ile sağlanabilir. Bu tez kapsamında insan hareket sınıflandırma problemi için tüm özneteliklerin kullanılması ile elde edilen başarımlar ve öznetelik seçimi yoluyla oluşturulan kümedeki özneteliklerin başarımları verilerek bu durum gösterilmiştir. Daha belirgin bir şekilde açıklanırsa, karşılıklı bilgi miktarı tabanlı öznetelik seçimi algoritmaları, optimal başarımları veren özneteliklerin karşılaştırılması ve incelenmesi için kullanılmışlardır. Elde edilen sonuçlar, açının bilinmesi durumunda mRMR algoritmasının daha iyi sınıflandırma başarımları verdiğini ve açının bilinmemesi durumunda MIFS-U algoritmasının daha iyi çalıştığını göstermektedir. Öznetelik seçimi kullanıldığı zaman başarımların tüm özneteliklerin kullanılması durumuna göre %1.1 artmaktadır. Bu tez kapsamında yapılan çalışma değişen çalışma durumlarında uyarlanabilen öznetelik seçimi için bir temel sağlamaktadır.

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

University : TOBB Economics and Technology University
Institute : Institute of Natural and Applied Sciences
Science Programme : Electrical and Electronics Engineering
Supervisor : Assist. Prof. Dr. Sevgi Zübeyde GÜRBÜZ
Degree Awarded and Date : M.Sc. – December 2014

Bürkan TEKELİ

**INFORMATION THEORY BASED FEATURE SELECTION FOR HUMAN
ACTIVITY CLASSIFICATION WITH RADAR**

ABSTRACT

The micro-Doppler signatures resulting from vibration or rotation of parts of a moving target can be used to not just classify different targets like vehicles, tanks, helicopters, or even animals, but also to classify and recognize different activities. For this purpose, a plethora of features have been extracted and proposed in the literature for classification of micro-Doppler signatures. Yet, use of all features does not guarantee the optimal classification performance. A high classification performance or success rate can be better obtained using a subset of features, which are selected among all possible features. In this thesis, this situation is demonstrated by comparing results on classification performance obtained with not only a selected subset of features, but also using all features for human activity classification. More specifically, information theory based feature selection algorithms are examined and compared for selecting features having optimal classification performance. Feature selection is considered for changing radar-target geometries aspect angle as well. Results Show that when the aspect angle is known mRMR algorithm yields higher correct classification rates, while for unknown angles MIFS-U algorithm performs better. When feature selection is used %1,1 improvement is achieved over when all features are used. Work provides basis for adaptive selection of features under varying operational conditions.

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

TEŐEKKÜR

Bana her zaman güvenen, desteklerini hiçbir zaman esirgemeyen ve beni bu günlere getiren sevgili aileme Őukran, saygı ve teŐekkürlerimi sunarım. Ayrıca alıŐmalarım boyunca, deđerli yardım ve katkılarıyla beni yönlendiren hocalarım Yrd. Do. Dr. Sevgi Zübeyde GÜRBÜZ, Yrd. Do. Dr. AyŐe Melda YÜKSEL TURGUT ve Do. Dr. Ali Cafer GÜRBÜZ'e, yardımlarını alıŐmalarım boyunca hiç esirgemeyen arkadaşım Cesur KARABACAK'a, kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Elektrik Elektronik Mühendisliđi Bölümü öğretim üyelerine teŐekkürü bir bor bilirim. TOBB Ekonomi ve Teknoloji Üniversitesi'nde Z-11laboratuvarında ve Radar Sistemleri Laboratuvarında beraber alıŐtığım ve yardımlarını hiçbir zaman esirgemeyen arkadaşlarıma ayrıca teŐekkürlerimi sunarım.

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

İÇİNDEKİLER

ÖZET.....	iii
ABSTRACT.....	iv
TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ	ix
KISALTMALAR	xi
SEMBOL LİSTESİ.....	xii
1 GİRİŞ.....	1
1.1 Tarihçe.....	1
1.2 Motivasyon.....	2
1.3 Problem Tanımı.....	4
1.4 Tez Kapsamı.....	7
1.5 Tez Organizasyonu.....	8
2 TEORİ.....	9
2.1 Radar Mesafe Denklemi.....	9
2.2 Radar Menzili.....	9
2.3 Doppler Etkisi.....	11
2.4 Bilgi Kuramı.....	13
3 LİTERATÜR ARAŞTIRMASI.....	17
3.1 Mikro-Doppler ile ilgili çalışmalar.....	17
3.1.1 Mikro-Doppler Gösterimi.....	17
3.1.2 Mikro-Doppler ile Sınıflandırma.....	20
3.2 Öznitelik Seçimi İle İlgili Yöntemler.....	24
3.2.1 Wrapper Metodu.....	25
3.2.1.1 İleri Yönlü Wrapper.....	25

3.2.1.2	Geri Yönlü Wrapper.....	27
3.2.2	Filtre Metodu.....	29
3.3	Kullanılan Benzetimler.....	33
3.3.1	Boulic Modeli	34
3.3.2	CMU Veri Tabanı ile Oluşturulan Model	37
3.3.3	Kinect ile Oluşturulan Model.....	40
4	VERİLERİN, ÖZİNİTELİK ÇIKARIMI ve SINIFLANDIRMA İŞLEMİNİN TANITILMASI.....	43
4.1	CMU Benzetim Verilerinin Tanıtılması.....	43
4.2	Çıkarılan Özneliklerin Tanıtımı	54
4.2.1	Gövde Doppler Frekansının Ortalaması	54
4.2.2	Gövde Salınımının Bant Genişliği	55
4.2.3	Üst Zarfın Maksimum Değeri	56
4.2.4	Alt Zarfın Minimum Değeri.....	57
4.2.5	Toplam Doppler Bant Genişliği.....	58
4.2.6	Üst Zarfın Ortalama Değeri	59
4.2.7	Alt Zarfın Ortalama Değeri.....	60
4.2.8	Alt ve Üst Zarf Ortalamaları Arasındaki Bant Genişliği	61
4.2.9	Alt ve Üst Zarf Ortalamalarının Ortalaması.....	62
4.2.10	Alt Zarfın Minimum ve Üst Zarfın Maksimum Değerleri Ortalaması	63
4.3	Öznelik Seçimi	64
4.4	Sınıflandırma İşleminin Tanıtımı	65
5	SONUÇLAR.....	68
5.1	Hedefle Radar Arasındaki Açının Bilinmesi Durumu.....	68
5.2	Hedefle Radar Arasındaki Açının Bilinmemesi	75
5.3	Sınıflandırma Karşılaştırma Matrisi	83
6	SONUÇ ve GELECEK ÇALIŞMALAR.....	86
	KAYNAKÇA.....	88
	ÖZGEÇMİŞ	93

ÇİZELGELERİN LİSTESİ

Çizelge 5.1: Bilinen açı değeri için yöntemlerin seçtiği özniteliklere göre sınıflandırma başarımları.....	69
Çizelge 5.2: Hedefle radar arasındaki açı biliniyorken en sık seçilen öznitelikler (● işareti özniteliğin seçildiğini, ○ işareti ise özniteliğin seçilmediğini göstermektedir.)	74
Çizelge 5.3: Hedefle radar arasındaki görüş açısının bilinmediği durumda yöntemlerin seçtiği özniteliklere göre sınıflandırma başarımları	77
Çizelge 5.4: Hedefle radar arasındaki açı bilinmiyorken en sık seçilen öznitelikler (● işareti özniteliğin seçildiğini, ○ işareti ise özniteliğin seçilmediğini göstermektedir.)	80
Çizelge 5.5: Bilinen açı durumunda hareketlerin 0° ve 90° için karşılaştırılma matrisleri	84
Çizelge 5.6: Bilinmeyen açı durumunda hareketlerin 0° ve 90° için karşılaştırılma matrisleri	85

ŞEKİLLERİN LİSTESİ

Şekil 1.1: Radarın çalışma prensibinin basit bir gösterimi	3
Şekil 1.2: İnsan hareketleri- a) yürüme hareketi, b) yürüme hareketi, c) koşma hareketi, d) koşma hareketi	5
Şekil 1.3: Tez kapsamında yapılan işlerin ilerleyiş şeması.....	6
Şekil 2.1: Radar sabit iken hareketli hedefin Doppler etkisi.....	12
Şekil 3.1: Farklı hayvan insan hareketleri için elde edilen mikro-Doppler izleri- a) yürüyen at, b) koşan köpek, c) yürüyen insan, d) emekleyen insan [16].....	18
Şekil 3.2: İleri yönlü wrapper metodunun çalışma ilkesi.....	26
Şekil 3.3: Geri yönlü wrapper metodunun çalışma ilkesi	28
Şekil 3.4: İnsan vücudunu temsil etmek için kullanılan 12 noktasal hedef modeli [23]	34
Şekil 3.5: Boulic modeliyle gerçekleştirilen insan yürüme benzetimi	36
Şekil 3.6: Oluşturulan insan modeli- a) 31 noktayı içeren asıl model, b) 14 nokta çıkarılarak oluşturulan model [61]	38
Şekil 3.7: Oluşturulan 12 noktalı modelin animasyonu [61]	39
Şekil 3.8: CMU veri tabanındaki bir yürüme verisine göre yapılan benzetimden elde edilen insan yürüme spektogramı.....	39
Şekil 3.9: Kinect verilerinin toplanma şekli [66]	41
Şekil 3.10: Kinect ile oluşturulan modelin yürüme simülasyonu [66]	42
Şekil 3.11: Kinect ile oluşturulan modelin benzetim sonucu [66]	42
Şekil 4.1: 0° için yürüme modelinin basit bir gösterimi	44
Şekil 4.2: 0° için CMU veri tabanından elde edilen spektogramlar- a) Yürüme verisi, b) Koşma verisi, c) Emekleme verisi, d) Sürünme verisi	45
Şekil 4.3: 0° için CMU veri tabanından elde edilen farklı sürünme spektogramları - a) sürünme hareketi, b) sürünme hareketi	47
Şekil 4.4: Yürüme hareketinin farklı açılardaki spektogramları - a) 30°, b) 45°, c) 60°, d) 90°	48
Şekil 4.5: Koşma hareketinin farklı açılardaki spektogramları - a) 30°, b) 45°, c) 60°, d) 90°	50
Şekil 4.6: Emekleme hareketinin farklı açılardaki spektogramları - a) 30°, b) 45°, c) 60°, d) 90°	51
Şekil 4.7: Sürünme hareketinin farklı açılardaki spektogramları - a) 30°, b) 45°, c) 60°, d) 90°	52
Şekil 4.8: Aynı insanın 0°, 45°, 135° ve 180°deki micro-Doppler izleri- a) 0°, b) 180°, c) 45°, d) 135°	53
Şekil 4.9: Gövde Doppler frekansının ortalaması	55
Şekil 4.10: Gövde salınımlarının bant genişliği	56
Şekil 4.11: Üst zarfın maksimum değeri	57
Şekil 4.12: Alt zarfın minimum değeri	58
Şekil 4.13: Toplam Doppler bant genişliği	59
Şekil 4.14: Üst zarfın ortalama değeri	60

Şekil 4.15: Alt zarfın ortalama değeri	61
Şekil 4.16: Alt ve üst zarf ortalamaları arasındaki bant genişliği	62
Şekil 4.17: Alt ve üst zarf ortalamalarının ortalaması.....	63
Şekil 4.18: Alt zarfın minimum ve üst zarfın maksimum değerlerinin ortalaması	64
Şekil 5.1: Bilinen açılı bilgisi için farklı algoritmalarla seçilen üç özneliğin başarımları karşılaştırması.....	70
Şekil 5.2: mRMR algoritması tarafından seçilen öznelik gruplarının başarımları.....	71
Şekil 5.3: Hedefle radar arasındaki açının bilinmemesi durumunda kullanılan algoritmanın organizasyon şeması.....	76
Şekil 5.4: Bilinmeyen açılı için farklı algoritmalarla seçilen üç özneliğin başarımları karşılaştırması.....	78
Şekil 5.5: En iyi başarımları veren üç öznelik sayısının komşuluğu olan öznelik sayılarındaki MIFS-U yönteminin başarımları	79
Şekil 5.6: Bilinen ve bilinmeyen açılı durumlarında mRMR ve ileri yönlü wrapperın başarımları.....	81
Şekil 5.7: Açının bilinmesi durumunda seçilen yöntem mRMR ve açının bilinmemesi durumunda seçilen yöntem MIFS-U'nun başarımları	82

KISALTMALAR

Bu çalışmada kullanılmış olan kısaltmalar açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
CMU	Carnegie Mellon University
CW	Continuous Wave (Sürekli Dalga)
EM	Elektro-Manyetik
FD	Fourier Dönüşümü
FM-CW	Frequency Modulated Continuous Wave (Frekans Kiplmeli Sürekli Dalga)
GAMIFS	Genetic Algorithm guided by Mutual Information for Feature Selection
ICA	Independent Component Analysis
kNN	k Nearest Neighbour (k En Yakın Komşu)
KZFD(STFT)	Kısa Zaman Fourier Dönüşümü (Short Time Fourier Transform)
MIFS	Mutual Information based Feature Selection
MIFS-U	Mutual Information Feature Selection Under uniform Information distribution
MOCAP	MOTion CAPture
mRMR	Minimum Redundancy-Maximum Relevance
NMIFS	Normalized Mutual Information based Feature Selection
PCA	Principle Component Analysis
PRF	Pulse Repetition Frequency (Darbe Yineleme Frekansı)
PRI	Pulse Repetition Interval(Darbe Yineleme Aralığı)
RADAR	RADio Detecting And Ranging
SVM	Support Vector Machine

SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
a_t	Radarin dönen sinyalinin genliği
$a_{t,k}$	k. vücut parçası için radarın dönen sinyalinin genliği
C	Sınıf değişkeni
c	Işık hızı
f	İletilen sinyal frekansı
f_c	Ötüş sinyalinin merkez frekansı
f_D	Doppler frekans kayması
f_i	Öznitelikleri belirten rastgele değişken
f_j'	Seçilecek öznitelikleri belirten rastgele değişken
$f(\tau)$	Analiz yapılacak sinyal
G	Antenin kazancı
$H(X)$	X değişkeninin entropisi
$H(Y)$	Y değişkeninin entropisi
$H(X,Y)$	Birleşik entropi
$H(Y X)$	Koşullu entropi
$I(X,Y)$	Bilgi miktarı
k	Vücut parçalarını temsil eden değişken
$L_a(R)$	Atmosferik kayıplar
L_s	Sistem kayıpları
m	Darbe numarası(boullic modeli kontrol et)
P_r	Alınan sinyalin gücü
P_t	İletilen sinyalin gücü
$p(x)$	x değişkeninin marjinal olasılık kütle fonksiyonu
$p(y)$	y değişkeninin marjinal olasılık kütle fonksiyonu
$p(x,y)$	olasılık kütle fonksiyonu
$p(y x)$	Koşullu olasılık kütle fonksiyonu
R	Radarin hedefe olan uzaklığı
R_k	k. hedefin radara olan uzaklığı
$r_{maksimum}$	Kesin menzil ya da ölçülebilecek maksimum mesafe
$r_{uzaklık}$	Hedefin hesaplanan uzaklığı
S	Seçilen özniteliklerin yerleştirildiği küme
t	Zaman parametresi
\mathcal{T}	Tüm özniteliklerin bulunduğu küme
t_d	Sinyalin radardan hedefe ve hedeften radara dönünceye kadar geçen zaman
$t_{d,k}$	k. vücut parçası için sinyalin radardan hedefe ve hedeften radara dönünceye kadar geçen zaman
T_{sys}	Sistem sıcaklığı
\hat{t}	Her darbenin gönderiliş anındaki hızlı-zaman indeksi

v	Hedef hızı
$W(t - \tau')$	$t = \tau'$ 'da pencere fonksiyonu
w	Frekans parametresi
β	Seçilen ve seçilecek özniteliklerin alakalılık ve bağımlılığı arasındaki göreceli önemi belirten bir katsayı
γ	Ötüş sinyalinin eğimi
ΔR	Hedefin radara olan uzaklığı
Δt	Gönderilen sinyal ile alınan sinyal arasındaki zaman farkı
θ	Görüş açısı (Aspect Angle)
λ	Sinyal dalga boyu
σ	Hedef kesit alanı
σ_k	k. vücut parçasının radar kesit alanı
σ_n	Gürültü gücü
τ	Ötüş sinyalinin darbe genişliği

1 GİRİŞ

1.1 Tarihçe

Radyo dalgaları, düşük frekanslardan başlayarak yüksek frekanslara kadar devam eden frekans spektrumunun belli bir kısmını işgal ederler. Elektromanyetikle ilgili ilk çalışmalar Michael Faraday tarafından yapılmıştır. 1830'lu yıllarda Faradayın çalışmalarını kullanarak J.C. Maxwell 1860'lı yılların başlarında elektriğin faydalarını ve manyetizmayı bir denklem seti ile kurgulayarak elektromanyetik için bir teori geliştirmeyi başarmıştır. Maxwell'in oluşturduğu bu teori ve denklemler modern radyo ve radar sistemlerinin tasarımının ve teorilerinin gelişmesi için temel hazırlamıştır [1]. 19. yüzyılda Heinrich Hertz, Maxwell'in çalışmalarının ışığında radyo dalgalarının nesnelere yansıdığını, kırılmasını, birbirleriyle etkileşime girip birbirlerini etkilediğini ve yüksek hızlarda yol aldığını göstermiştir [1], [2].

1897'de A.S. Popov Baltık denizinde iki gemi arasında haberleşme üzerinde test yaparken, üçüncü bir aracın sinyaller üzerinde bir etki oluşturduğundan raporunda bahsetmiş ancak bununla ilgili başka bir çalışma yapmamıştır. 1904 yılında Christian Hülsmeier, sisli havalarda Rhine nehrinde seyir halinde olan gemilerin çarpışmasını engellemek için bir cihaz geliştirmiştir. Bu cihaz tam bir RADAR (RADio Detecting And Ranging), olmasa da alıcı, verici, anten ve hedef menzilindeyken alarm vermesi bir RADAR sisteminin özelliklerini taşımaktadır. 1922'de Albert H. Taylor ve Leo C. Young telekomünikasyon deneyleri yaparlarken tahta gemilerin sinyalleri bozduğunun farkına varmışlardır. Bu bulgularının liman savunması için kullanılabileceğini belirtmelerine rağmen fikirleri kabul edilmemiştir. 1930'da Lawrence A. Hyland'dında katılımıyla uçan uçakların tespiti için radyo ekipmanları benzeri bir sistem kurmuşlardır. Aynı zamanlarda RADAR'la ilgili çeşitli ülkelerde bu tarz çalışmaları bulunmaktadır. RADAR ismi 1939 yılında Amerika Birleşik Devletleri Donanması tarafından konulmuştur [2].

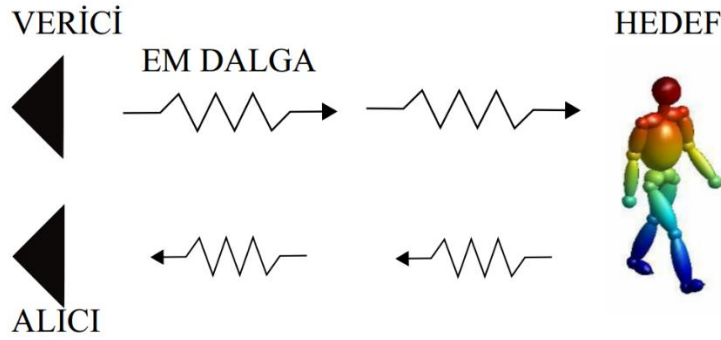
II. Dünya savaşı sırasında ise RADAR pek çok ülkenin çalışma alanına girmiştir. Bu ülkeler Amerika, Rusya, Almanya, Hollanda, Fransa ve Japonya olarak örnekleri verilebilir. Bu ülkeler tarafından savaş öncesi ve savaş sırasında geliştirilen sistemler ve özellikleri diğer ülkelerle paylaşılmamıştır. İngilizlerin, kıyı boyunca yerleştirdikleri alıcı ve vericilerle herhangi bir Alman saldırısını tespit eden ve önceden uyarı vererek halkın sığınaklara girmelerini ve pilotların savaş uçaklarını havalandırarak karşı koymalarını sağlayan '*Chain Home*' adı verilen RADAR sistemi geliştirilen sistemlerden biridir. Burada örnekleri verilmese de diğer ülkelerinde RADAR konusunda araştırmaları mevcuttur [2].

II. Dünya Savaşı sonrasında RADAR için geliştirilen sistemler sivil hayata aktarılmaya ve entegre edilmeye başlanmıştır. 1946'da sivil uçuşlar için deneysel bir ekipman kurulmuş ve 1952 yılında uçuş kontrolü için bir sistem geliştirilmiştir. Savaş sırasında geliştirilen RADAR sistemlerinde hava koşullarından (kar, yağmur vb.) kaynaklanan gürültüler tespit edilmiştir. Buradan yola çıkılarak 1950-1980 yılları arasında dünya çapında yağışın yoğunluğunu ve pozisyonunu ölçen radarlar kurulmuştur. 1980-2000 yılları arasında bu radarlar gelişmiş ülkeler için standart haline gelmiştir [2].

1.2 Motivasyon

Temel olarak RADAR bir Elektro-Manyetik (EM) dalganın bir verici tarafından iletilmesi, bu EM dalganın hedeften yansıdıktan sonra bir alıcı tarafından alınması ve sinyalin, alıcı tarafından alındıktan sonra bir takım sinyal işleme teknikleri uygulanarak işlenmesine dayalı bir yapıdır. Radar bu yapısıyla, doğada göremedikleri için yönlerini bulmak amacıyla ses dalgalarını kullanan yarasalarla oldukça benzerdir. Radarın gönderdiği EM sinyalinde hedefin hızına göre bir frekans kayması meydana gelmektedir. Bu frekans kayması Doppler etkisi olarak adlandırılır. Bölüm 2.3'te bu etkiden daha ayrıntılı olarak bahsedilecektir. Ayrıca radarın geri dönen EM sinyalinde, zaman gecikmesinden menzile ve frekans kaymasından da hız tespit edilebilir. Temel bir radarın genel yapısı Şekil 1.1'de görülmektedir.

Günümüzde radarlar hava tahmin radarlarından hız kontrol radarlarına, yer altı görüntüleme radarlarından hava trafik kontrol radarlarına kadar birçok farklı amaç için birçok uygulama alanında kullanılmaktadır. Radarın kullanımının geniş bir alana yayılmasındaki temel etkenler gece ve gündüz (aydınlık ve karanlık), yağmur, kar, rüzgâr gibi çevresel etkenlerden etkilenmemesi olarak özetlenebilir.



Şekil 1.1: Radarın çalışma prensibinin basit bir gösterimi

Radar hedef sezim, tanıma ve takip edebilme özelliklerinden dolayı insan sezimi, tanıma ve sınıflandırma problemlerinde kullanılabilir. İnsan sezim, tanıma ve sınıflandırma özellikle sınır kontrolü, güvenlik, gözetleme ayrıca engel arkası görüntüleme radarlarıyla insan arama-kurtarma ve kapalı mekanda insan yer ve hareket tespiti gibi uygulama alanları radarda mevcuttur. Sınır kontrolünde hareket tespiti ile tehlike arz edebilecek insan tespiti yapılarak güvenlik sağlanabilir. Gözetleme ve güvenlik amaçlı, canlı bomba hareketleri tespit edilerek bu konuda güvenlik sağlanabilir [3]. Engel arkası radarlar, kamera gibi belirlenmesi kolay görüntüleme cihazlarının konulamayacağı kapalı mekânlarda içerideki insan sayısını, hareketlerini ve yerlerini, eşyaların konumlarını belirlemek için kullanılmaktadır [4]. Radarlar ayrıca otomatik alarm verme kabiliyeti nedeniyle saatler boyu süren gözetleme görevlerinde operatörün dikkat dağılımı veya uyuklaması durumunda hedefin takip edilememesi ve hedefin kaçırılması gibi durumları ortadan kaldırarak avantaj sağlamaktadır. Özellikle insan hareketlerinin sınıflandırılması, insanın elinde silah taşıma ve taşımama gibi durumlarda bu hareketlerin sınıflandırılması güvenlik uygulamalarında önemli bir


savunma mekanizması ortaya koymaktadır. Ayrıca radarın çevresel faktörlerden etkilenmeden bu tespiti yapabilmesi radarı kızılötesi ve optik gibi tespit yapabilen diğer sistemlerden ayırarak öne çıkarmaktadır.

1.3 Problem Tanımı

Radarların, hedefin hareketlerini çevresel şartlardan etkilenmeden her türlü çevresel şartlarda tespit edebilmesi radarlar için önemli bir avantajdır. Hedefin sezilmesi sayesinde hedef hareketinin tanımlamasının yapılabilmesi mümkün olmaktadır. Radarda bu hareket tanımlamaları mikro-Doppler analizi ile gösterilmektedir. Mikro-Doppler, hedefin ortalama hızı üzerinde gerçekleşen dönmelerin ve titreşimlerin ek frekans kipleme olarak tanımlanır ve spektogram gibi zaman-frekans gösterim yöntemleriyle gösterilir. İlerleyen bölümlerde bu tanımlar daha ayrıntılı olarak açıklanacaktır. Hedef hareketlerinin mikro-Doppler izleri hareketten harekete ve hedeften hedefe farklılık göstermektedir. Bu farklılıklar incelenerek hareketler ve hedefler birbirinden ayrılabilir.

[5]–[8]’deki çalışmalar incelendiğinde tank, helikopter, helikopter pervanesi ve insan hareketlerine ait veriler görülebilir ve bu veriler incelendiğinde her bir hedefin Micro-Doppler izlerinin farklı olduğu rahatça görülebilir. Farklı hedeflerin micro-Doppler izleri farklı olduğu gibi insan hareketleri de farklıdır ve diğer hedef türlerinden ayrılabilir. Aynı şekilde insan hareketleri de kendi içinde incelendiği zaman her hareketin mikro-Doppler izlerinin farklı olduğu Şekil 1.2 incelenirse görülebilir. Eğer Şekil 1.2 incelenirse insanın yürüme ve koşma olarak iki farklı hareketi için farklı hedeflerden elde edilen mikro-Doppler izleri ve bu hedeflerin mikro-Doppler izlerindeki farklılıklar görsel olarak görülebilir. Şekil 1.2’de insanın yürüme ve koşma hareketleri için elde edilen micro-Doppler izleri verilmektedir. Şekil 1.2 incelendiği zaman izlerin birbirine benzediği ama farklılıklar içerdiği görülebilir. Şekil 1.2’de ki benzerliğin sebebinin insanın iki ayaklı olması, her insanda ortak bir iskelet yapısının olması ve bundan dolayı hareketlerde benzerlik olması şeklinde söylenebilir. Şekil 1.2’de görülen farklılıkların sebebi olarak da insanın vücut uzunluğu, kilosu, hareket

hızı kısacası insanın kendine has olan hareket tipi olarak özetlenebilir. Dolayısıyla Şekil 1.2 'deki farklılıklar kullanılarak hedefler birbirinden ayrılabilir.



Şekil 1.2: İnsan hareketleri- a) yürüme hareketi, b) yürüme hareketi, c) koşma hareketi, d) koşma hareketi

Şekil 1.2 incelendiğinde yürüme ve koşma hareketinin micro-Doppler farklılıkları görsel olarak görülebilir. Bu farklılıklar mikro-Doppler'in hedeflerin veya bu hedeflerin yapısal parçalarının hızlarından dolayı radarın iletilen sinyalinin taşıyıcı frekansı üzerinde bir frekans kayması meydana getirmesinden kaynaklanmaktadır. Şekil 1.2'de bir insanın kol, bacak, gövde vb. uzuvlarının salınımları veya hareketlerinden kaynaklanan micro-Doppler izleri görülmektedir. Bilindiği gibi bir insanın yürüme ve koşma hızları birbirinden farklıdır. Koşma hareketinde bir insanın hızı, yürüme hareketine oranla daha fazladır, bu sebeple Şekil 1.2'nin c ve d bölümünde a ve b bölümüne göre mikro-Doppler frekansının daha yüksek olduğu ve mikro-Doppler izlerinin periyodunun daha kısa yani frekanslarının daha yüksek olduğu görülebilir. Bu analiz, mikro-Doppler etkisinin hızla doğru orantılı olduğunu

göstermektedir. Bir insan ya da herhangi bir nesnenin hızı ne kadar artarsa bu spektogramlar üzerindeki mikro-Doppler frekansını etkileyecek ve arttıracaktır.



Şekil 1.3: Tez kapsamında yapılan işlerin ilerleyiş şeması

Radarın önceden belirtildiği gibi çevresel faktörlerden etkilenmemesi, insan seziminin ve sınıflandırmasının rahatça yapılmasına olanak vermektedir. Sınıflandırma işlemi yapılarak amaçlanan ayırım yapılabilir. Sınıflandırma işlemi, öznitelik adı verilen sınıflandırılacak durumlarda ortak olan ve bu nesnelerin farklılıklarını ortaya koyan özellikleri kullanarak, bu durumları ayırma işlemidir. Bu tez kapsamında yapılan sınıflandırma işlemi Şekil 1.3'te gösterildiği gibi üç bölümden oluşmaktadır. İlk aşamada kullanılacak öznitelikler spektogramlar üzerinden çıkarılmaktadır. Öznitelikler çıkarıldıktan sonra ikinci aşama olan öznitelik seçimine sıra gelmektedir. Tüm özniteliklerin kullanılması optimum başarıyı vermeyebilir. Öznitelik seçimi genel olarak sınıflandırmada işlevsiz veya önemsiz olan özniteliklerin elenerek başarıyı optimuma çıkaracak özniteliklerin belirlendiği bölümdür. Gereksiz özniteliklerin kullanımı ile daha fazla öznitelik kullanmak başarıyı düşürmektedir. Kullanılan sınıflandırıcıdan ziyade kullanılan özniteliklerin seçilmesinin sınıflandırıcı performansı üzerinde daha etkin bir rolü vardır [9]. Bu sebeple sınıflandırma işlemi için, kullanılan sınıflandırıcı tarafından ayırımı rahatça yapılabilen ve sınıflandırılacak durumları iyi bir şekilde belirtebilen öznitelikler kullanılmalıdır. Öznitelikler teker teker kullanılabilirdiği gibi birbirlerinin kombinasyonları şeklinde de kullanılabilirler. Ancak tek tek kullanıldığında en iyi sınıflandırma sonucunu veren özniteliklerin beraber kullanıldığında başarımın kesin artacağı gibi bir durum söz konusu değildir. Bu sebeple beraber kullanıldığında en iyi sonucu veren özniteliklerin bulunması, seçilmesi ve bu özniteliklerin beraber kullanılması sınıflandırma sonucunu iyileştirecektir. Bu amaçla öznitelik seçimi üzerine yapılan çalışmaların farklı çalışma alanlarındaki örneklerine [10]–[13]'den ulaşılabilir. Öznitelik seçimi aşamasından

sonra ise son kısım olan sınıflandırma bölümü gelmektedir. Bu kısımda ise sınıflandırılacak sınıflar belirtilerek sınıflandırıcının ayırım yapması sağlanarak başarımlar belirlenmektedir.

Öznitelik seçimi ile ilgili olarak mikro-Doppler'da öznitelik seçiminin pek uygulanmadığı literatüre bakıldığında rahatça söylenebilir. [11]'daki çalışmaya bakıldığında PCA metodu uygulanarak öznitelikler seçilmiştir. Bu çalışmada PCA ile öznitelik kümesi bir dönüşümden geçilerek yeni bir öznitelik kümesi oluşturulmuştur. Yeni öznitelik kümesinde eski kümedeki öznitelikler değil onlar yardımıyla oluşturulan yeni öznitelikler yer almaktadır). Genel olarak mikro-Doppler alanındaki çalışmalara bakıldığında bu alandaki öznitelik seçim çalışmalarının eksik olduğu görülebilir. Bu tez kapsamında bu açıklığın giderilmesi amaçlanmıştır.

1.4 Tez Kapsamı

Mikro-Doppler ile sınıflandırmayı doğrudan etkileyen bazı unsurlar bulunmaktadır. Bu unsurlar mikro-Doppler datasının toplam süresi, SNR ve açısal bağımlılık olarak sayılabilir. Mikro-Doppler datasının toplam süresi başarımların optimum olacağı en kısa süre olarak ayarlanmaya çalışılır. Bu aynı zamanda hedef tespitini de kısaltmaktadır. Bununla beraber EM dalganın yayıldığı ortamda EM dalga ortama bağlı olarak bir gürültüye maruz kalır. Bu gürültü gücüne bağlı olarak mikro-doppler izlerini baskılayarak mikro-Doppler izlerinin zayıflamasına ve hedefin tespit edilememesine sebebiyet vermektedir. Ayrıca mikro-Dopplerin açısal bir bağımlılığı bulunmakta ve açıya göre mikro-Doppler izleri iyileşmekte ya da kötüleşmektedir. Mikro-Doppler izlerinin kötü olduğu açı değerlerinde mikro-Doppler fazla bir bilgi içermeyeceği için hedef tespiti zorlaşmaktadır. Bu tez kapsamında mikro-Dopplerin açısal bağımlılığı ele alınarak öznitelik seçimi yardımıyla hedef tespiti için sınıflandırma performansını optimum yapmak hatta mikro-Doppler bilgisinin kötü olduğu açı değerlerinde bile sınıflandırma performansını arttırmak amaçlanmıştır.

Hedef hareketlerinden kaynaklanan mikro-Doppler izleri en net hedefle radar arasındaki açı 0° olduğu zaman yani hedef radara doğru hareket yaparken oluşmaktadır.

Mikro-Doppler izleri en kötü ise hedefle radar arasındaki açı 90° olduğu zaman yani hedef radarın bakışına dik hareket ederken oluşmaktadır. Mikro Doppler izlerinin açı ile değiştiği bilgisi Bölüm 2’de teori verildikten sonra Bölüm 4’te daha ayrıntılı olarak açıklanacaktır. Bu tezin kapsamında insan hareketlerinin sınıflandırılması için, insanla radar arasındaki açı değişik değerlerde olduğu zaman (0° - 180°) bir takım öznitelikler önerilerek açısız olarak sınıflandırma başarımını maksimum yapacak özniteliklerin seçimi için yöntemler önerilmiştir. Böylece açı değişerek artıka mikro-Doppler izleri kötüleşse de sınıflandırma sonucunun en yüksek başarımı vermesi amaçlanmıştır.

Literatürde çeşitli öznitelik seçim yöntemleri bulunmaktadır. Bu tez kapsamında ise seçilme aşaması için bu öznitelik seçim yöntemleri arasından bilgi kuramsal yaklaşım kullanılmıştır. Çünkü bilgi kuramsal yaklaşım, en basit açıklamasıyla iki rastgele değişkenin arasındaki bağımlılığı vermektedir. Bu özellik sayesinde çıkarılan özniteliklerden hangilerinin ve hangi kombinasyonun sınıflandırılacak sınıflarla daha ilintili olduğu bulunabilmektedir. Bu sayede öznitelik kümesi, sınıflandırılacak sınıfları daha iyi temsil eden bir alt kümeye düşürülmektedir. Ayrıca bilgi kuramsal yaklaşımın sınıflandırma sonucu üzerindeki etkisi, sınıflandırma sonuçları verilerek gösterilecektir.

1.5 Tez Organizasyonu

Bu tez, Bölüm 2’de radar ve bilgi kuramsal yaklaşım hakkında genel bilgilerin, ve kullanılan benzetim hakkında bilgilerin verildiği teori bölümü, Bölüm 3’te radarla insan sezimi hakkında yapılan çalışmalar ve bilgi kuramsal yaklaşımın öznitelik seçimi için kullanılmasını içeren bir literatür bölümü, Bölüm 4’te özniteliklerin çıkarılmasını anlatan bir öznitelik çıkarım bölümü ve Bölüm 5’te radarla insan benzetimi ile elde edilen verilerden çıkarılan özniteliklerle insan hareketlerinin sınıflandırılması ile ilgili sonuçların yer aldığı bir sonuç bölümü olarak organize edilmiştir.

2 TEORİ

2.1 Radar Mesafe Denklemi

Radarda geri dönen sinyalin ya da alınan sinyalin gücü, gönderilen sinyalin genliğine bağlı olan mesafe denklemi ile hesaplanabilir. Ayrıca geri gelen sinyalin gücü değişik sistem parametrelerinde iletilen sinyalin gücüne de bağlıdır. Eğer isotropik bir anten ve noktasal bir hedef düşünülürse radar mesafe denkleminin basit hali Denklem (2.1)'de görülebilir:

$$P_r = \frac{P_t * G^2 * \lambda^2 * \sigma}{(4\pi)^3 * R^4 * L_s * L_a(R)} \quad (2.1)$$

Denklem (2.1)'de P_t iletilen sinyalin gücünü, G kullanılan antenin kazancını, λ kullanılan sinyalin dalga boyunu, σ hedefin kesit alanını, R radarın hedefe olan uzaklığını, L_s sistem kayıplarını ve $L_a(R)$ ise atmosferik kayıpları belirtmektedir. Denklem (2.1)'de görüldüğü üzere alınan sinyalin gücü birçok parametreye bağlıdır. P_t, G, λ ve L_s gibi parametreler sistem tasarımcısı tarafından ayarlanabileceği gibi σ ve $L_a(R)$ gibi parametreler sistemi tasarlayan tarafından ayarlanamayan hedef tipine ve ortamın koşullarına bağlı özelliklerdir. $L_a(R)$ kaybı sadece radar sinyalinin ortamda aldığı mesafeye değil aynı zamanda ortamdaki sıcaklığa, neme, basınç gibi atmosferik şartlara da bağlıdır.

2.2 Radar Menzili

Doppler radarlarının, frekans kiplmeli (Frequency Modulated Continuous Wave-FM-CW) ve frekans kiplemesiz (Continuous Wave-CW) sürekli dalga radarları ve koherent darbe radarları olmak üzere çeşitleri bulunmaktadır. CW radarlar yalnızca hızı ölçebilmektedir. FM-CW ve koherent darbe radarları ise sahip oldukları geniş frekans band genişlikleri sayesinde yüksek mesafe çözünürlüklerini, mesafeyi ve Doppler bilgisini ölçebilmektedir. Birinci kısımda söylendiği gibi radar hedefe bir EM

dalga göndermekte ve daha sonra hedeften yansıyan bu sinyali toplamaktadır. Alınan sinyalle gönderilen sinyal arasındaki zaman farkına bakılarak hedefin radara olan uzaklığı belirlenebilir. Hedefin radara olan uzaklığına menzil denir ve Denklem (2.2) ile hesaplanabilir [14].

$$\Delta R = \frac{\Delta t * c}{2} \quad (2.2)$$

Burada ΔR hedefin radara olan uzaklığı, Δt gönderilen sinyalle alınan sinyal arasındaki zaman farkı, c ise ışık hızıdır.

Darbe radarlarının sinyal gönderim aralıklarına (pulse repetition interval-PRI) sinyal tekrar aralığı denir. PRI'in tersine ise sinyal gönderim frekansı (pulse repetition frequency-PRF) denir. Denklem (2.2)'de ölçülebilecek mesafenin Δt 'ye bağımlı olduğu gösterilmiştir. Bu sebeple darbe radarlarında ölçülebilecek mesafe PRI ile kısıtlıdır. Bunun sebebi, EM dalga PRI aralıklarla gönderilir ve yeni bir EM dalga gönderilene kadar gönderilen EM dalganın geri gelmesi gerekmektedir. Bu nedenlerden dolayı ölçülebilecek kesin menzil, PRI'in Δt 'ye eşit olduğu zaman hesaplanabilir. Bu eşitlik ve ölçülebilecek kesin menzil ya da maksimum menzil denklemi Denklem (2.3)'te gösterilmiştir. Denklem (2.4)'te ise bu menzilin sinyal gönderim frekansına bağlı ifadesi görülebilir [14]:

$$r_{maksimum} = \frac{PRI * c}{2} \quad (2.3)$$

$$r_{maksimum} = \frac{c}{2 * PRF} \quad (2.4)$$

Denklem (2.3) ve (2.4) te belirtilen $r_{maksimum}$ kesin menzil ya da ölçülebilecek maksimum mesafedir.

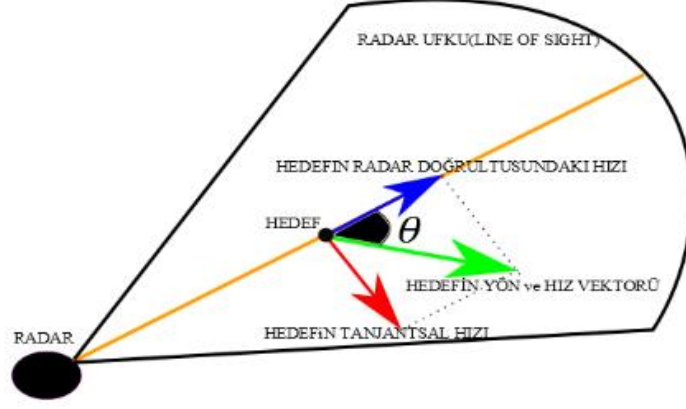
Eğer gönderilen EM dalga PRI'dan daha uzun bir zamanda ve radar iletim modundayken geri dönerse sinyal alınmaz. Eğer gönderilen EM dalga PRI'dan daha

uzun bir zamanda ve radar dinleme modunda değilken geri dönerse bu EM dalga radar tarafından alınır ancak bu EM dalga önceki bir periyotta gönderilen bir dalga olduğu için hedef mesafesi yanlış hesaplanır. Bu durum için hedefin hesaplanan uzaklığı $r_{uzaklık}$ olsun. Gerçekte ise hedef radardan $r_{maksimum}+r_{uzaklık}$ kadar uzaktadır.

2.3 Doppler Etkisi

Eğer hedef hareketliyse alınan sinyalle gönderilen sinyal arasında Doppler etkisi olarak adlandırılan frekans kayması meydana gelir. Ayrıca hedefin ötelenen parçalarından veya diğer bir deyişle hedefin uzuvlarından dolayı, Doppler kaymasının yanına ek olarak ek frekans kiplenmeleri görülür. Doppler frekans kayması, Şekil 2.1'te radar ufkunda hareketli hedefin radar doğrultusunda uzaklaşan veya yaklaşan vektörünün hızıyla belirlenir. Şekil 2.1'te yeşil vektör hareketli hedefin gittiği yönü ve hızını belirtsin (yeşil vektör için radarla hedef arasındaki açı farkı θ°), o zaman mavi vektör hedefin radar doğrultusunda ki (mavi vektör için radarın doğrultusu ve hareketli hedef arasındaki açı farkı 0°) yönünü ve hızını, kırmızı vektör ise hedefin tanjantsal hızını (radarın doğrultusu ve hareketli hedef arasındaki açı farkı 90°) gösterebilir.

Doppler frekans kayması hedefin radar doğrultusundaki hızıyla (mavi renkli vektör) belirlenir. Hareketli hedefin hızı (v), EM dalganın hızına oranla çok daha yavaş bir hızdır. Radar tarafından alınan dalga, radardan hedefe ve daha sonra hedeften radara doğru bir yol izleyerek hedef mesafesinin 2 katı yol alır. Her iki harekette de bir Doppler frekans kayması meydana gelir. Bu Doppler kayması Denklem (2.5) de görülebilir:



Şekil 2.1: Radar sabit iken hareketli hedefin Doppler etkisi

$$f_D = -\frac{v}{c} * f \quad (2.5)$$

Denklem (2.5)'de f_D Doppler frekans kaymasını, f iletilen sinyalin frekansını, v hedef hızını belirtmektedir.

Eğer radar sistemi monostatik, radar sabit ve hedef hareketliyse burada v Şekil 2.1 de gösterildiği gibi hedefin radar doğrultusundaki hızını belirtmektedir. Hedef radardan radar doğrultusunda uzaklaşıyorsa, hedefin hızı pozitif olarak tanımlanır ve Denklem (2.5)'e göre Doppler frekans kayması negatif değer alır. Bunun tam tersi olarak hedef radar doğrultusunda radara yaklaşıyorsa, hedefin hızı negatif olarak tanımlanır ve Doppler frekans kayması pozitif değer alır. Eğer radar ve hedefin her ikisi de hareketliyse göreceli hıza göre Doppler frekans kayması hesaplanabilir [14].

Hedefin hızından kaynaklanan Doppler frekans kayması EM dalganın gidiş ve dönüş hareketinde de aynıdır fakat işaret farkı vardır. Toplam Doppler frekans kayması Denklem (2.6) de belirtildiği gibi ifade edilebilir [14]:

$$f_D = -f * \frac{2 * v}{c} \quad (2.6)$$

Hedefin hızından kaynaklanan Doppler frekans kayması hedefin radar doğrultusundaki hızıyla belirlenir. Eğer Şekil 2.1’de gösterildiği gibi hedef radar doğrultusunda hareket etmiyorsa ve radarla hedef arasında bir açı varsa bu açıya görüş açısı (aspect angle) denir ve Doppler frekans kayması bu açıya bağlı olarak değişir. Bu değişim Denklem (2.6a) ile belirtilir:

$$f_D = -f * \frac{2 * v}{c} * \cos(\theta) \quad (2.6a)$$

Denklem (2.6a)’da verilen θ görüş açısı olarak adlandırılır ve radarla hedef arasındaki açıyı belirtmektedir.

2.4 Bilgi Kuramı

Bilgi kuramı rastgele iki değişkenin birbiri ile ne kadar ilintili olduğu ya da birbirleri hakkında ne kadar bilgi içerdiğini belirtilen bir bağıntıdır. Bu rastgele iki değişken birbirleri ile ne kadar ilintililerse bilgi kuramına göre karşılıklı bilgi miktarları da o kadar yüksek olur. Eğer bu iki rastgele değişken birbirleri ile bağımsız ise karşılıklı bilgi miktarları sıfır olarak bulunur [15]. Karşılıklı bilgi miktarı, bu rastgele iki değişkenin birleşik olasılık kütle fonksiyonu ile marjinal olasılık kütle fonksiyonu arasındaki birleşik entropi olarak adlandırılır. Karşılıklı bilgi miktarının daha iyi anlaşılmasının sağlanması için karşılıklı bilgi miktarının tanımı verilmeden önce entropinin tanımı verilecektir.

Rastgele bir değişkenin belirsizliğinin ölçüsü entropi, $H(X)$ olarak adlandırılır. $x \in \mathbf{X}$ ile gösterilen ayrık bir rastgele değişken ve $p(x) = \Pr\{X = x\}$, $x \in \mathbf{X}$ ve $p(y) = \Pr\{Y = y\}$, $y \in \mathbf{Y}$ olsun. Entropi $H(X)$, $H(Y)$ Denklem (2.7a) ve (2.7b) ile tanımlanır:

$$H(X) = - \sum_{x \in \mathbf{X}} p(x) * \log_2(p(x)) \quad (2.7a)$$

$$H(Y) = - \sum_{y \in Y} p(y) * \log_2(p(y)) \quad (2.7b)$$

Denklem (2.7a) ve (2.7b)'de belirtilen $p(x)$ ve $p(y)$ marjinal olasılık kütle fonksiyonlarıdır.

Denklem (2.7a) ve (2.7b)'de tek rastgele değişkenin entropisi belirtilmiştir. Bu tanım bir rastgele değişken çifti (X, Y) içinde verilebilir. Bu rastgele değişken çiftinin birleşik entropisi denir ve $H(X, Y)$ olarak gösterilir ve Denklem (2.8) ile tanımlanır:

$$H(X, Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) * \log_2(p(x, y)) \quad (2.8)$$

Denklem (2.8)'de verilen $p(x, y)$ birleşik olasılık kütle fonksiyonudur.

Bir rastgele değişkenin entropisi verildiğinde diğer değişkenin entropisine koşullu entropi $H(Y|X)$ denir ve Denklem (2.9), (2.10) ve (2.11) ile tanımlanır:

$$H(Y|X) = \sum_{x \in X} p(x) * H(Y|X = x) \quad (2.9)$$

$$H(Y|X) = - \sum_{x \in X} p(x) * \sum_{y \in Y} p(y|x) * \log_2(p(y|x)) \quad (2.10)$$

$$H(Y|X) = \sum_{x \in X} \sum_{y \in Y} p(x, y) * \log_2(p(y|x)) \quad (2.11)$$

Denklem (2.10) ve (2.11)'de belirtilen $p(y|x)$ koşullu olasılık kütle fonksiyonudur.

Bölümün başında da bahsedildiği gibi bilgi miktarı iki rastgele değişken arasındaki ilintiyi vermektedir. Bu iki rastgele değişken arasında bir ilinti yoksa yani

bağımsızlarsa bilgi miktarı minimum değer olan sıfır değerini alır. Bilgi miktarı en yüksek yani maksimum değerini ise bu iki rastgele değişken tam olarak ilintililerse alır. O halde bu iki rastgele değişkeni ayrık rastgele değişkenler olarak önceden tanımlandığı gibi X ve Y olarak, marjinal olasılık kütle fonksiyonları $p(x)$ ile $p(y)$ ve birleşik olasılık kütle fonksiyonu ise $p(x,y)$ olarak tanımlansın. Sonuç olarak X ve Y ayrık rastgele değişkenleri için bilgi miktarı $I(X;Y)$ Denklem (2.12) ile tanımlanabilir:

$$I(X;Y) = \sum_x \sum_y p(x,y) * \log_2 \left(\frac{p(x,y)}{p(x) * p(y)} \right) \quad (2.12)$$

Bilgi miktarı $I(X;Y)$ aynı zamanda Y'in bilgisi varken X'nin belirsizliğindeki eksilmedir. Entropi ve koşullu entropi üzerinden belirlenebilir ve Denklem (2.13) ile tanımlanır:

$$I(X;Y) = H(X) - H(X|Y) \quad (2.13)$$

Denklem (2.13) simetrik bir denklemdir ve $I(X;Y)$ Denklem (2.14)'deki gibi de hesaplanabilir:

$$I(X;Y) = H(Y) - H(Y|X) \quad (2.14)$$

Denklem (2.12)'de iki ayrık rastgele değişken arasındaki bilgi miktarı $I(X;Y)$ hesaplanmaktadır. Ortada ikiden fazla ayrık rastgele değişken olursa bu değişkenlerin arasındaki bilgi miktarı zincir kuralı yardımıyla Denklem (2.15)'daki gibi hesaplanır.

$$I(X_1, X_2, X_3, \dots, X_n; Y) = \sum_{i=1}^n I(X_i; Y | X_{i-1}, X_{i-2}, \dots, X_1) \quad (2.15)$$

Ancak rastgele değişken sayısı büyük boyutlara ulaştığı zaman karşılıklı bilgi miktarını hesaplamak büyük yükü getirmektedir. Bu amaçla karşılıklı bilgi miktarını hesaplamak için ve gerçek karşılıklı bilgi miktarına yakın bir sonuç elde edebilmek

amacıyla bir takım yöntemler geliştirilmiştir. Bu yöntemler Bölüm 3'te filtre metotları başlığı altında verilecek ve incelenecektir.


3 LİTERATÜR ARAŞTIRMASI

3.1 Mikro-Doppler ile ilgili çalışmalar

Radarin dönen sinyalinde mikro-Doppler izlerinin keşfedilmesiyle, bu izlerin ne olduğu, nelerden kaynaklandığı ve etkilendiği hakkında birçok çalışma yapılmıştır. Bu bağlamda farklı hareketli hedeflerin mikro-Doppler izleri çıkarılmış ve incelenerek farklılıkları çalışılmıştır. Ayrıca ne tarz yöntemlerle birbirlerinden ayrılacağı hakkında da çalışmalar yapılmıştır. Bu çalışmalar mikro-Doppler analizi ve mikro-Doppler ile sınıflandırma konu başlıklı iki alt başlıkta incelenmiştir.

3.1.1 Mikro-Doppler Gösterimi

Pek çok hedefin veya bu hedeflerin yapısal parçası olan nesnelerin titreşimsel veya salınımsal hareketleri bulunmaktadır. Bu titreşimsel veya salınımsal hareketlere mikro-hareket adı verilir. Mikro-hareketler, bir hedefin veya bu hedefin yapısal parçalarının titreşimine ve salınımına ek olarak bu nesnenin veya yapısal parçanın büyüklüğüne de bağlıdır. Mikro-hareketin kaynağı olarak bir insanın yürürken gövdesinin sallanması, kol ve bacaklarının hareketi, kuşların kanat çırpışları, helikopter pervanelerinin hareketleri, bir tankın paletlerinin hareketi, bir arabanın tekerleklerinin hareketleri sayılabilir [5]–[8], [14]. Şekil insan ve hayvanlardan elde edilen mikro-Doppler izleri görülebilir:



Şekil 3.1: Farklı hayvan insan hareketleri için elde edilen mikro-Doppler izleri- a) yürüyen at, b) koşan köpek, c) yürüyen insan, d) emekleyen insan[16]

Bu mikro-hareketlerin hızları, radar sinyalinin taşıyıcı frekansında doğal Doppler frekansının yan bantlarında frekans kaymalarına sebep olur. Bu frekans değişimlerine micro-Doppler adı verilir [14]. Her hedeften kaynaklanan frekans kaymaları yani micro-Doppler etkileri hedeften hedefe farklıdır. Bir insanın micro-Doppler iziyle bir köpeğin, bir kuşun, bir atın, sallanan bir sarkacın, bir helikopterin pervanelerinin, araba tekerleklerinin, tank paletlerinin izleri birbirinden farklıdır.

Bu veriler radarla deneysel olarak elde edilebileceği [17] gibi benzetimlerle [18]–[20] de elde edilebilir. Radarla herhangi gerçek bir ortamdan veri alınımı zor olduğu ve bu konuda çalışanların her zaman böyle bir imkânı olmamasından dolayı benzetim ortamında analizlerin gerçekleşmesi önem arz etmektedir. İki tür model kullanılır:

kinematik ve MOCAP. Benzetimlerde en çok kullanılan kinematik model, biomekanik üzerindeki çalışmalarla ortaya çıkan Boulic modelidir [18]. Bu model temel alınarak [19]'teki model öne sürülmüştür. Bu modeller ile yapılan çalışmalar [21]–[23] olarak sayılabilir. Bölüm 3.3'te bu tez kapsamında kullanılan model daha ayrıntılı olarak verilecektir.

Problem tanıtımı bölümünde (Bölüm 1.3) hedeflerin mikro-Doppler izlerini incelemek ve görsel olarak görmek için spektogramlar kullanıldığından bahsedilmiştir. Spektogramlar sinyalin zamanla değişen frekans bileşenlerinin frekans-zaman temsilinde göstermektedir. Genel olarak spektogramlarda Kısa Zaman Fourier Dönüşümü (KZFD; İngilizcesi : Short Time Fourier Transform- STFT) kullanılır. KZFD'nin genel olarak sık kullanılmasının sebebi frekans bileşenlerinin değişiminin zamansal olarak belirlenmesindeki en kolay zaman-frekans gösterimi olmasıdır. KZFD radar sinyalinin bir pencere fonksiyonu yardımıyla bölümlere ayrılarak, her bölümün Fourier Dönüşümü (FD) alınarak hesaplanır. Burada bu pencere fonksiyonu uygun bir şekilde ayarlanarak zaman-frekans çözünürlüğü ayarlanabilir. Bu tez kapsamında KZFD kolay hesaplanmasından ötürü kullanılmıştır. KZFD'nin formülü Denklem (3.1)'de görülebilir [24]–[26] :

$$\text{KZFD}(t, w) = \int_{-\infty}^{\infty} f(\tau) * W(t - \tau) * e^{-j*w*\tau} * d\tau \quad (3.1)$$

Denklem (3.1)'de, $f(\tau)$ analizi yapılacak sinyali, $W(t - \tau)$ ise $t = \tau$ 'da pencere fonksiyonunu, t zaman parametresini ve w ise frekans parametresini göstermektedir.

Literatürde, spektogramlar için KZFD'nin dışında da kullanılan S-Method, Gabor Transform, Wigner Distribution, Gabor-Wigner Transform gibi çeşitli metotlar yer almaktadır. Bahsedilen bu metotların birbirlerine göre bazı avantajları ve

dezavantajları bulunmaktadır. Bu sebeple bazı arařtırmacılar tarafından tercih edilerek kullanılmaktadırlar [24]–[26].

3.1.2 Mikro-Doppler ile Sınıflandırma

Radarda mikro-Doppler ile hareketli hedef seziminin yapılabileceđi keřfedildiđinden beri hareketli hedeflerin birbirinden ayrılması için alıřmalar süregelmektedir. Özellikle insanın diđer hareketli hedeflerden ve insan hareketlerinin birbirinden ayrılabilmesi için çeřitli alıřmalar yapılmıřtır [6], [27]–[29].

[6]'te helikopter pervaneleri ile insan yürüyüşünün radarın dönen sinyali üzerindeki Doppler izleri incelenerek bu iki hareketinde mikro-Doppler izleri ıkarılmıřtır. Her iki hareket modeli içinde birden fazla deney yapılmıř ve mikro-Doppler izlerindeki farklılıklar anlatılarak analizleri yapılmıřtır. İnsan hareketi için, radarla insan arasında ki açđ 30°, 45°, 60° olacak řekilde insanın kollarını sallama hareketiyle yürürken üç farklı deney gerekleřtirildiđi belirtilmektedir. Yapılan deneylerde zaman-frekans analizleri yapılmıřtır. Bu analizler hem helikopter pervaneleri hem de insan yürüme hareketi için yapılmıřtır. Sonuçlarda insan hareketinin helikopter pervane hareketinden farklı olduđu ıkarılan sonuçlarla belirtilmiřtir. Bu izler ve aralarındaki farklılıklar bahsi geen makale incelendiđinde spektogramlarda görsel olarak görülebilir.

D. Tahmouh et. al., insan yürüyüşü ile üzerinde insan varken atın yürüyüşü ile ilgili arařtırma yapmıřlardır [27]. Bu alıřmaya bakıldıđında insan ile üzerinde insan varken atın hareketlerini görsel olarak gözlemlenmek mümkündür. D. Tahmouh et. al. bu alıřma kapsamında bu iki farklı hedefin sınıflandırmasının yapılabilmesi için spektogram üzerinden ıkarılabilen bir takım öznitelikler önermiřlerdir. Bu öznitelikleri hedefin ortalama hızı, maksimum ayak salınım hızı, kol sallanmaları hızları, gövde hızı, hareketin periyodu, bacakla gövde arasındaki faz farkı, ayađın

salınım zamanı ve hedeflerin mesafe bilgileri olarak belirtmişlerdir. Ayrıca mesafe bilgilerinin kullanım için her zaman uygun olmadığını belirtmişlerdir. Ancak hedefin kafasının, iki ayaklı hedeflerde olduğu gibi hedefin omuzunun üzerinde mi yoksa dört ayaklı hedeflerde olduğu gibi hedefin vücudundan önde mi olduğunun anlaşılması için kullanılabilirdiğinden bahsedilmiştir. Bu mesafe bilgileri kullanılarak hedefin insan mı yoksa hayvan mı olduğunun anlaşılabilirdiğini savunulmuş ve bir öznitelik olarak önerilmiştir. Ancak herhangi bir sınıflandırma sonucuna çalışmada yer verilmemiştir.

Li Fei et. al.[30]'de hareket yakalama veri tabanını [20] kullanarak insan yürüme ve koşma hareketini modelleyerek benzetimini gerçekleştirmişlerdir. Çalışmada, insan hareketini sınıflandırmak amacıyla insan yürüme ve koşma ritmi öznitelik olarak önerilmiştir. Çalışmada, insan yürüme ritminin 1.8-2.2 Hz arasında ve insan koşma ritminin 3-3.3 Hz arasında olduğu egzersiz fizyologları tarafından bulunduğu bahsedilmekle beraber insan koşma ve yürüme hareketinin bir eşik değeri belirlenerek sınıflandırılabilirdiği belirtilmiştir. Çalışma içerisinde verdikleri sonuçlarla yürüme ve koşma hareketinde 2.5 Hz civarında bir eşik değeri belirlenerek insan ayırımının yapılabileceği belirtilmiştir. Ancak herhangi bir sınıflandırma sonucu verilmemiştir.

Y. Yang et. al. [29]'teki çalışmalarında hareket yakalama veri tabanını kullanarak [20] oluşturdukları insan modelinden elde ettikleri mikro-Doppler izlerini, deneysel radarla elde ettikleri mikro-Doppler izleri ile kıyaslamışlardır. Benzetimle elde ettikleri yürüme ve koşma verilerinden, yürüme ve koşma hareketinin ayrılması için en uygun özniteliklerin kol, bacak ve ayak sallanmasından elde edilen öznitelikler olduğunu belirtmişlerdir. Deneysel radarla 60 farklı insandan hızlı yürüme, normal hızda yürüme, yavaş koşma (jogging) ve hızlı koşma hareketleri için veri toplamışlardır. Burada hızlı yürüme ve normal hızda yürüme, yürüme hareketi olarak yavaş koşma ve hızlı koşma hareketleri ise koşma hareketi olarak gruplanarak iki, sınıf oluşturulmuştur. Bu verilerden Temel Bileşen Analizi (PCA : Principle Component Analysis) ve Bağımsız Bileşen Analizi (ICA : Independent Component Analysis) kullanılarak öznitelikler çıkarılmış ve Destek Vektör Makinaları (SVM : Support

Vector Machine) ile k En Yakın Komşu (kNN : k-Nearest Neighbor) kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Böylece ICA-SVM, ICA-kNN, PCA-SVM, PCA-kNN olarak dört metot kullanmışlardır. Sınıflandırma sonuçlarına çalışma içinde ulaşılabilmektedir. Sonuç olarak öznelik çıkarımı ICA ile ve sınıflandırma işlemi kNN ile yapıldığında yani ICA-kNN yöntemi kullanıldığında 96,05% ile en iyi sonuç elde edilmiştir. Ayrıca bu sonucun dışında kullanılan dört metotta 90% başarımın üstüne çıkmıştır.

Y. Kim ve H. Ling [31], [32]'deki çalışmalarında on iki insandan topladıkları gerçek radar verileri ile koşma, yürüme, insan elinde bir çubuk tutarken yürüme, emekleme, boks yaparak öne doğru yürüme, olduğu yerde boks yapma, ve sabit oturma hareketlerini sınıflandırmışlardır. Bu çalışmada spektrogramdan çıkarılan (1) gövde Doppler frekansı, (2) Doppler sinyalinin toplam bant genişliği, (3) toplam Dopplerin offseti, (4) gövde Doppler frekansının bant genişliği, (5) Doppler sinyal gücünün standart sapması, (6) bacak hareketinin periyodu olmak üzere altı adet öznelik kullanılmıştır. Sınıflandırma işleminde sınıflandırıcı olarak SVM kullanılmıştır. SVM yalnızca iki sınıf ayırma özelliğinde olduğu için topladıkları yedi hareketi sınıflandırmak için SVM'den oluşan bir karar ağacı oluşturmuşlardır. Bu karar ağacında her biri iki farklı hareket için eğitilmiş 6 adet SVM kullanılmıştır. Bu karar ağacı hareketler için genelden özele gitmektedir. Mesela, ilk SVM hareketleri gövde hareketinin hızının yüksek veya düşük olma durumunu ayırmak için kullanılmıştır. İlk SVM'den sonra hareketler dal yapısı kullanılarak bu şekilde ayrılarak en sonda hareket belirlenmiştir. Çalışmada, sınıflandırma işleminde çıkarılan her bir özneliğin teker teker kullanılması ile özneliklerin tek başlarına kullanıldıkları zaman ki başarımları bulunarak gösterilmiştir. Ayrıca en başarılı öznelikten başlayarak başarımlarına göre öznelik sayısı artırılarak başarımlarını gösteren bir uygulama yapılmış ve bu uygulamanın sonucunu gösteren bir grafik çalışmaya eklenmiştir. Ancak hangi özneliklerin beraber kullanımında en iyi sonucu vereceğine dair bir çalışma yapılmamıştır. Ayrıca çalışmada SVM ile oluşturulmuş karar ağacının başarımlarını hareketlere göre gösteren bir karşılaştırmalı tablo oluşturulmuştur. Bu tablo ile hangi hareketin hangi hareketle, hangi yüzdeyle karıştığı görülerek, hangi hareketlerin

ayrımının yapılmasının zor olduğu ya da kolay olduğu görülmektedir. Ayrıca sabit bir hareket değil de bu hareketlerin birleşiminden oluşan bir hareket dizilimi oluşturularak böyle bir hareket dizilimi olduğunda insan mikro-Dopplerinin nasıl değiştiği de gösterilmiştir. Ayrıca bu çalışmalar dahilinde duvar ötesi çalışmalar da yapılmıştır.

Radarla insan hareket sınıflandırma hakkında bu kesimde bahsedilen çalışmaların dışında da birçok farklı çalışma da literatürde yer almaktadır. Kol sallanmıyorken, tek kol ve çift kol sallanma hareketlerinin üç farklı öznelik çıkarma metoduyla sınıflandırıldığı, F. H. C. Tivive, et. al. tarafından yapılan [33], [34] çalışmalar, J. Li, et. al. tarafından dört metot kullanılarak dış ortamda normal yürüme, bir elde bir eşya taşınırken yürüme ve iki elde de eşya taşıma hareketleri için yedi insandan toplanan verilerle öznelik çıkarımı ve sınıflandırmanın yapıldığı [35] çalışma, ayrıca D. Tahmoush ve J. Silvious tarafından yapılan öznelik çıkarımı ve sınıflandırmayla ilgili olan çalışma [36] çalışma, O. R. Fogle ve B. D. Rigling tarafından öznelik çıkarımı hakkında yapılan [37] çalışma, Y. Yang et. al. tarafından yapılan ICA ve PCA in öznelik çıkarımı ve SVM, kNN, Doğrusal Ayrıştırma Sınıflandırıcı (LDC : Linear Discrimination Classifier) metotlarının sınıflandırıcı olarak kullanıldığı sadece benzetim verilerinin kullanıldığı [38] çalışma literatürde radar mikro-Doppler izlerini kullanarak, işleyerek, öznelik çıkararak ve hareketleri sınıflandıran çalışmalara örnek gösterilebilir.

Genel olarak literatürde mikro-Dopplerin radarla insan arasındaki açısız bağımlılığı hakkında çalışmalar yapılmıştır [22], [27]. ‘de sınıflandırma performansının hedef görüş açısını 30°’den fazla geçmediği müddetçe en az %90 başarımlı elde edildiği belirtilmektedir. Tivive, et. al. [34]’de görüş açısı 0° iken sınıflandırma başarımlının ortalama %97-99, görüş açısı 30° iken başarımlının %77 ila %91 civarında olduğunu göstermişlerdir. Ayrıca hareketin görüş açısı 0° ile 90° arasında yapılabileceğini belirtmişlerdir. Görüş açısı 90° gelirken mikro-Doppler kiplemesi azalmakta ve öznelik çıkarımı zorlaşmaktadır. Görüş açısı 90°’de iken en kötü durum senaryosunda, D. Tashmoush ve J. Silvious [39] sınıflandırma başarımlının %40

olduğunu belirtmişlerdir. Yapılan çalışmalarda açığa bağımlılıktan bahsedilmesine rağmen sonuç olarak çalışma fazla bir çalışma yapılmamış ve açığa bağlı sınıflandırma performansları çok fazla incelenmemiştir.

3.2 Öznitelik Seçimi İle İlgili Yöntemler


Sınıflandırma işleminde önceden belirtildiği gibi öznitelikler kullanılmaktadır. Öznitelikler sınıflandırılacak olayların, hedeflerin, nesnelerin veya objelerin ortak olan ama birbirlerinden farklı ve ayrımları yapılabilecek özellikleri olarak nitelenebilir. Bu amaçla her sınıflandırma işlemi için ayırımın yapılabileceği çok sayıda öznitelik önerilmektedir. Örüntü tanıma konusunun içine giren her sınıflandırma için muazzam sayıda öznitelik önerilebilir. Ancak önerilen öznitelikler her zaman sınıflandırma probleminde minimum hata oranını ya da maksimum başarı oranını vermezler. Bazen yüksek bir başarı oranı, sınıflandırma işleminde öznitelik kümesine yeni bir öznitelik katıldığında düşebilir. Bu düşüş kullanılan özneliğin durum uzayında yarattığı etkiyle alakalıdır. Ancak bazı işlemlerde eklenen yeni öznitelik düşük bir başarı oranını yükseltebilir. Bazen de sınıflandırma işlemine eklenen yeni öznitelik başarı oranını hiç değiştirmeyebilir ya da önemsiz bir oranda iyileştirebilir veya kötüleştirebilir [40]. Bu bilgilere ek olarak kullanılan özniteliklerin sınıflandırma işlemine etkisinin dışında, çok sayıda gereksiz öznitelik kullanılması bu işlem için harcanan zamanı arttırmaktadır. İşte bu sebeplerle, sınıflandırma işlemine harcanan zamanın kısaltılması ve başarımın artırılması için öznitelik havuzundan sınıflandırma işlemi için başarımı en yükseğe çıkaracak gerekli özniteliklerin bulunarak ve var olan öznitelik kümesinin bir alt kümesi oluşturularak kullanılması gerekmektedir. Bu işlem için birçok yöntem geliştirilmiştir. Bu yöntemler, wrapper ve filtre metotlar olmak üzere iki ana başlık altında toplanabilirler.

3.2.1 Wrapper Metodu

Wrapper metodu öznitelikleri seçerken öznitelik kombinasyonlarının her birinin başarımına bakmakta ve en başarılı kombinasyonu seçmektedir. Eğer n adet öznitelik varsa 2^n adet olası öznitelik kümesi vardır ve wrapper bu 2^n adet kümeyi teker teker sınıflandırmaya sokarak başarımına bakmaktadır. En yüksek başarım oranını veren öznitelik kümesi bu 2^n adet kümenin içerisinde dir. Wrapper tüm olası kümeleri denediği için en yüksek başarım oranını veren öznitelik kümesini bu 2^n adet küme arasından bulmaktadır. Ayrıca wrapper öznitelikleri seçerken, öznitelikleri teker teker sınıflandırıcıda denediği için seçtiği öznitelik grupları öznitelik seçiminde kullanılan sınıflandırıcıya bağlıdır. Bu sebep ile sınıflandırıcı değiştiği zaman öznitelik seçilen grupları da değişebilmektedir. Bu bilgilerle beraber wrapperın çalışması büyük bir zaman gereksinimi gerektirdiğinden wrapper üzerinden ileri yönlü wrapper ve geri yönlü wrapper metotları geliştirilerek kullanılmaya başlanmıştır [41] .

3.2.1.1 İleri Yönlü Wrapper

İleri yönlü Wrapper ya da diğer adıyla greedy algoritmasında ilk başta boş bir S kümesi ve tüm özniteliklerin yer aldığı bir V kümesi yer almaktadır. Bu işlemin en başında tüm öznitelikler teker teker sınıflandırıcıya sokularak başarımları bulunmakta ve en yüksek başarımı veren öznitelik V kümesinden çıkarılarak S kümesine konmaktadır. Daha sonra S kümesindeki bu öznitelik ile V kümesinde kalan öznitelikler teker teker sınıflandırıcıya sokularak başarımları bulunmakta ve S kümesinde öznitelik ile en yüksek başarımı veren V kümesindeki öznitelik seçilmekte ve önceki aşamada olduğu gibi bu öznitelik V kümesinden çıkarılarak S kümesine yerleştirilmektedir [41]. Bu işlem istenen sayıda öznitelik bulununcaya ya da tüm öznitelikler bitinceye kadar devam ettirilebilir. İşlem istenen sayıda özniteliğe kadar devam ettirilirse istenen sayıda özniteliğin başarımına ulaşılabilir. Ancak işlem V kümesi boşalincaya kadar devam ettirilirse en yüksek başarıma sahip öznitelik sayısı görülebilir. Bu metot Şekil 3.2'de gösterilmiştir.

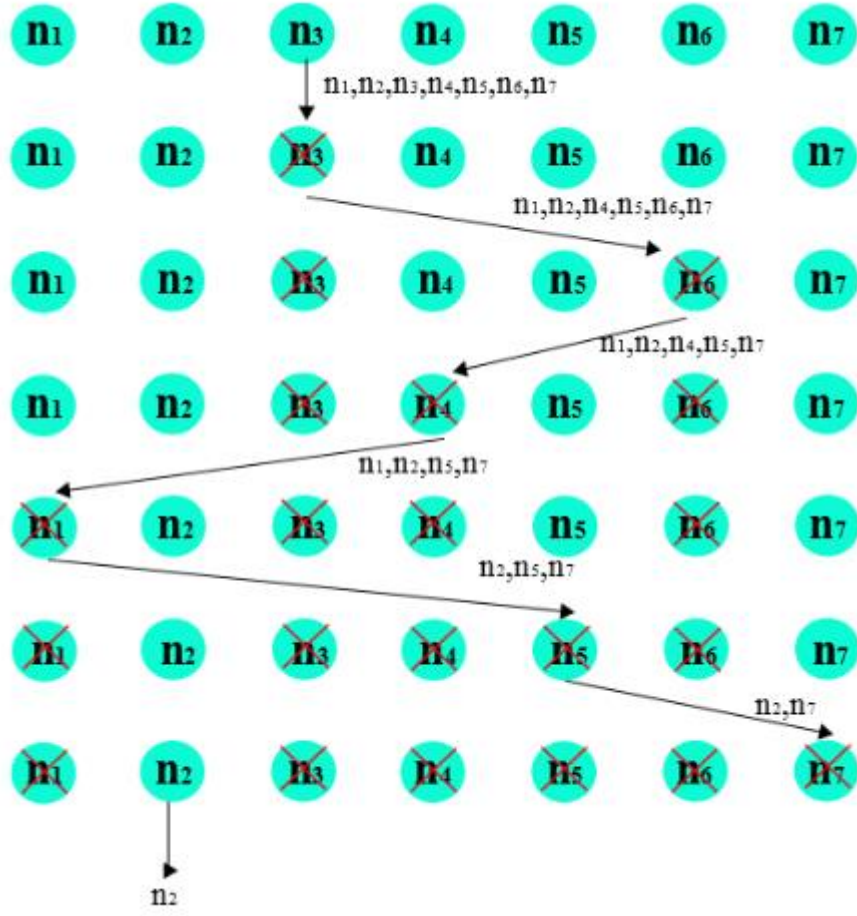


Şekil 3.2: İleri yönlü wrapper metodunun çalışma ilkesi

Şekil 3.2’de ileri yönlü wrapper metodunun temsili bir resimle çalışma ilkesi gösterilmiştir. Şekil 3.2 de satırlar V kümesini ve oklar ise S kümesini belirtsin. Elimizde ilk başta yedi adet öznelik yer alsın ve bu öznelikler n_i ($i=1,2,\dots,7$) ile gösterilsin. Şekil 3.2’de bu yedi adet öznelikten ilk başta n_3 no.lu öznelik seçilmiştir ve bu öznelik V kümesinden çıkarılarak S kümesine eklenmiştir. Daha sonra n_3 ile en yüksek başarıyı veren öznelik n_5 no.lu olarak bulunmuştur ve V kümesinden çıkarılarak S kümesine eklenmiştir. Üçüncü öznelik olarak n_3 ve n_5 ile en yüksek başarıyı veren öznelik n_4 olarak bulunmuş ve V kümesinden çıkarılarak S kümesine eklenmiştir. Bu işlem Şekil 3.2’de en son öznelik seçilinceye kadar devam ettirilmiştir. Burada seçilen öznelik bir daha seçilemeyeceği özneliklerin üzerine X işareti konularak betimlenmiştir.

3.2.1.2 Geri Yönlü Wrapper

Geri yönlü Wrapper da ilk başta tüm öznitelikler seçilmiş gibi davranılır. Bu yöntemde tüm özniteliklerin bulunduğu bir S kümesi ve çıkarılan özniteliklerin yerleştirildiği boş bir V kümesi yer almaktadır. Bu işlemin en başında öznitelikler teker teker S kümesinden çıkarılarak oluşturulan yeni S kümeleri sınıflandırıcıya sokulur ve başarıımı düşüren öznitelik bulunarak, bu öznitelik S kümesinden çıkarılarak V kümesine yerleştirilmektedir. Başarımı düşüren öznitelik S kümesinden çıkarılıp V kümesine yerleştirildikten sonra yeni S kümesinde kalan öznitelikler teker teker çıkarılarak oluşturulan yeni S kümeleri sınıflandırıcıya sokulur ve başarıımı düşüren yeni öznitelik bulunur [41]. Başarımı düşüren ikinci öznitelik bulunduktan sonra bu öznitelik S kümesinden çıkarılarak V kümesine konulur ve yeni bir S kümesi oluşturulur. Bu işlem istenen sayıda öznitelik bulununcaya ya da tüm öznitelikler bitinceye kadar devam ettirilebilir. İşlem istenen sayıda özniteliğe kadar devam ettirilirse istenen sayıda özniteliğin başarımina ulaşılabilir. Ancak işlem V kümesi doluncaya kadar ya da S kümesi boşalincaya kadar devam ettirilirse en yüksek başarıma sahip öznitelik sayısı görülebilir. Bu metot Şekil 3.3’de gösterilmiştir.



Şekil 3.3: Geri yönlü wrapper metodunun çalışma ilkesi

Şekil 3.3’de geri yönlü wrapper metodunun temsili bir resimle çalışma ilkesi gösterilmiştir. Şekil 3.3’te satırlar ve oklar S kümesini ve X işareti taşıyan elemanlar ise V kümesini belirtsin. Elimizde ilk başta yedi adet öznelik yer alsın ve bu öznelikler n_i ($i=1,2,\dots,7$) ile gösterilsin. Şekil 3.3’te bu yedi adet öznelikten ilk başta n_3 no.lu öznelik, tüm özneliklerin (n_i) S kümesinden teker teker çıkarılıp sınıflandırıcıya sokulduktan sonra başarıyı en fazla düşüren öznelik olsun ve bu öznelik S kümesinden çıkarılarak V kümesine eklenmiştir. S kümesinden n_3 çıkarıldıktan sonra ikinci aşamada geri kalan öznelikler S kümesinden teker teker çıkarılıp başarımlarına bakıldığında en düşük başarımın n_6 no.lu öznelikte saptanmış ve n_6 no.lu öznelik S kümesinden çıkarılarak V kümesine konmuştur. Bu durumda geri kalan öznelikler n_1, n_2, n_4, n_5, n_7 no.lu öznelikler ve kalan öznelik sayısı beştir. Öznelik çıkarma işlemi bu işleme göre ilerlemektedir. En son durumda geriye n_2 no.lu

öznitelik kalmaktadır. Önceden bahsedildiği gibi bu öznitelik işlemine tek bir öznitelik kalıncaya kadar ya da istenen sayıda öznitelik bulununcaya kadar devam edilebilir.

3.2.2 Filtre Metodu

Bölüm 3.2.1’de wrapper metodunun çalışma ilkesinden ve öznitelikleri seçerken ilk önce öznitelikleri tek tek veya gruplar halinde sınıflandırıcıya soktuğunu, öznitelik veya öznitelik gruplarının başarımına baktığı ve bu başarım üzerinden seçim işlemini gerçekleştirdiğinden bahsedilmişti. Bu yöntemin tüm özniteliklere ve bu özniteliklerin kombinasyonlarına uygulandığı düşünülürse, bu işlem için çok büyük bir zamanın harcandığı söylenebilir [42]–[44]. Bu açıdan wrapper yöntemi daha kısa süreli öznitelik seçim süresi gerektiren işlemlerde kullanıcıyı dezavantajlı bir duruma sokabilir. Aynı zamanda wrapper’ın işlem yükünü azaltmak için kullanılan Bölüm 3.2.1.1 ve 3.2.1.2’de bahsedilen ileri yönlü ve geri yönlü wrapper da maksimum başarıyı vermeyebilir. Bu iki yöntemde bir ağaç şeması üzerinden çalıştığı için ve başarımın düşük çıktığından dolayı ilerlenmeyen bir dalın sonraki uzantılarından birinde maksimum başarım yer alabilir. Bu sebeplerle hem öznitelik seçim süresinin kısaltması hem de bu sürede maksimum başarıma yaklaşımları için öznitelik seçim aşamasında sınıflandırıcıya gerek duymayan metotlar/yöntemler geliştirilmiştir. Bu metotlara filtre metotları adı verilir.

Filtre yöntemlerin en büyük dezavantajı, tek kullandığı zaman düşük bir başarım veren ama grup halinde kullanılması durumunda büyük bir başarım için fayda sağlayabilecek bir özneliğin es geçilmesi olarak belirtilebilir. Filtre yöntemleri, öznitelikleri belli değerlendirme ölçütlerine göre seçerler. Öklid uzaklığı, Mahalanobis uzaklığı, birbirleriyle olan bağıntıları (dependency), birbirleriyle olan bilgi miktarı mesela entropi ve karşılıklı bilgi miktarı (mutual information) bu değerlendirme ölçütlerine örnek olarak verilebilir. Bu tez kapsamında, bu değerlendirme ölçütlerinden bilgi kuramı ve karşılıklı bilgi miktarı değişkenler arasındaki ilişkiye bağlı kalmadan çok değişkenli öznitelik seçimi için daha uygundur. Öznitelikler ve sınıflar rastgele değişkenler olarak düşünüldüğünde karşılıklı bilgi miktarı hangi özneliğin sınıfla

nasıl bir alakası olduğunu ve özniteliklerin ilintisini ölçmektedir. Tez kapsamında başarılı özniteliklerin seçilmesi amaçlandığından karşılıklı bilgi miktarı öznitelik seçimi için kullanılmıştır. Diğer methodlar bazı aritmetik uzaklık gibi değerleri kullandığından burada öznitelikler ve sınıflar birer rastgele değişken olarak düşünülerek alakayı bulan karşılıklı bilgi miktarı tercih edilmiştir. Karşılıklı bilgi miktarının tez için öznitelik seçimi için kullanılacağından dolayı bilgi kuramı hakkında yapılan çalışmalar hakkında bilgi verilecektir.

Bölüm 2.4 Bilgi Kuramı başlığı altında rastgele değişkenlerin sayısının büyük boyutlara ulaştığı vakit karşılıklı bilgi miktarının hesaplanmasındaki zorluktan ve bu problem için geliştirilen yöntemler olduğundan bahsedilmiştir. Bu çalışmalar hakkında bilgi verilmeden önce kavramların daha iyi anlaşılabilmesi için bazı tanımlamalar yapılacaktır. Öncelikle, f_i ($i = 1, 2, \dots, n$) öznitelikleri belirten bir rastgele değişken ve C sınıflandırılacak sınıfı belirten bir rastgele değişken olsun. $I(f_i; C)$ ise sınıf değişkeni C ile öznitelik değişkeni f_i arasındaki karşılıklı bilgi miktarını belirtir. $I(f_i; C | f_{i-1})$ ise f_{i-1} 'nci öznitelik verildiği zaman f_i ile C arasındaki karşılıklı bilgi miktarını belirtsin. Bu tanımlamaların yanında ilk başta tüm özniteliklerin bulunduğu bir küme ve aşama aşama seçilen özniteliklerin konulacağı seçim kümesinin de tanımlanması gerekmektedir. Tüm özniteliklerin bulunduğu küme \mathcal{T} , $\mathcal{T} = (f_1, f_2, \dots, f_n)$ olarak tanımlansın. Seçilecek öznitelik sayısı k olsun, bu durumda seçilen öznitelikler f'_j ($j = 1, 2, \dots, k$) olarak tanımlanacaktır. Seçilen özniteliklerin konulacağı küme ise S , $S = (f'_1, f'_2, \dots, f'_k)$ ile tanımlansın. Burada S kümesi \mathcal{T} kümesinin bir alt kümesidir ($S \subset \mathcal{T}$).

Karşılıklı bilgi miktarının getireceği karmaşıklıktan ve yoğun işlem gücünden kurtulmak için gerçekleştirilen ilk çalışma Battiti [45] tarafından yapılmıştır. MIFS (Mutual Information based Feature Selection) olarak adlandırılan bu yöntem öznitelikleri istenen öznitelik sayısına ulaşana kadar tek tek seçmektedir. Her bir öznitelik seçim döngüsünde (iterations) Denklem (3.2)'i maksimum yapan öznitelik seçilmektedir:

$$\max \left(I(C; f_i) - \beta * \sum_{f_s \in S} I(f_s; f_i) \right) \quad (3.2)$$

Denklem (3.2)'de ilk terim olan $I(C; f_i)$ T kümesindeki f_i ile C sınıf değişkeni arasındaki karşılıklı bilgi miktarını ve $I(f_s; f_i)$ ise f_i ile S kümesindeki f_s arasındaki karşılıklı bilgi miktarını belirtmektedir. β f_i ile f_s 'nin alakalılığı(relevance) ile bağımlılığı(redundancy) arasındaki göreceli önemi belirtmektedir.

Eğer $\beta = 0$ olursa algoritma hemen hemen aynı bilgiyi sağlayan öznitelikleri seçmektedir. β büyüdükçe Denklem (3.2)'deki ifadenin maksimum değeri alması algoritmanın her döngüsünde seçilen özniteliklerin birbirinden gittikçe bağımsız olmasını gerektirir. Yani algoritma $I(f_s; f_i)$ değerinin gittikçe küçülen değerlerini seçmektedir, çünkü ancak bu şekilde Denklem (3.2) maksimum değere ulaşacaktır. β değeri çok büyük olursa mevcut döngüde maksimum değeri sağlayan $I(f_s; f_i)$ ifadesi algortmada daha etkin bir konuma gelir. Bu durumda Denklem (3.2)'i maksimum yapan öznitelikler birbirinden daha bağımsız olmaya ve bu durumda, bu sınıf değişkeni ile seçilen özneliğin birbirlerinden daha bağımsız olmasına neden olmaya başlar. Bu bir problemdir çünkü bu algortmada amaçlanan sınıfla seçilen özniteliklerin bağımsız olması değil oluşturulan en küçük setle en büyük alakayı(relevance) yakalayabilmektir.

Bu problemde kaynaklanan sorunu giderebilmek için Kwak and Choi[46] bir düzeltmeyle MIFS-U (Mutual Information Feature Selection Under uniform Information distribution) algortmasını önermişlerdir. Bu algortma Denklem (3.3)'de görülebilir:

$$\max \left(I(C; f_i) - \beta * \sum_{f_s \in S} \frac{I(C; f_s)}{H(f_s)} * I(f_s; f_i) \right) \quad (3.3)$$

Denklem (3.3)'de $H(f_s)$ S kümesinin içerisindeki özniteliğin entropisini belirtmektedir. $I(C; f_s) \leq H(f_s)$ olduğunda, Denklem (3.3)'deki $I(C; f_s)/H(f_s)$ oranı S kümesindeki f_s 'in önemini belirtmekte ve bu oran $I(f_s; f_i)$ için bir katsayı olarak kullanılmaktadır. Böylece f_i daha fazla bilgi içeren öznitelikler için daha az alakalı(relevant) bir hale gelmekte ve alakasızlık(redundancy) da az alakalı öznitelikler için daha toleranslı bir hale gelmektedir. Dahası, seçim işleminin başında, sınıf değişkeniyle olan alaka güvenceye alınmakta ve seçilen öznitelik kümesi büyüdükçe yeni seçimler artarak daha az alakasız olmaya başlamaktadır. Bu yöntemle $I(C; f_s)/H(f_s)$ özniteliklerin ayıklanmasını daha kolay bir hale getirmektedir.

Karşılıklı bilgi miktarının getireceği karışıklığı gidermek için önerilen diğer bir yöntem Peng et. al. [40] tarafından önerilen mRMR (Minimum Redundancy-Maximum Relevance) yöntemidir. Önerilen yöntem Denklem (3.4)'te görülebilir:

$$\max \left(I(C; f_i) - \frac{1}{|S|} * \sum_{f_s \in S} I(f_s; f_i) \right) \quad (3.4)$$

Denklem (3.4)'te $|S|/S$ kümesindeki öznitelik sayısını belirtmektedir. Denklem (3.4)'in aksine alakasızlık teriminin $(I(f_s; f_i))$ önündeki katsayı S kümesindeki seçilen öznitelik büyüdükçe değişmektedir. Ayrıca, mRMR tarafından seçilen özniteliklerin sayısı arttıkça, mRMR metodu önceki seçilen öznitelikten bağımsız olarak sınıflandırma problemine daha fazla alaka yüklemektedir.

Bahsedilen MIFS, MIFS-U ve mRMR metotlarının dışında da karşılıklı bilgi miktarını kullanan yöntemler literatürde yer almaktadır. Estevez et. al. [47] tarafından önerilen iki çalışma Normalized Mutual Information based Feature Selection (NMIFS) ve Genetic Algorithm guided by Mutual Information for Feature Selection (GAMIFS) ile Sotoca et. al. [48] hierarchial clustering algorithm literatürde yer alan çalışmalara örnek olarak verilebilir. Önerilen metotların yanında bu metotlar kullanılarak yapılan çalışmalarda literatürde yer almaktadır. Bu çalışmalardan bazıları [43], [44], [49], [50] olarak gösterilebilir.

3.3 Kullanılan Benzetimler


Bölüm 2.1.1’de bahsedildiği gibi bir dış ortama gidilip radarla veri toplamanın zorluğundan dolayı veya bu alanda çalışan kişilerin her zaman böyle bir imkânının olmamasından dolayı çalışmaların yapılması ve ilerlemesi için benzetimsel verilerden sıkça faydalanılmaktadır. Benzetimlerin araştırmacılara kazandırdığı önemli bir olanakta gerçek veri toplananın zahmetinden dolayı gerçekleştirilemeyen çeşitli senaryoların benzetimler kullanılarak tekrar ve tekrar istenilen parametrelerle gerçekleştirilebiliyor olmasıdır. Aynı zamanda gerçek verilerin toplanması zaman aldığı için hedef sayısı istenilen sınıflandırma performansını sağlayacak genişliğe ulaşmamakta hâlbuki benzetim verileri ile geniş bir veri seti oluşturulabilmektedir. Böylece çeşitli senaryolar için hedef sayısı istenilen seviyelere getirilerek çalışmaların gerçekleştirilebilmesi için geniş veri setleri oluşturulabilmektedir.

[21]’de yapılan çalışma mekân içi insan takibi üzerine çalışmaları içermektedir. Bu çalışmada hem benzetim verileri hem de gerçek veriler test için kullanılmıştır. Benzetim için [19]’teki model temel alınarak [18]’de hesaplanan ağırlık merkezine bağlı olarak model oluşturulup kullanılmıştır. [22]’daki çalışmada G.E. Smith, et. al. multistatik radar için gerçek verilerle insan yürüme koşma hareketleri için veriler üretip kıyaslamışlardır. Üretilen verilerde kullanılan insan modeli sadece baş ve ayakların bulunduğu bir pendulum şeklindedir. Bu çalışmadaki amaç radarla hedef arasındaki açı değiştiğinde mikro-Doppler izlerindeki değişimi analiz etmektir. A. Ghaleb et. al. benzetim ve gerçek verilerle, tekerlek, insan yürüme ve koşma hareketlerinin mikro-Doppler izleri üzerine çalışmışlar ve benzetim ile gerçek verilerin farklılıklarını göstermişlerdir [51]. L. Vignaud et. al. insan yürüyüşünü hem benzetim verileri hem de gerçek verileri inceleyerek kıyaslamışlardır [52]. Mikro-Doppler incelenmesi ve çıkarımı hakkında çalışmalar, radarın çeşitli hava koşullarından etkilenmemesinden dolayı birçok farklı araştırmacının araştırma konusu haline gelmiş, deneysel ve benzetim verileri üzerine çeşitli araştırmalar yapılmıştır [19], [27], [52]–[58]. Bu çalışmalarda insan hareketlerinin zamansal olarak karmaşık hareketler olduğu gösterilmiştir. Ayrıca bahsi geçen makalelerde bu hareketler üzerinde çalışma metodları önerilmiş ve denenmiştir.

Bu aşamada hareket yakalama[20] ve kinematik modeller [18], [19] gibi modeller benzetim verisi olarak sıkça kullanılmaktadır. Bu modeller de insan vücudu sonlu sayıda noktasal hedeflerle temsil edilmektedir. Bu noktasal hedeflerin her biri silindir, küre gibi şekillerden biri ile modellenmektedir. Bu modelleme yapılırken, bu şekiller insan vücut parçasının şekline uygun seçilmektedir. Mesela insan başı bir küre kollar ve bacaklar silindir ile modellenmektedir. Her bir vücut parçasından dönen sinyal ve mikro-Doppler sinyali ayrı ayrı hesaplanmakta ve üstdüşüm ilkesine uygun olarak toplanmaktadır. Bu üstdüşüm ilkesi, mikro-Doppler üzerinde deneysel verilerle ve insan üzerine yerleştirilen infrared işaretleyicilerle elde edilen benzetim verileri karşılaştırılarak Geisheimer, et. al. [59] gösterilmiştir. Bu bölümde kullanılan benzetimleri tanıtmak için üç alt başlık halinde Boulic modeli, hareket yakalama verileri ile ve kinect hareket yakalayıcı sensör yardımıyla elde edilen veriler ve gerçekleştirilen benzetimlerden bahsedilecektir.

3.3.1 Boulic Modeli

Boulic et. al. tarafından önerilen kinematik yürüme modelinde[18] insan vücudu baş, sağ ve sol üst kol, sağ ve sol bacak, sağ ve sol ayak, sağ ve sol baldır, sağ ve sol alt kol ve gövde olmak üzere 12 parçayla modellenmiştir. Bahsedilen modelde parçalar noktasal hedefler olarak da modellenebilirler. Şekil 3.4'e bakıldığında insan modelini oluşturan 12 nokta görülebilir [23].



Şekil 3.4: İnsan vücudunu temsil etmek için kullanılan 12 noktasal hedef modeli [23]

Önerilen modelde her bir vücut parçasının zamanla değişen uzaysal koordinatları, çalışmada verilen vücut ölçümleri, denklemler ve grafikler yardımıyla hesaplanabilmektedir. Çalışma içerisinde denklemler karmaşık ve ayrıntılı görünse de aslında bu denklemler sadece insan yürüme hızına ve insanın bel uzunluğuna bağlıdır. Model insan yürümesi üzerine oluşturulduğu için diğer hareketlerin yani koşma, emekleme, zıplama, sürünme, boks hareketi ve diğer spor hareketleri gibi hareketlerin benzetimleri gerçekleştirilememektedir.

Boulie modeliyle her bir noktasal hedefin zamanla değişen konumları bulunduğundan sonra radar benzetimleri yapılmaktadır. Radarın dönen sinyali radar menzil denklemi ile hesaplanır. Bölüm 2’de bahsedildiği gibi radarın geri gelen sinyali, gönderilen sinyalin zamanda gecikmeli ve frekansta kaydırılmış halidir. Genellikle Doppler radarlarda ötüş (chirp) sinyali kullanılmaktadır. Alınan radar sinyali, modelde kullanılan noktasal hedef için Denklem (3.5) ile hesaplanabilir:

$$s_r(m, t) = a_t * \text{rect}\left(\frac{\hat{t} - t_d}{\tau}\right) * e^{j*[-2*\pi*f_c*t_d + \pi*\gamma*(\hat{t} - t_d)^2]} \quad (3.5)$$

Denklem (3.5) de τ ötüş sinyalinin darbe genişliği, γ ötüş sinyalinin eğimi, a_t radarın dönen sinyalinin genliği, f_c ötüş sinyalinin merkez frekansı, \hat{t} her darbenin gönderiliş anındaki hızlı-zaman indeksi, t_d sinyalin radardan hedefe ve hedeften radara dönünceye kadar geçen zaman, m darbe numarasını temsil etmektedir.

Bölüm 3.3’te mikro-Dopplerın, Geisheimer [59] tarafından her bir vücut parçasından geri yansıyan sinyallerin toplanmasıyla (üstdüşüm ilkesi) temsil edilebileceğinden bahsedilmişti. Denklem (3.5)’te tek bir vücut parçasından yansıyan radar sinyali gösterilmiştir. Dolayısıyla Boulie modelinden 12 vücut parçasından elde edilen verilerin toplam mikro-Doppler bilgisi Denklem (3.6)’de görülebilir:

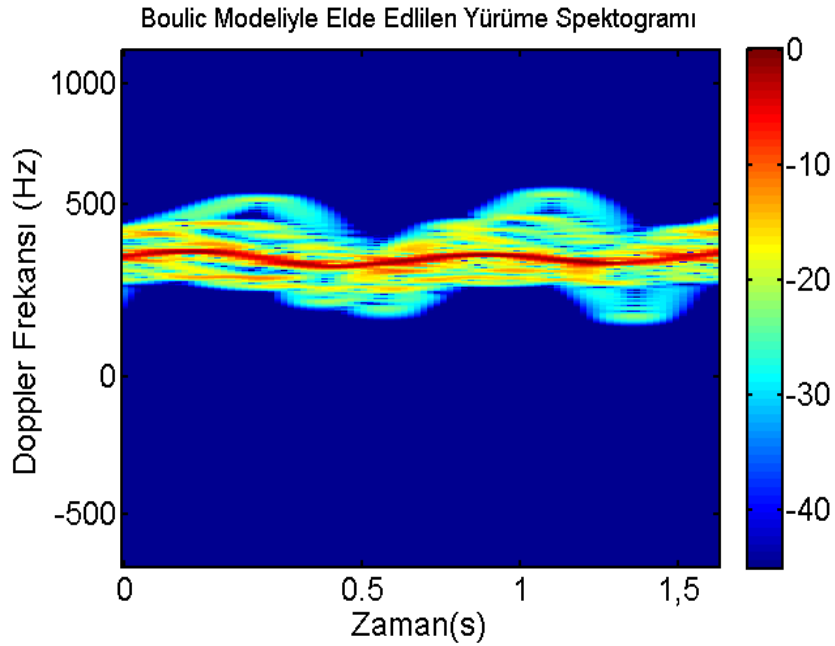
$$s_h(m, t) = \sum_{k=1}^{12} a_{t,k} * \text{rect}\left(\frac{\hat{t}_k - t_{d,k}}{\tau}\right) * e^{j*[-2*\pi*f_c*t_{d,k} + \pi*\gamma*(\hat{t}_k - t_{d,k})^2]} \quad (3.6)$$

Denklem (3.6)'da k değişkeni vücut parçalarını temsil etmektedir. Bu durumda, $t_{d,k}$ k . vücut parçası için sinyalin radardan hedefe ve hedeften radara dönünceye kadar geçen zaman $a_{t,k}$ k . vücut parçası için radarın dönen sinyalinin genliğini belirtmektedir.

Radarin dönen sinyalinin genliği radar menzil denklemiyle hesaplanmaktadır. Denklem (3.7) radarın dönen sinyalinin genliğini radar menzil denklemine göre göstermektedir:

$$a_{t,k} = \frac{G * \lambda * \sqrt{P_t * \sigma_k * \sigma_n}}{\sqrt{(4\pi)^3 * R_k^2 * \sqrt{L_s} \sqrt{L_a} \sqrt{T_{sys}}}} \quad (3.7)$$

Denklem (3.7)'te verilen ifadede G anten kazancını, λ sinyalin dalga uzunluğunu, P_t gönderilen sinyalin gücünü, σ_k vücut parçalarının radar kesit alanını, σ_n gürültü gücünü, R_k hedefin radara olan uzaklığını, L_s sistem kayıplarını, L_a atmosferik kayıpları ve T_{sys} ise sistem sıcaklığını belirtmektedir. Bahsedilen model kullanılarak radar benzetimleri gerçekleştirilmiştir. Şekil 3.5'de Boulic modeliyle gerçekleştirilmiş bir insan yürüme benzetimi sonucu görülmektedir.



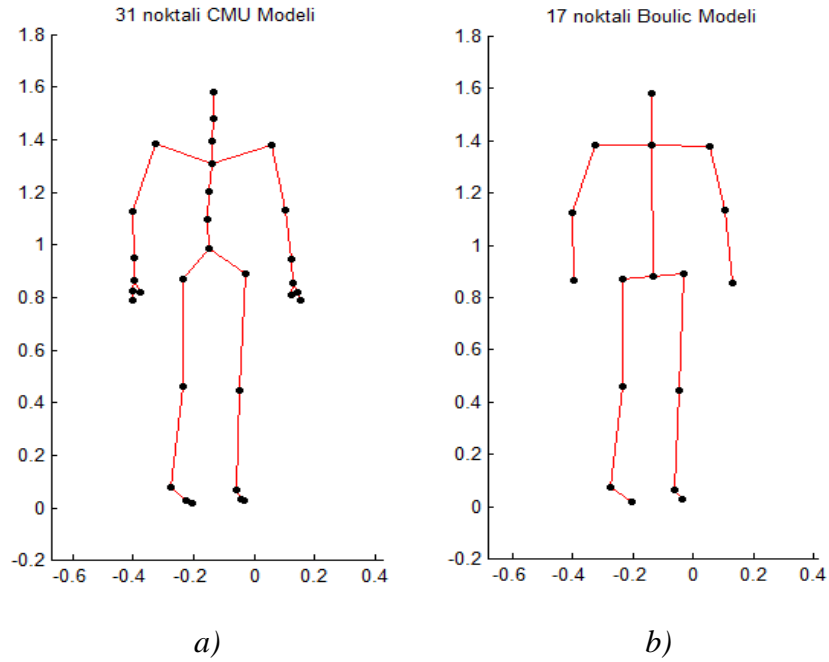
Şekil 3.5: Boulic modeliyle gerçekleştirilen insan yürüme benzetimi

3.3.2 CMU Veri Tabanı ile Oluşturulan Model

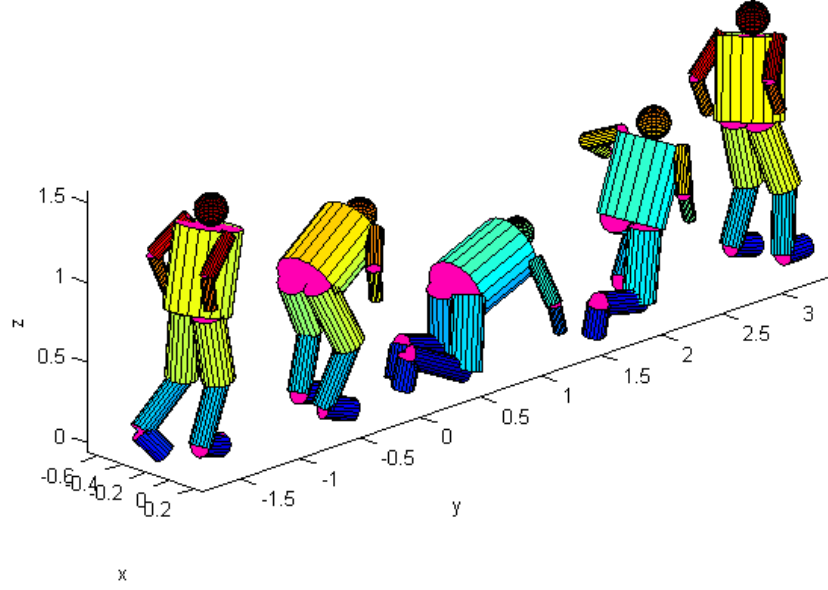
3.3.1’de Boulic modelinden bahsedildi. Ancak her ne kadar Boulic modeli deneysel verilerle uyumluluk gösterse de sadece yürüme hareketi için tanımlanmış olup diğer hareketleri (koşma, emekleme, sürünme, tırmanma, nesne taşıma) içeren çalışmalar için yetersiz kalmaktadır. Bu sebepten ötürü çeşitli hareket tiplerini içeren hareket yakalama (MOCAP) [20] verileri kullanılarak insan benzetimlerinin gerçekleştirilmesi ve kullanılması son yıllarda gerçekleştirilmektedir [29], [30], [60]–[64]. MOCAP veri tabanında emekleme, tırmanma, yürüme, tekme atma, koşma, zıplama ve sportif hareketler gibi çeşitli hareket tiplerini içeren veriler yer almaktadır. MOCAP verileri, insan vücuduna yerleştirilmiş 41 sensör yardımıyla ve 12 kızılötesi kamera kullanılarak 120 Hz frekansta toplanmışlardır. MOCAP veri tabanı 112 deneğe ait 2605 adet hareket verisi içermektedir. Kullanılan sensörler ve kameralar ile sensörlerin zamansal değişen konumları kayıt edilmiştir. MOCAP veri tabanı bahsedildiği gibi farklı deneklere ait, farklı ve çeşitli bir hareket veri tabanı sunduğundan dolayı araştırmacılara büyük kolaylıklar sağlamaktadır.

CMU veri tabanında yer alan veriler insan vücudunda belirlenmiş 30 parçanın uzunluklarını ve yönlerini içerir. Bu 30 parça kök noktasından başlayarak ağaç hiyerarşisi ile düzenlenerek veriler oluşturulmuştur. Bu 30 vücut parçasının verileri ağaç yapısında kendi üzerinde bulunan parçaya göre yön ve dönme eksenlerinin açıları şeklinde sunulmuş olup, her bir parçanın üç boyutlu düzlemde yani XYZ düzleminde aldığı değerler (konumlar) bu sunulan bilgiler yardımıyla kinematik hesaplamalar yapılarak bulunmaktadır. MOCAP veri tabanında yer alan veriler kök noktası ve diğer 30 parçanın noktası olmak üzere 31 tane nokta olarak düzenlenmiş ve ASF ile AMC dosyaları olarak sunulmaktadır. ASF dosyası iskelet bilgisinin yer aldığı dosya olup insan vücudunda belirlenmiş 30 parçanın yönlerini ve uzunluk bilgilerini içermektedir. AMC dosyası ise hareket bilgilerinin yer aldığı dosya olup kemiklere ait zamansal yön ve dönme bilgilerinin hesaplandığı dosyadır. Her bir denek için bir ASF dosyası ve her bir hareket içinse bir AMC dosyası veri tabanında yer almaktadır.

CMU veri tabanındaki veriler, arařtırmacılara radar alıřmalarında benzetim verileri üretmek için kullanılan Boulic modeline göre daha ayrıntılı bir iskelet yapısı sunmaktadır. Örneğın, Boulic modelinde kol yapısı alt ve üst kol olarak iki paradan oluşurken, CMU verilerinde altı paradan oluşmaktadır. Boulic modelinin başarımı görüldüğünden dolayı, fazla verinin getireceğı yükü azaltmak için, bu model, 31 noktanın 14 noktası çıkarılarak 17 referans noktası içeren Boulic modeline benzetilmiştir. 31 noktayı içeren asıl model ile 14 nokta çıkarılarak oluşturulan modelin aynı veri için karşılaştırılması Şekil 3.6'de [61] görülebilir. Bu modelin animasyonu gerçekleştirilmiş ve bu gereklemede insan vücudu 12 noktadan oluşturulmuştur [61]. Oluşturulan 12 noktalı modelin animasyonu Şekil 3.7'de görülebilir:

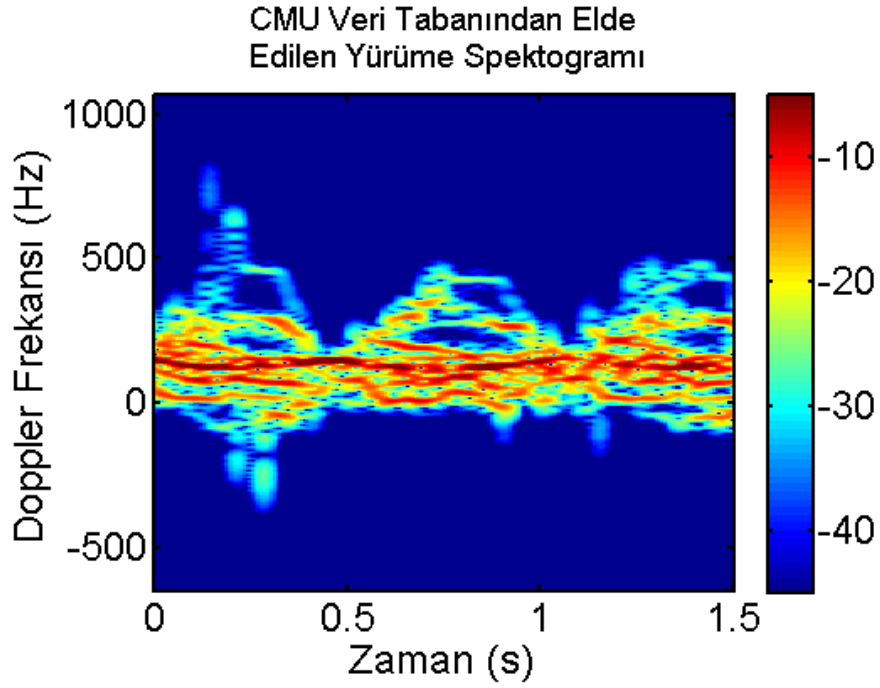


Şekil 3.6: Oluşturulan insan modeli- a) 31 noktayı içeren asıl model, b) 14 nokta çıkartılarak oluşturulan model [61]



Şekil 3.7: Oluşturulan 12 noktalı modelin animasyonu [61]

CMU veri tabanındaki bir yürüme verisine göre yapılan benzetimden elde edilen insan yürüme spektogramı Şekil 3.8’te görülmektedir.



Şekil 3.8: CMU veri tabanındaki bir yürüme verisine göre yapılan benzetimden elde edilen insan yürüme spektogramı


Bu tez kapsamında yapılan çalışmada CMU veri tabanındaki veriler kullanılmıştır. Bu hareket verilerinden 4. Bölüm olan “*Verilerin, Özniteliklerin Çıkarımı ve Sınıflandırma İşleminin Tanıtımı*” bölümünde bahsedilecektir.

3.3.3 Kinect ile Oluşturulan Model

Bölüm 3.3.2 de bahsedilen MOCAP verilerinin en büyük dezavantajı hareketlerin kontrol dışında olması olarak belirtilebilir. Verilerin sağlandığı insanların boy, kilo gibi özellikleri ile verilerin toplandığı zaman ve istenen farklı hareketler seçilememektedir. Bu tarz sistemlerin fiyatları çok yüksek olduğundan, MOCAP verilerinin araştırmacıların kendileri tarafından toplaması için büyük bir zorluk olarak sayılabilir. Ayrıca, Organic Motion firması tarafından geliştirilen OpenStage2 ve Xsens firması tarafından geliştirilen MVN/BIOMECH bu tarz sistemlere örnek olarak sunulabilir. Daha düşük maliyetle bu tarz bir model oluşturulması ve benzetimlerin yapılarak insan hareket bilgilerinin toplanarak mikro-Doppler izlerinin çıkarılabilmesi için TOBB ETU Radar Sistem Laboratuvarında Kinect sensörü üzerine yapılan çalışmalarla Kinect tabanlı bir MOCAP sistemi geliştirilmiştir [65], [66].


Kinect içerisinde dahili bir mikrofon, renkli bir kamera, kızılötesi ışın (IR) projektörü ve kızılötesi kamera (IR) barındıran PrimeSense, Rare ve Microsoft kuruluşları tarafından ortak geliştirilen bir hareket algılayıcı sistemdir. Oyun konsolları için piyasaya sürülmesine rağmen robotik ve biyomedikal gibi çeşitli alanlarda kullanılmaktadır. Üzerinde bulunan kızılötesi projektör görüş alanı içerisinde bulunan cisimlerin üzerine kızılötesi ışınlardan oluşan bir alan yansıtılmaktadır ve oluşturulan bu IR noktaları IR kamera yardımıyla algılanmaktadır. Algılanan bu IR noktaları üzerinden insan vücudundaki eklemlerin büyük bir kısmının ve iskelet yapısının üç boyutlu düzlemde yani XYZ düzleminde zamanla değişen konumları hesaplanabilmektedir. B.Erol tarafından gerçekleştirilen çalışmada kinectin hareket algılama özelliğini kullanarak tıpkı MOCAP verilerinde olduğu gibi insan vücudu üzerinde tanımlanan noktasal hedeflerin zamanla değişen pozisyonun ölçülmesi ve hesaplanması amaçlanmıştır. Ancak Kinect’in [66]’te Tablo 1’de görülebilecek bazı teknik özelliklerinden dolayı iskelet takibinde bazı sıkıntılar ve zorluklar

yaşanmaktadır. Bu sıkıntılar kızılötesi kameranın görüş alanı, deneyin yapıldığı ortamdan kaynaklanan sorunlar ve hedeften düzgün veri toplarken kinectin bulunduğu ya da konulduğu konum örnek olarak sayılabilir. Bu tarz sıkıntıların giderilmesi için bir takım düzeltmeler yapılmıştır. Kinectin konumundan kaynaklanan sıkıntıların giderilebilmesi için Kinect sabitlenmiş ve hedefin kızıl ötesi kameranın görüş alanından çıkmaması için yürüme ve koşma gibi hareketler için bir koşu bandı gerekli modifikasyonlar yapılarak kinectin önüne yerleştirilmiştir. Geliştirilen bu sistemin genel yapısı Şekil 3.9'da görülebilir:

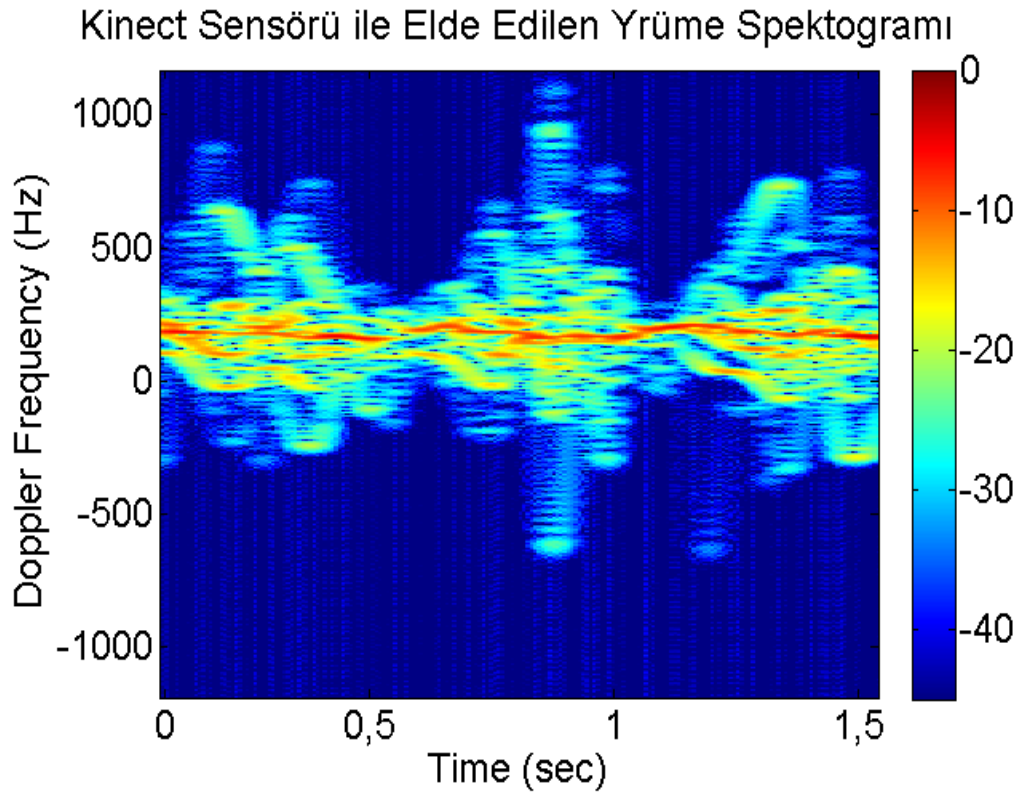


Şekil 3.9: Kinect verilerinin toplanma şekli [66]

Yapılan çalışmada Kinectin algılama aralığı dar olması sebebiyle koşma, yürüme ve insan hareket halindeyken rastgele hareketler gibi veriler hedef koşu bandı üzerindeyken toplanmaktadır. Zıplama, boks benzeri hareket verileri hedef sabit zemin üzerindeyken toplanmaktadır. Toplanan verilerle ilk olarak hedefin bir animasyonu yapılmakta ve daha sonra bu animasyon üzerinden radar benzetimi yapılarak hedefin yürüme spektogramı çıkarılmaktadır. Animasyon Şekil 3.10'da ve elde edilen spektogram ise Şekil 3.11'te [66] görülebilir.



Şekil 3.10: Kinect ile oluşturulan modelin yürüme simülasyonu [66]



Şekil 3.11: Kinect ile oluşturulan modelin benzetim sonucu [66]

4 VERİLERİN, ÖZNİTELİK ÇIKARIMI ve SINIFLANDIRMA İŞLEMİNİN TANITILMASI


Bu bölümde tez kapsamında yapılan çalışmalar hakkında bilgi verilecektir. Bu bölüm, kullanılan CMU veri tabanı verilerinin Bölüm 4.1’de tanıtımının yapılması ve benzetim hakkında bilgi verilmesi ile başlanarak Bölüm 4.2’de öznitelik çıkarım aşamalarından bahsedilerek ve son olarak Bölüm 4.3’te öznitelik seçim aşaması hakkında bilgi verilerek geliştirilecektir.

4.1 CMU Benzetim Verilerinin Tanıtılması

Gerçekleştirilen benzetimler CMU veri tabanı kullanılarak gerçekleştirilmiştir. Bölüm 3.3.2’de CMU veri tabanında yer alan hareketler, hareket verileri ve gerçekleştirilen benzetim konusunda bilgi verilmişti. Bu tez kapsamında yürüme, koşma, emekleme ve sürünme olmak üzere dört farklı hareket için radar benzetimleri her hareket için CMU MOCAP veri tabanının sağladığı sayıda veri kullanılarak gerçekleştirilmiştir. Emekleme hareketinde eller ve dizler yere temas halinde sürünmede ise askeri tipte vücut yerle temas halinde olduğunun vurgulanması gerekmektedir. Burada benzetimler ile CMU MOCAP veri tabanı kullanılarak 196 adet yürüme verisi, 71 adet koşma verisi, 38 adet emekleme verisi ve 73 adet sürünme verisi olmak üzere toplamda 378 adet veri elde edilmiştir. Veri tabanında yer alan bu veriler yürüme verileri 11 farklı insandan, koşma verileri 9 farklı insandan, emekleme verileri 6 farklı insandan ve sürünme verileri 5 farklı insandan olmak üzere toplamda 23 farklı insandan toplanmıştır. Ayrıca burada kullanılan veri tabanında 378 tanesinden 64 adedi aynı kadına ait olmakla beraber, geri kalan 314 adet veri içinse bir cinsiyet bilgisi verilmemiştir.


Gerçekleştirilen radar benzetimleri insan bu dört hareket yaparken radarla arasındaki açı değeri 0° ile 180° arasında 5° aralıklarla değiştirilmiştir. Elde edilen benzetim sonuçlarında mikro-Doppler izlerinin açısız bağımlılığı incelenerek her açı değerinde sınıflandırma başarımının çıkarılan özniteliklerle nasıl değiştiği incelenmiştir. Bu kısım 5. Bölüm olan “Sonuç” kısmında daha ayrıntılı olarak verilecektir.

Benzetimlerde radar sinyali merkez frekansı 15 GHz, PRF 2400 Hz böylece PRI 0.416 ms, hedefle radar arasındaki mesafe 1 km ve sinyal gönderim uzunluğu 3.34 μ s olarak ayarlanmıştır. Şekil 4.1’de yürüme verileri için gerçekleştirilen benzetimin 0° için basit bir gösterimi verilmiştir.



Şekil 4.1: 0° için yürüme modelinin basit bir gösterimi

Benzetim sonucunda her dört hareket için elde edilen verilerin KZFD’si alınarak spektogramları oluşturulmuştur. KZFD aşamasından sonra elde edilen spektogramlar 0° için Şekil 4.2’de görülebilir:




Şekil 4.2: 0° için CMU veri tabanından elde edilen spektogramlar - a) Yürüme verisi, b) Koşma verisi, c) Emekleme verisi, d) Sürünme verisi

Şekil 4.2’de insanın yürüme, koşma, emekleme ve sürünme hareketlerinin CMU MOCAP veri tabanına göre yapılan benzetimleri yer almaktadır. Yürüme, koşma emekleme ve sürünme hareketlerinin kendilerine has imzaları olduğu ama aynı zamanda yürüme ve koşma ile emekleme ve sürünme çiftlerinin kendi aralarında mikro-Doppler izlerinin birbirlerine benzedikleri Şekil 4.2’den rahatça görülebilir. Bunun sebebi olarak koşma hareketi ile yürüme hareketinde insan hareketinin birbirine benzerliği söylenebilir. Sürünme ile emekleme hareketleri içinde aynı şey söylenebilir. Ancak hareketler her ne kadar birbirlerine benzese de birbirlerinden farklı oldukları Şekil 4.2 incelendiği zaman anlaşılabilir. Birbirine en çok benzeyen koşma ve yürüme hareketleri birbirlerine ne kadar çok benzediği iki hareket arasında belirgin farklılıklar yer almaktadır. Bu farklılıklar Şekil 4.2a ve 4.2b incelendiğinde hareketlerin merkez Doppler frekanslarını oluşturan gövde frekansının yürüme hareketine göre koşma


hareketinde daha büyük olduđu görülebilir. Aynı Şekilde aynı zaman diliminde koşma hareketinde bacaklar ve kollar yürüme hareketine göre daha fazla sallanır. Bu sallanmalara ek olarak insan gövdesi de koşma hareketinde daha fazla sallanır. Şekil 4.2a ve 4.2b incelendiğinde koşma ve yürüme hareketlerinin mikro-Doppler izlerinin periyodik bir yapıda olduđu ve koşma hareketinde bu periyodun daha küçük olduđu görülebilir. Bu periyodun koşma hareketinde yürüme hareketine göre daha küçük olmasının nedeni aynı zaman diliminde kol, bacak, gövde, baş vb. salınımların daha fazla ya da daha sık yapılması olarak gösterilebilir. Benzer yapıda Şekil 4.2c ve 4.2d emekleme ve sürünme için incelendiğinde periyodik bir mikro-Doppler izinden ve merkez Doppler frekansının emekleme hareketinde sürünme hareketine göre biraz daha yüksek olduğundan bahsedilebilir. Emekleme ve sürünme hareketlerinde periyot aşağı-yukarı söylenebilse de, bu periyodik yapı yürüme ve koşma hareketleri kadar açık ve bariz değildir. Emeklemenin merkez Doppler frekansının sürünmeden fazla olmasının nedeni ise bu hareketler her ne kadar çok benzer olsa da emeklerken insan vücut parçalarının sürünme hareketine göre daha fazla sallanması ve hareket hızının daha fazla olması gösterilebilir. Bunun etkisi sonucunda ortaya çıkan mikro-Doppler izlerindeki farklılıklar, emekleme ve sürünme için Şekil 4.2c ve Şekil 4.2d kıyaslanıp incelendiğinde daha açık bir şekilde anlaşılabilir.

Benzer kıyaslamalar hareketler kendi içlerinde incelediğinde de yapılabilir. Bu amaçla sürünme hareketinin iki farklı verisinin verildiği Şekil 4.3a ve 4.3b incelenirse iki hareketin arasında farklılık olduđu ve Şekil 4.3b'deki sürünme hareketinin, Şekil 4.3a'daki sürünme hareketi yerine Şekil 4.2d'deki sürünme hareketine daha fazla benzediği rahatlıkla görülebilir. Bunun temel nedeni verilerin, toplandığı insanlara duyarlı olduđu ve bir insanın sürünme hareketinin başka bir insanın emekleme hareketine benzemesi olarak gösterilebilir.



Şekil 4.3: 0° için CMU veri tabanından elde edilen farklı sürünme spektrogramları a) sürünme hareketi, b) sürünme hareketi

Bu tez kapsamında mikro-Dopplerin radarla insan arasındaki açıya bağımlılığına göre insan hareketlerinin sınıflandırılması yer almaktadır. Bundan ötürü Şekil 4.2 ve Şekil 4.3'te verilen 0° 'deki hareket spektrogramlarının bazı farklı açı değerlerinde nasıl değiştiği görülmesi önem teşkil etmektedir. Böylece radar ile hedef arasındaki açı değiştikçe sınıflandırma başarımının nasıl değişeceği konusuna ışık tutulmuş olunabilir. Bu amaçla 30° , 45° , 60° ve 90° için elde edilen spektrogramlar hareket hareket gösterilip açısal farklılık anlatılmaya çalışılacaktır. Şekil 4.4'te 30° , 45° , 60° ve 90° için elde edilen aynı insana ait yürüme verisinin spektrogramları görülebilir.




Şekil 4.4: Yürüme hareketinin farklı açılardaki spektogramları - a) 30° , b) 45° , c) 60° , d) 90°


Şekil 4.4'ten radarla hedef arasındaki açı arttıkça mikro-Doppler izlerinin gittikçe sıkışmakta ya da daralmakta olduğu görülmektedir. Bu etki Bölüm 2.3'de Denklem (2.6a)'daki ifadeye bakılınca anlaşılabilir. Denklem (2.6a)'daki $\cos(\theta)$, (θ hedefle radar doğrultusundaki açı olduğu zaman) bu etkiye sebep olmaktadır. Bilindiği gibi kosinüs fonksiyonu açıya göre 0-1 arasında değerler alır. Bir değerini açı sıfırdayken, sıfır değerini ise açı doksan derecedeyken alır. Bu özellikten yola çıkılarak ve Denklem (2.6a) kullanılarak mikro-Doppler izlerinin açı 0° 'den 90° 'ye giderken gittikçe daralması beklenir ki Şekil 4.4'e bakıldığında beklenen bu olayın gerçekleştiği görsel olarak görülebilir. İnsanla radar doğrultusu arasındaki açı 90° olduğu zaman radar doğrultusunda insanın herhangi bir hızı kalmadığından mikro-Doppler izi çıkarılamaz. Bu ifadenin Denklem (2.6)'ya bakıldığı zaman doğru olduğu görülmektedir. Böylece hesaplanacak bir mikro-Doppler kalmaz ve mikro-Doppler izi

sıfır olur. Ancak Şekil 4.4'e bakıldığında micro-Doppler etkisinin 90° 'de sıfır olmadığı görülebilir. Burada bu etkinin sıfır olmamasının nedeni, insanın her ne kadar radar yönünde direkt bir hareketi olmasa da, vücut parçalarının hareketlerinin, titreşimlerinin ve salınımlarının azda olsa radar yönünde bir hıza sahip olmaları olarak gösterilebilir. Ayrıca Denklem (2.6a)'ya göre sıfır çıkan bir etkinin CMU MOCAP veri tabanından elde edilen benzetim verilerinde sıfır çıkmaması bahsedilen nedenden ötürüdür. Bu sonuçta CMU MOCAP veri tabanının gerçek insanlardan toplanmasından ötürü benzetim sonuçlarının gerçek radar verilerine yakın sonuçlar verdiğini göstermektedir.


Bu kısımda CMU MOCAP veri tabanından elde edilen veriler tanıtıldığı için diğer hareketlerinde açısal değişimle mikro-Doppler izlerinin nasıl değiştiği gösterilecektir. Diğer hareket tiplerinde de açı değiştiği zaman mikro-Doppler izlerinin nasıl değiştiği koşma hareketi için Şekil 4.5, emekleme hareketi için Şekil 4.6 ve sürünme hareketi için Şekil 4.7'ye bakıldığında rahatça görülebilir.




(a)



(b)




(c)




(d)

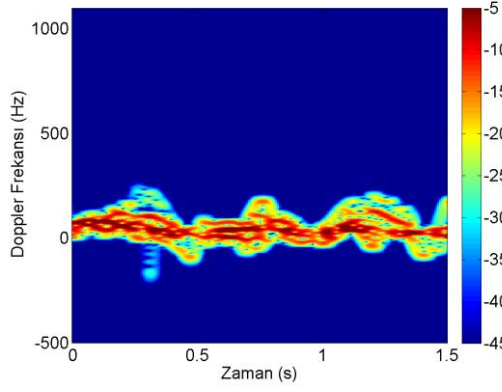
Şekil 4.5: Koşma hareketinin farklı açılardaki spektrogramları - a) 30° , b) 45° , c) 60° , d) 90°




(a)



(b)




(c)




(d)

Şekil 4.6: Emekleme hareketinin farklı açılardaki spektogramları - a) 30° , b) 45° , c) 60° , d) 90°



Şekil 4.7: Sürünme hareketinin farklı açılardaki spektrogramları - a) 30° , b) 45° , c) 60° , d) 90°

0° ile 180° derecedeki micro-Doppler izlerinin spektrogram üzerindeki izleri x-ekseni etrafında 180° 'lik bir döndürmeden bahsedebiliriz. Burada bu 180° 'lik döndürmeden sonra y-eksenindeki frekans değerleri değişmez. Bu durumdan Bölüm 2.3'te Denklem (2.6a) açıklanırken bahsedilmişti. Hedef radara yaklaşıyorsa Doppler etkisi Denklem (2.6)'ya göre pozitif değer alır. Eğer hedef radardan uzaklaşıyorsa Doppler izi Denklem (2.6)'ya göre negatif değer alır. Bahsedilen bu etki 0° ve 45° radardan uzaklaşma açılarının, radara yaklaşma açıları olan 180° ve 135° açılarıyla incelendiğinde Şekil 4.8'de gösterilecektir. Böylece bu etki daha net bir şekilde anlaşılacaktır.



Şekil 4.8: Aynı insanın 0° , 45° , 135° ve 180° 'deki micro-Doppler izleri- a) 0° , b) 180° , c) 45° , d) 135°

4.2 Çıkarılan Özniteliklerin Tanıtımı

Bu kısımda çıkarılan özniteliklerin çıkarılma metotları hakkında bilgi verilecektir. Önceki kısımlarda da bahsedildiği gibi öznitelik olarak adlandırılan değişkenler, sınıflandırılacak sınıflarda ortak olarak bulunan ama bu sınıfların farklılıklarını ortaya koyan değişkenlerdir. Bu tez kapsamında benzetimler sonucu oluşturulan spektogramlar üzerinden çıkarılan öznitelikler kullanılarak çalışmalar gerçekleştirilmiştir. Çıkarılan öznitelikler alt bölümler şeklinde bu kısımda verilecektir. Özniteliklerin çıkarılma metotları verilmeden önce bazı tüm öznitelikler numaralandırılarak verilecek ve ilerleyen bölümlerde bu öznitelik isimleri yerine bu numaralar kullanılacaktır.

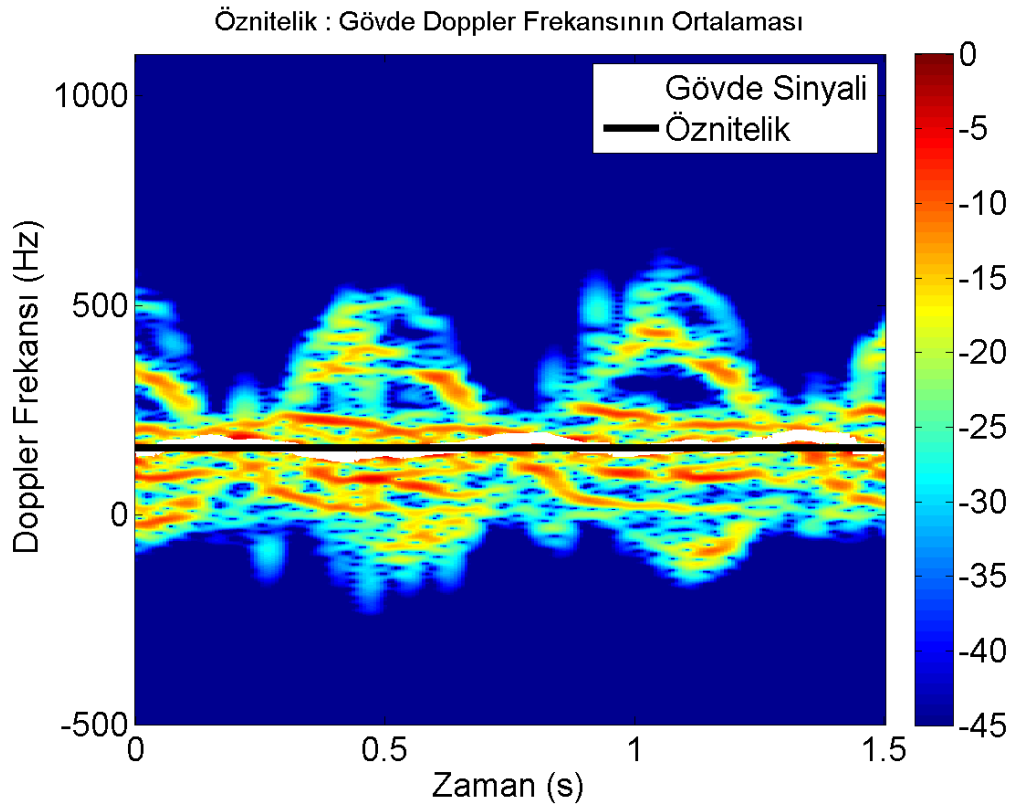
Çıkarılan Öznitelikler:

- 1) Gövde Doppler Frekansının Ortalaması
- 2) Gövde Salınımının Bant Genişliği
- 3) Üst Zarfın Maksimum Değeri
- 4) Alt Zarfın Minimum Değeri
- 5) Toplam Doppler Bant Genişliği
- 6) Üst Zarfın Ortalama Değeri
- 7) Alt Zarfın Ortalama Değeri
- 8) Alt ve Üst Zarf Ortalamaları Arasındaki Bant Genişliği
- 9) Alt ve Üst Zarf Ortalamalarının Ortalaması
- 10) Alt Zarfın Minimum ve Üst Zarfın Maksimum Değerlerinin Ortalaması

4.2.1 Gövde Doppler Frekansının Ortalaması

Sinyalin KZFD'si alındıktan sonra oluşturulan spektogram matrisinin her bir sütundaki en yüksek güce sahip olan eleman bulunur. Daha sonra bu elemanın Doppler frekans eksenindeki konumu bulunarak bu konuma karşılık gelen Doppler frekansı bulunur. Bu işlem, spektogram matrisinin tüm sütunları boyunca devam eder. Sonuç olarak spektogram matrisinin sütun sayısı kadar uzunlukta Doppler frekanslarını içeren bir vektör oluşur. Bu vektör içerisinde yer alan Doppler frekansları

gövde Doppler sinyalini vermektedir, başka bir deyişle bu vektör içerisinde yer alan Doppler frekansları gövde Doppler sinyalinin her bir spektogram matrisinin her bir sütunundaki parçalarıdır. Gövde salınımı bulunduktan sonra ise bu vektörün ortalaması alınarak Şekil 4.9’de gösterilen ve öznitelik olarak kullanılan Gövde Doppler Frekansının Ortalaması bulunmaktadır.

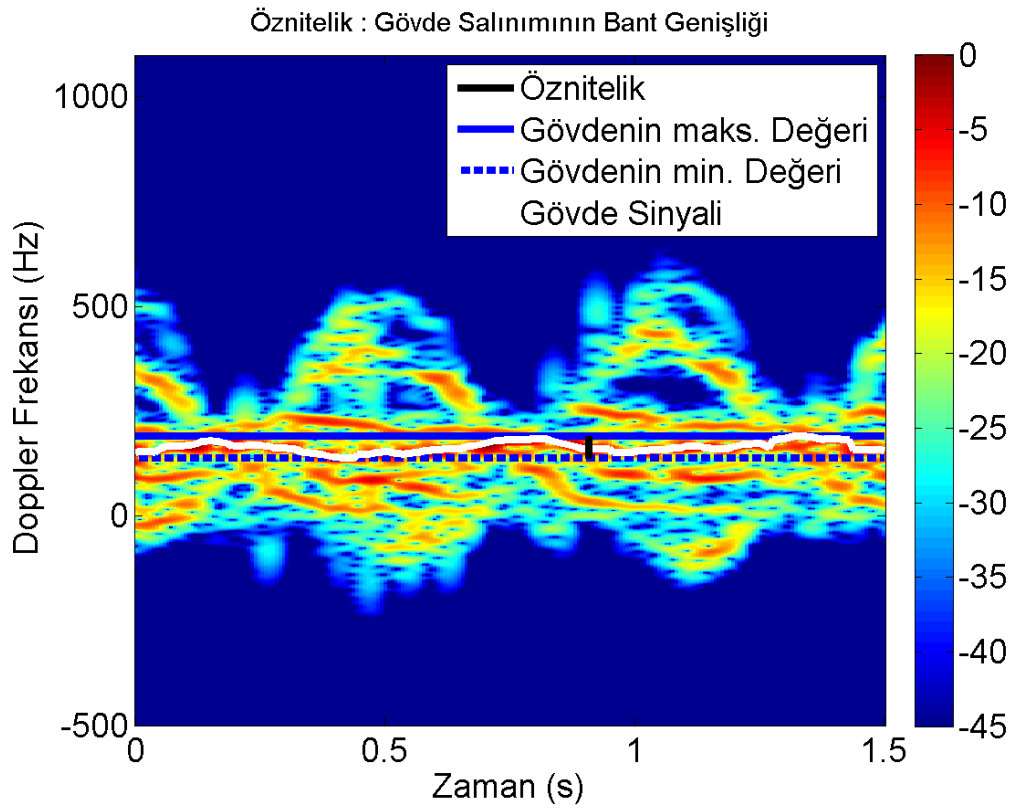


Şekil 4.9: Gövde Doppler frekansının ortalaması

4.2.2 Gövde Salınımının Bant Genişliği

Sinyalin KZFD’si alındıktan sonra oluşturulan spektogram matrisinin her bir sütunundaki en yüksek güce sahip olan eleman bulunur. Bu işlem spektogram matrisinin tüm sütunları için gerçekleştirilir. Daha sonra bu elemanların Doppler frekans eksenindeki konumları bulunarak bu konumlara karşılık gelen Doppler frekansları bulunur. Sonuç olarak spektogram matrisinin sütun sayısı kadar uzunlukta olan ve Doppler frekanslarını içeren bir vektör oluşmaktadır. Bu vektör içerisinde yer

alan Doppler frekansları gövde Doppler sinyalini vermektedir, başka bir deyişle bu vektör içerisinde yer alan Doppler frekansları gövde Doppler sinyalinin her bir spektogram matrisinin her bir sütunundaki parçalarıdır. Bu vektörün maksimum ve minimum noktaları bulunarak bu iki nokta arasındaki bant genişliği bulunur. Bu bant genişliğinin mutlak değeri Şekil 4.10'da gösterilen ve öznitelik olarak kullanılan gövde salınımının bant genişliğini vermektedir.

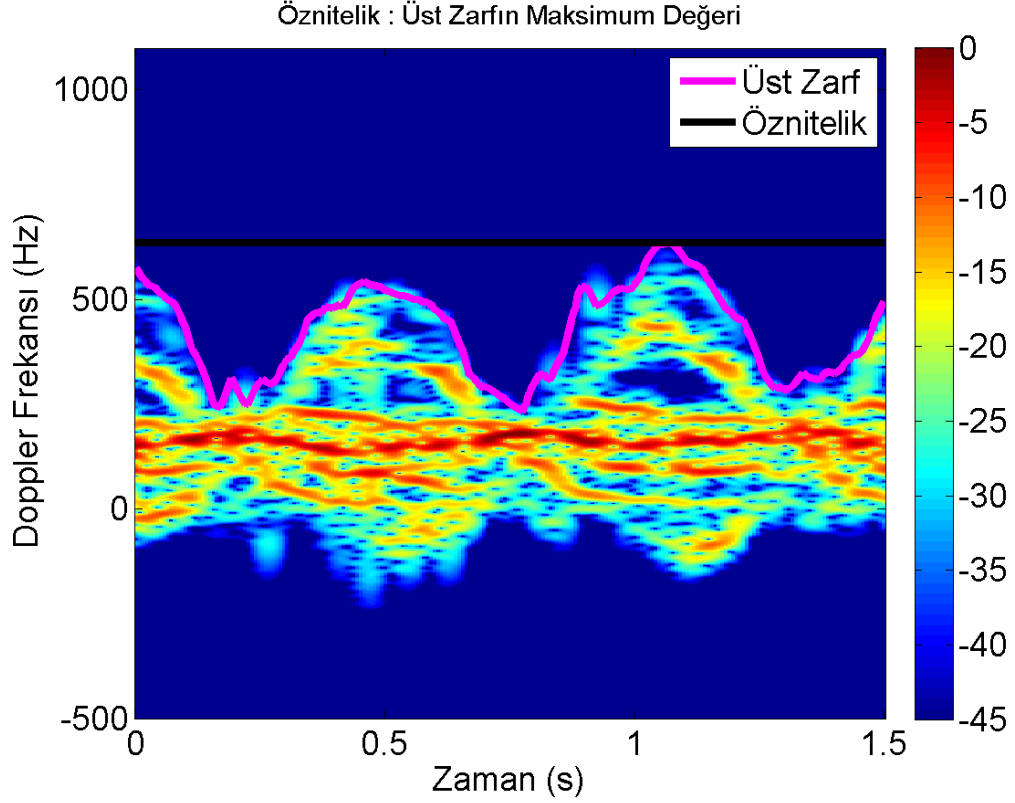


Şekil 4.10: Gövde salınımının bant genişliği

4.2.3 Üst Zarfın Maksimum Değeri

Sinyalin KZFD'si alındıktan sonra oluşturulan spektogram matrisinin her bir sütununda belli bir eşik değeri'nin üstünde güç değerine sahip olan tepe değerleri bulunur. Daha sonra ise bulunan bu tepe değerlerinin ilk başındaki tepe değerleri bulunup, bulunan bu tepe değerlerinin spektogram matrisinde buldukları sütundaki konumları bulunur. Sütun üzerinde konumlar bulduktan sonra bu konumlar üzerinden Doppler frekansları bulunur. Böylece ilk tepe değerleri bulunarak

spektrogram sütunları boyunca üst zarf oluşturulur. Üst zarfın maksimum Doppler frekans değeri öznitelik olarak kullanılan ve Şekil 4.11’da gösterilen üst zarfın maksimum değerini vermektedir.

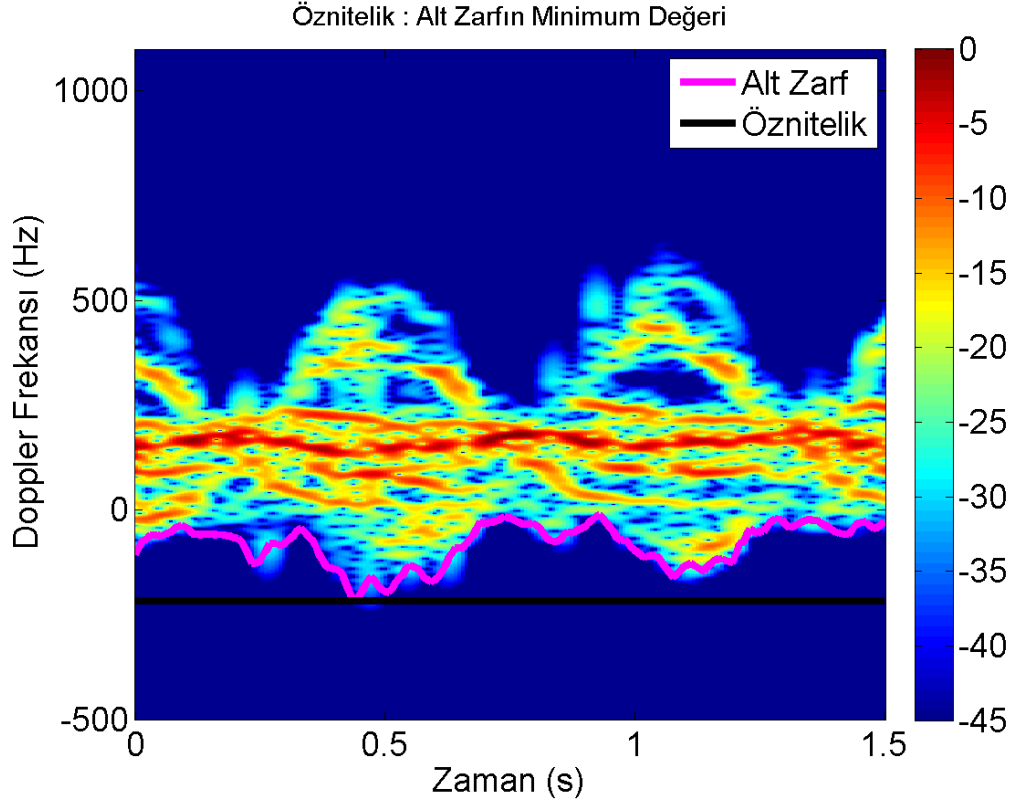


Şekil 4.11: Üst zarfın maksimum değeri

4.2.4 Alt Zarfın Minimum Değeri

Sinyalin KZFD’si alındıktan sonra oluşturulan spektrogram matrisinin her bir sütununda belli bir eşik değerinin üstünde güç değerine sahip olan tepe değerleri bulunur. Daha sonra ise bulunan bu tepe değerlerinin son olanları tepe değerleri bulunup bulunan bu tepe değerlerinin spektrogram matrisinde buldukları sütundaki konumları bulunuyor. Sütun üzerinde konumlar bulduktan sonra bu konumlar üzerinden Doppler frekansları bulunur. Böylece son tepe değerleri bulunarak spektrogram sütunları boyunca alt zarf oluşturulur. Alt zarfın minimum Doppler


frekans değeri öznitelik olarak kullanılan ve Şekil 4.12’de gösterilen alt zarfın minimum değerini vermektedir.



Şekil 4.12: Alt zarfın minimum değeri

4.2.5 Toplam Doppler Bant Genişliği


Sinyalin KZFD’si alındıktan sonra oluşturulan spektrogram matrisinin her bir sütununda belli bir eşik değerinin üstünde güç değerine sahip olan tepe değerleri bulunur. Daha sonra ise bulunan bu tepe değerlerinin ilk ve son tepe değerleri bulunup, bulunan bu tepe değerlerinin spektrogram matrisinde buldukları sütundaki konumları bulunur. Sütun üzerinde konumlar bulunduktan sonra bu konumlar üzerinden Doppler frekansları bulunur. Böylece ilk ve son tepe değerleri bulunarak spektrogram sütunları boyunca üst ve alt zarf oluşturulur. Üst zarfın maksimum Doppler frekans değeri ile alt zarfın minimum Doppler frekans değeri arasındaki bant genişliği öznitelik olarak kullanılan ve Şekil 4.13’de gösterilen toplam Doppler bant genişliğini vermektedir.



Şekil 4.13: Toplam Doppler bant genişliği

4.2.6 Üst Zarfın Ortalama Değeri


Sinyalin KZFD'si alındıktan sonra oluşturulan spektrogram matrisinin her bir sütununda belli bir eşik değerinin üstünde güç değerine sahip olan tepe değerleri bulunur. Daha sonra ise bulunan bu tepe değerlerinin ilk başındaki tepe değerleri bulunup, bulunan bu tepe değerlerinin spektrogram matrisinde buldukları sütundaki konumları bulunur. Sütun üzerinde konumlar bulunduktan sonra bu konumlar üzerinden Doppler frekansları bulunur. Böylece ilk tepe değerleri bulunarak spektrogram sütunları boyunca üst zarf oluşturulur. Üst zarfın ortalaması alınarak hesaplanan Doppler frekans değeri öznitelik olarak kullanılan ve Şekil 4.14'te gösterilen üst zarfın ortalama değerini vermektedir.



Şekil 4.14: Üst zarfın ortalama değeri

4.2.7 Alt Zarfın Ortalama Değeri


Sinyalin KZFD'si alındıktan sonra oluşturulan spektrogram matrisinin her bir sütununda belli bir eşik değerinin üstünde güç değerine sahip olan tepe değerleri bulunur. Daha sonra ise bulunan bu tepe değerlerinin son tepe değerleri bulunup, bulunan bu tepe değerlerinin spektrogram matrisinde buldukları sütundaki konumları bulunur. Sütun üzerinde konumlar bulunduktan sonra bu konumlar üzerinden Doppler frekansları bulunur. Böylece son tepe değerleri bulunarak spektrogram sütunları boyunca alt zarf oluşturulur. Alt zarfın ortalaması alınarak hesaplanan Doppler frekans değeri öznitelik olarak kullanılan ve Şekil 4.15'te gösterilen alt zarfın ortalama değerini vermektedir.



Şekil 4.15: Alt zarfın ortalama değeri

4.2.8 Alt ve Üst Zarf Ortalamaları Arasındaki Bant Genişliği


Sinyalin KZFD'si alındıktan sonra oluşturulan spektrogram matrisinin her bir sütununda belli bir eşik değerinin üstünde güç değerine sahip olan tepe değerleri bulunur. Daha sonra ise bulunan bu tepe değerlerinin ilk ve son tepe değerleri bulunup, bulunan bu tepe değerlerinin spektrogram matrisinde buldukları sütundaki konumları bulunur. Sütun üzerinde konumlar bulduktan sonra bu konumlar üzerinden Doppler frekansları hesaplanır. Böylece ilk ve son tepe değerleri bulunarak spektrogram sütunları boyunca üst ve alt zarf oluşturulur. Üst zarf ve alt zarfın ortalamaları hesaplanarak bu ortalamalar arasında kalan Doppler bant genişliği bulunur. Bulunan bu Doppler bant genişliği öznitelik olarak kullanılan ve Şekil 4.16'te gösterilen alt ve üst zarf ortalamaları arasındaki bant genişliğini vermektedir.



Şekil 4.16: Alt ve üst zarf ortalamaları arasındaki bant genişliği

4.2.9 Alt ve Üst Zarf Ortalamalarının Ortalaması


Sinyalin KZFD'si alındıktan sonra oluşturulan spektrogram matrisinin her bir sütununda belli bir eşik değerinin üstünde güç değerine sahip olan tepe değerleri bulunup, bulunan bu tepe değerlerinin ilk ve son tepe değerleri bulunur. Daha sonra bulunan ilk ve son tepe değerlerinin spektrogram matrisinde buldukları sütundaki konumları ve bu konumlar üzerinden de Doppler frekansları hesaplanır. Böylece ilk tepe değerlerinin oluşturduğu üst zarf ve son tepe değerlerinin oluşturduğu üst zarf bulunarak bu zarfların ortalamaları hesaplanır. Bu hesaplanan ortalamalarında ortalaması alınarak öznitelik olarak kullanılan ve Şekil 4.17'ta gösterilen alt ve üst zarf ortalamalarının ortalaması bulunur.



Şekil 4.17: Alt ve üst zarf ortalamalarının ortalaması

4.2.10 Alt Zarfın Minimum ve Üst Zarfın Maksimum Değerleri Ortalaması

Sinyalin KZFD'si alındıktan sonra oluşturulan spektrogram matrisinin her bir sütununda belli bir eşik değerinin üstünde güç değerine sahip olan tepe değerleri bulunur. Daha sonra ise bulunan bu tepe değerlerinin ilk ve son tepe değerleri bulunup, bulunan bu tepe değerlerinin spektrogram matrisinde buldukları sütundaki konumları bulunarak bu konumlar üzerinden bu tepe değerlerinin Doppler frekans değerleri bulunur. Böylece ilk ve son tepe Doppler frekans değerleri bulunarak spektrogram sütunları boyunca üst ve alt zarf oluşturulur. Üst zarfın maksimum Doppler frekans değeri ile alt zarfın minimum Doppler frekans değerlerinin ortalaması öznitelik olarak kullanılan ve Şekil 4.18'de gösterilen alt zarfın minimum ve üst zarfın maksimum değerlerinin ortalamasını vermektedir.



Şekil 4.18: Alt zarfın minimum ve üst zarfın maksimum değerlerinin ortalaması

4.3 Öznitelik Seçimi

Bölüm 4.2’de bahsedilen özniteliklerin, sınıflandırma işleminde kaç tanesinin ve bu sayıda, önerilen özniteliklerin hangilerinin kullanılacağı seçim işlemini gerektirmektedir. Çünkü istenilen sayıda uygun özniteliklerin bulunması performansı optimum hale getirecektir. Ancak istenen sayıda rastgele seçilen öznitelikler sınıflandırma performansını kötü etkileyebilirler. Bu kötü etkiyi ortadan kaldırmak ve başarıyı arttırmak için istenen sayıda ve beraber kullanıldığında başarıyı optimum yapan öznitelikler seçilmelidir. Bu tez kapsamında öznitelik seçim aşamasında özniteliklerin seçimi için Bölüm 2.4’de anlatılan karşılıklı bilgi miktarı kullanımının etkisi incelenmiştir. Özniteliklerin boyutunun büyümesi, karşılıklı bilgi miktarının hesaplanmasında gittikçe büyüyen bir yük getirdiğinden Bölüm 3.2.2’de bahsedilen ve karşılıklı bilgi miktarının hesaplanması için önerilen metotlar kullanılmıştır. Bu tezdeki çalışmada karşılıklı bilgi miktarını hesaplamak için MIFS, MIFS-U ve mRMR yöntemleri kullanılmıştır. Üç yöntemdeki temel mantık aynı olmakla beraber karşılıklı

bilgi miktarının elde edilebilmesi için bu temel mantık üzerinden bir takım değişikliklerin yapılmış halleridir. Her üç yöntemde S kümesi boş olarak başlar ve her seferinde öznitelikleri tek tek seçerek bu S kümesini doldururlar. Karşılıklı bilgi miktarının hesaplanması için olasılık kütle ve marjinal olasılık kütle fonksiyonlarının hesaplanması gerekmektedir. Burada bu fonksiyonlar histogramlar üzerinden hesaplanmıştır. Bu histogramlar Denklem (3.2), (3.3) ve (3.4)'te verilen $I(f_i;C)$ ve $I(f_s,f_i)$ ifadelerini hesaplamak için kullanılmıştır. Denklem (2.12)'den hatırlanabileceği gibi bu iki ifade olasılık kütle ve marjinal olasılık kütle fonksiyonları üzerinden hesaplanmaktadır. Hatırlanacağı gibi sınıflandırma işlemimizde dört sınıf yer almaktadır. Dolayısıyla $I(f_i;C)$ histogramın bir eksenini bu dört sınıfı temsil eden 4 sütundan ve diğer eksenini işlemi yapılan özneliğin değerlerini içeren ve satırları kullanıcı tarafından belirlenen n adet satırdan oluşmaktadır. $I(f_s,f_i)$ ifadesinde ise histogramın iki eksenini de seçilen ve seçilecek öznelikleri temsil etmektedir ve bu iki eksen sayısı kullanıcı tarafından belirlenen n adet satır ve sütuna bölünmüştür. Bu çalışmada bu n sayısı 100 olarak seçilmiş ve kullanılmıştır.

Öznitelik seçimi için MIFS, MIFS-U ve mRMR yöntemlerinin dışında öznelikleri deneyerek seçimi yapan ileri yönlü wrapper metodu bu üç yöntemin başarısının incelenmesi için bu tez kapsamında öznitelik seçimi için kullanılmıştır. Wrapper metodunun maksimum başarıyı veren öznelikleri seçtiği için bu yöntemle karşılıklı bilgi miktarını hesaplayan yöntemlerin kıyaslanması bu üç yöntemin başarısını daha açık bir şekilde ortaya koyacaktır. Böylece zamansal ve karmaşıklık içeren wrapper metodundan ziyade ön işlemlerden geçirilen karşılıklı bilgi miktarının başarısı gösterilecektir.

4.4 Sınıflandırma İşleminin Tanıtımı

Sınıflandırma işlemi özneliklerin başarılı bir şekilde verilerden elde edilmesiyle başlar. Daha sonra sınıflandırıcının seçimi ve özneliklerin bu sınıflandırıcı ile işlenmesiyle sınıflandırma işlemi devam ederek sınıfların ayrımı ve başarımın bulunmasıyla sona erer. Bu tez kapsamında insanın yürüme, koşma, emekleme ve sürünme hareketlerinin radar verileri ile incelenerek bu dört sınıfın farklı açılarda

birbirinden ayrılıp, başarımlarının arttırılması ve bu işlem yapılırken zamandan tasarruf edilebilmesi için bu yüksek başarıyı verecek en az öznitelik seçimi hedeflenmiştir.

Tüm sınıflandırıcı metotlarında öznitelikler genel olarak 2 gruba ayrılırlar. Bu gruplar eğitim ve test grupları olarak adlandırılır. Eğitim verileri ile sınıflandırıcı, sınıfların ayrılabilmesi için eğitilir. Her sınıflandırıcı eğitim için ayrılan öznitelikleri birbirinden ayırmak ve test grubundan gelen öznitelikleri kullanarak o özniteliklerin ait olduğu veriyi uygun sınıfa koymak için değişik metotlar kullanırlar. Bir kısmı istatistiksel metotlar kullanarak eğitim verilerinin öznitelikleri ile belli bir model oluşturur ve test verilerinin özniteliklerinin oluşturulan modellere uyup uymadığına bakarak bu verileri sınıflandırır. Bir kısmı öznitelik uzayını verilerin en rahat ayrılabilceği şekilde bölerler. Daha sonra ise test grubunun verilerini bu uzaydaki uygun bölümlere koyarak sınıflandırma işlemine devam eder ve verileri sınıflandırır.

Buradaki çalışmada sınıflandırıcı olarak kNN seçilmiştir. kNN'nin seçilmesindeki en temel amaç ikiden fazla sınıfa rahatça ayrılabilmesi olarak özetlenebilir. SVM'in aksine öznitelik uzayını bir fonksiyonla sınıfların rahatça ayrılabilceği gibi ikiye bölmez (SVM maksimum iki sınıfa seçebileceğinden ötürü bu çalışmada kullanılmamıştır). kNN test verilerinden gelen herhangi bir verinin, eğitim verilerinden en yakın K sayıda komşuna bakar ve bu komşuların çoğunluğunun ait olduğu sınıfa test verilerinden gelen bu herhangi verinin sınıfı olarak atar.

Bu tez kapsamında yapılan çalışmada kNN sınıflandırıcısı için komşuluk sayısı birden yediye kadar değiştirilmiş ve komşuluk sayısı için altı komşuluk seçilmiştir. Sonuçlar kısmında elde edilen sonuçlar verilecektir. Şimdilik sadece eğitim ve test verilerinin nasıl seçildiği ve sınıflandırma işleminin nasıl gerçekleştirildiği hakkında bilgi verilecektir.

Sınıflandırma işleminin başında öznitelikler Bölüm 4.2'de anlatıldığı gibi CMU MOCAP verilerinden çıkarıldıktan sonra Bölüm 2.4'te teorisi verilen karşılıklı bilgi miktarı kullanılarak seçim işlemi gerçekleştirilmiştir. Ancak öznitelik sayısı büyük

olunca bu yöntemin getirdiği yükümlülükten kurtulmak için Bölüm 3.2.2’de bahsedilen karşılıklı bilgi miktarını hesaplamak için önerilen metotlar kullanılarak öznitelikler seçilmiştir. Bu metotların başarımının ve seçtikleri özniteliklerin ne kadar başarılı olduğunun karşılaştırılması için Bölüm 3.2.1.1’de anlatılan ileri yönlü wrapper uygulanarak öznitelikler seçilmiştir. Daha sonra CMU MOCAP verilerinden elde edilen tüm öznitelikler arasından, seçilen öznitelikler alınarak her bir sınıf için yeni bir veri tabanı oluşturulmuştur. Bu veri tabanları 196 yürüme, 71 koşma, 38 emekleme ve 73 sürünme verisinin seçilen özniteliklerini içermektedir. Sınıfları temsil eden bu veri tabanlarının her birinin %60’lık kısmı rastgele seçilerek her bir sınıf için eğitim verilerini içeren bir veri tabanı oluşturulmuştur. Her bir sınıf veri tabanında seçilmeyen ve geriye kalan %40’lık veri ise test verisi olarak ayrılmıştır. Sınıflandırma işleminin yapılması için eğitim ve test verilerinin yanında KNN sınıflandırıcısına komşuluk sayısı da girilir. Komşuluk sayısı, her bir test verisinin sınıflandırılması için sınıflandırılan test verisinin, eğitim verilerinden en yakın kaç komşusuna bakılacağını söyleyen bir parametredir.

Sınıflandırma işleminin eğitim ve test verileri üzerinden yapıldığı konusundan bahsedilerek bu işlemin sonucunun nasıl elde edildiği konusu hakkında bilgi verilmiştir. Eğitim ve test verilerinin rastgele seçildiğinden bahsedilmiştir. Bu sebeple aynı veri tabanı üzerinden yapılan sınıflandırma başarımı, eğitim ve test verilerinin içerikleri değiştirildikçe değişmektedir. Bu amaçla bahsedilen sınıflandırma işlemi 10 kez tekrarlanmıştır. Ayrıca gerçek başarıma ulaşmak için bu 10 kez tekrarlanan sınıflandırma işleminden elde edilen başarımların ortalaması alınmıştır. Bu şekilde her bir eğitim ve test veri tabanları değiştirilerek, değişik veri tabanlarının başarımlarının nasıl değiştiği gözlemlenmiş ve değişik verilerin sınıflandırmaya hem eğitim hem de test olarak sokularak belli bir başarıma ulaşmaya çalışılmıştır.

5 SONUÇLAR

Bu bölümde karşılıklı bilgi miktarı tabanlı öznitelik seçim algoritmaları olan MIFS, MIFS-U ve mRMR algoritmaları ile elde edilen öznitelik seçim sonuçları, ileri yönlü wrapper ile elde edilen öznitelik seçim sonuçları ile karşılaştırılacaktır. Ayrıca bu algoritmalar ile elde edilen başarımlar paylaşılacaktır. Karşılıklı bilgi miktarı tabanlı yöntemlerin ileri yönlü wrapper ile kıyaslanmasındaki neden, ileri yönlü wrapper'ın başarımlar için bir üst limit oluşturması ve karşılıklı bilgi miktarı tabanlı bu yöntemlerin performansının bu üst limitle incelenmesi olarak açıklanabilir. Bazı radarların hedefi takip edebilme yeteneği olduğundan hedefin radarla olan açısı bulunabilmektedir. Ancak bazı radarlarda da bu yetenek bulunmamaktadır. Bundan dolayı hedefin takip edilemediği durumlarda hedef pozisyonun tahmin edilmesi gerekmektedir. Bu nedenden ötürü bu tez kapsamında yapılan çalışmalarda hedefle radar arasındaki açının bilinmesi ve açının bilinmemesi durumları incelenmiştir. Yapılan çalışmalar ve elde edilen sonuçlar, hedefle radar arasındaki açının bilinmesi ve açının bilinmemesi olmak üzere iki temel başlık altında verilecektir.

5.1 Hedefle Radar Arasındaki Açının Bilinmesi Durumu

Bu bölümde hedefle radar arasındaki açının bilinmesi durumu için elde edilen sonuçlar paylaşılacaktır. Bu kısımda öznitelik seçimi ve sınıflandırma işlemi, benzetim sonucunda elde edilen veri tabanındaki her bir açı değeri için ayrı ayrı yapılmıştır. Bölüm 4'te belirtildiği gibi, veri tabanındaki açı değerleri 0° ile 180° arasında değişmektedir. Ayrıca veri tabanında bulunan sınıf sayısı yürüme, koşma, emekleme ve sürünme olmak üzere dört tanedir. Yine Bölüm 4'te belirtildiği gibi her bir sınıfa ait verilerin %60'ı eğitim ve %40'ı test için rastgele seçilmiştir. Karşılıklı bilgi miktarı tabanlı yöntemler ve ileri yönlü wrapper ile en uygun sayıda optimal başarıyı veren özniteliklerin seçilmesi için sınıflandırma sonuçları her açı değerinde 10 kez rastgele seçilen eğitim ve test verilerinden elde edilmiştir. Bu işlem sonucunda her algoritma ve açı değeri için 10 farklı öznitelik seti elde edilmiştir. Bu 10 farklı öznitelik setinden her bir açı değeri için elde edilen sonuçların arasından seçilen üç açı ($0^\circ, 45^\circ, 90^\circ$) ile 0°

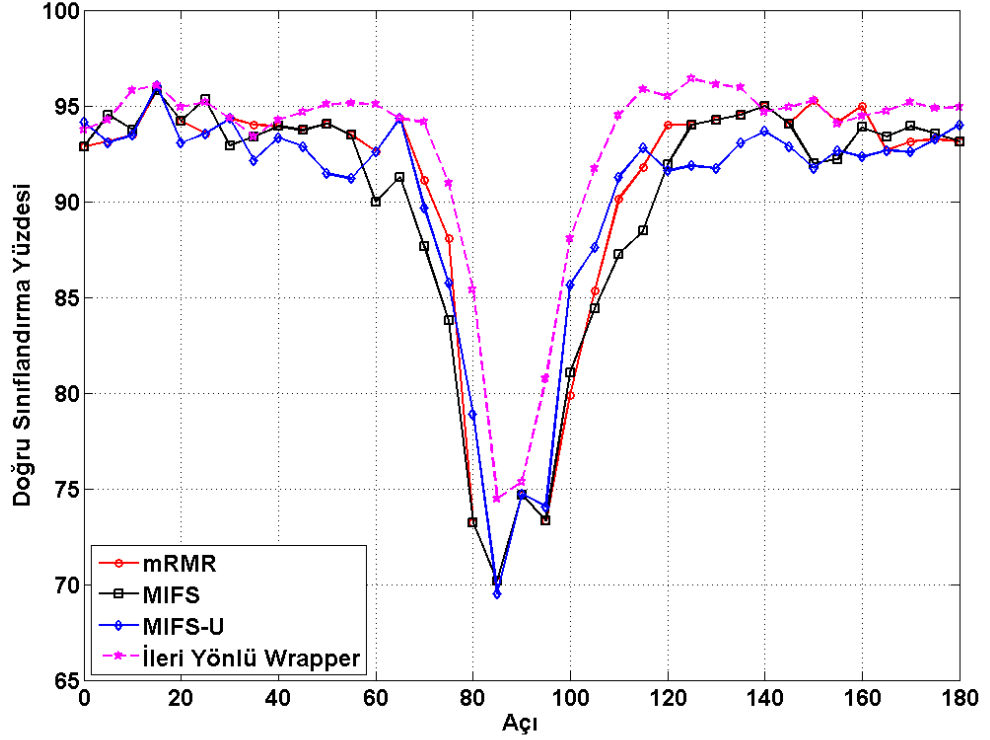
ve 180° arasındaki açılar üzerinden elde edilen ortalama başarımlar, yöntemlerin başarımlarının gösterilmesi için Çizelge 5.1’de verilmiştir.

Çizelge 5.1: Bilinen açı değeri için yöntemlerin seçtiği özniteliklere göre sınıflandırma başarımları

Hedefle Radar Arasındaki Açı	Method	Seçilen Öznitelik sayısı									
		1	2	3	4	5	6	7	8	9	10
0°	mRMR	91,7	93,9	92,9	94,3	94,6	95	94,9	94,6	93,7	93,2
	MIFS	91,7	93,9	92,9	93,5	94,6	95	94,6	93,3	93,7	93,2
	MIFS-U	91,7	92,3	94,1	94,3	94,6	95	94,6	94,6	93,7	93,2
	Wrapper	91,7	95,2	93,7	93,5	94,6	95,1	95,1	94,6	93,4	93,2
45°	mRMR	92,4	93	93,7	92,3	91,1	90,8	91,2	91,5	91,6	90,7
	MIFS	92,4	93	93,7	94	92,8	91,4	91,2	91,5	91,6	90,7
	MIFS-U	92,4	92,5	92,9	93,7	92,1	91,3	91,2	91,5	91,6	90,7
	Wrapper	92,4	95,5	94,7	95,1	93,9	94,1	93,9	93,1	91,8	90,7
90°	mRMR	62,5	65,9	74,7	73,3	64,1	68,1	64,9	68,9	69,7	69,7
	MIFS	62,5	65,9	74,7	70,1	69,5	68,1	68,7	68,9	69,7	69,7
	MIFS-U	62,5	70,2	74,7	70,5	70,9	68,1	69,3	69,9	69,7	69,7
	Wrapper	64,9	70,5	75,3	76,9	77,3	76,9	77	75,3	72,4	69,7
Tüm Açı Değerleri Üzerinden Ortalama	mRMR	88,6	89,5	90,6	90	89,6	89,6	89,6	89,6	89,6	89,5
	MIFS	88,6	89,5	89,9	89,1	89,7	89,1	89	89	89,5	89,5
	MIFS-U	88,6	89,8	90,3	90,1	89,9	89,4	89,4	89,5	89,5	89,5
	Wrapper	89	92,2	92,8	92,8	92,6	92,3	91,9	91,3	90,4	89,5

Çizelge 5.1’e bakıldığı zaman önemli gözlem ve çıkarımlar yapılabilir. İlk olarak, karşılıklı bilgi miktarı tabanlı en başarılı yöntem için Çizelge 5.1’de tüm açı değerleri üzerinden ortalama kısmı incelendiğinde en yüksek başarımların üç öznitelik kullanılarak mRMR yöntemi ile elde edildiği görülebilir. Çizelge 5.1’de tüm açı değerleri üzerinden ortalama kısmına bakıldığında, mRMR’in %90.6’lık başarımlarını ile karşılıklı bilgi miktarı tabanlı yöntemler içinde ilk sırada geldiği ve üst sınır olarak karşılıklı bilgi miktarı tabanlı yöntemlerin başarımlarının kıyaslanması için kullanılan ileri yönlü wrapperın başarımlarından %2.2 geride olduğu görülebilir. mRMR’in karşılıklı bilgi miktarı tabanlı yöntemler arasında en yüksek başarımlara sahip olduğu söylenebilse de MIFS ve MIFS-U olarak adlandırılan yöntemlerin mRMR’a çok yakın başarımlarını verdiği Çizelge 5.1 ve Şekil 5.1’e bakıldığında rahatça görülebilir.

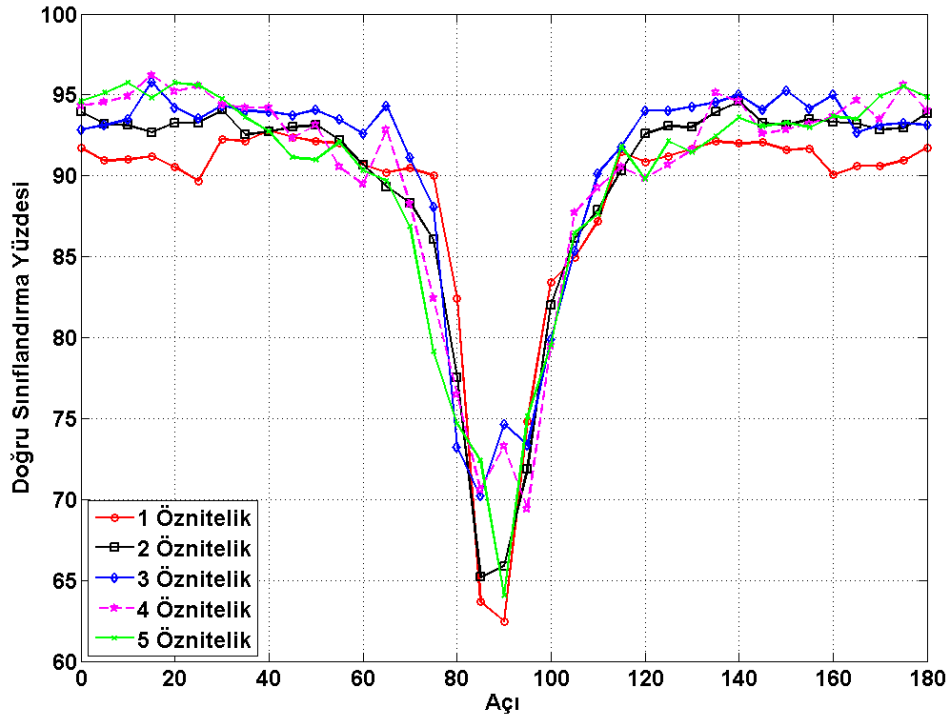
Buradan karşılık bilgi miktarı tabanlı yöntemlerin buradaki problem açısından birbirlerine açık ara baskın olmadığı sonucuna ulaşılabilir.



Şekil 5.1: Bilinen açı bilgisi için farklı algoritmalarla seçilen üç özneliğin başarımlarını karşılaştırması

Bölüm 4’de micro-Doppler’in açısal bağımlılığından dolayı verilerin etkilendiği gösterilmişti. Bölüm 4’te, açısal bağımlılık verileri etkilemekte ve açı 0° ’den 90° ’ye doğru yaklaştıkça micro-Doppler’in kötü bir şekilde etkilendiği görülmektedir. Bu etkide çıkarılan öznelikleri etkilemektedir. İkinci sonuç olarak, başarımların açıya bağlı olarak değiştiği Çizelge 5.1 ve Şekil 5.2’ye bakılarak söylenebilir. Şekil 5.1’e bakıldığında açı değerinin 90° doğru gittikçe başarımların düştüğü rahatça görülebilir. Bu durum seçilen öznelik sayısından farklı bir öznelik sayısı için gösterilebilir. Çizelge 5.1’te altı öznelik için mRMR yöntemine bakıldığında 0° için başarımları %95 iken 90° için bu başarımları %68.1’e düşmektedir. Bu karşılaştırma diğer yöntemlere bakıldığında da görülebilir. Bu karşılaştırma mRMR için ve en başarılı olarak gösterilen üç öznelik ile yapıldığında başarımları, 0° için %92 iken 90° için bu başarımları %74.7’ye düşmektedir. Üç öznelik için 90° ’de

mRMR ile üst sınır olan ileri yönlü wrapper arasında % 0.6 bir fark bulunmaktadır. Altı öznitelik içinse bu oran %8.8 ve öznitelik sayıları arasında en yüksek fark olarak görülebilir. Buradan bir açı değeri için daha iyi olan bir öznitelik sayısının farklı bir açı değerinde ise daha kötü olabileceği söylenebilir. Sonuç olarak farklı öznitelik sayılarında başarımın açığa bağlı olarak değiştiği söylenebilir. Başarımın açığa bağlı olarak değiştiği Çizelge 5.1'e, Şekil 5.1'e bakıldığında görülebilir. Ayrıca mRMR'ın seçtiği öznitelik sayısı seçilen öznitelik sayısının komşuluğu olan sayılarda yine mRMR'ın seçtiği özniteliklerin başarımının açığa bağlı olarak nasıl değiştiği Şekil 5.2'de gösterilerek başarımın açığa olan bağımlılığının öznitelik sayısından bağımsız olduğu gösterilmiştir.



Şekil 5.2: mRMR algoritması tarafından seçilen öznitelik gruplarının başarımı

Üçüncü sonuç olarak öznitelik sayısının değişmesinin sınıflandırma performansının değişmesi üzerine bir etkiye neden olması gösterilebilir. Bu etki Çizelge 5.1'e ve Şekil 5.2'ye bakıldığında rahatça görülebilir. Bazı açı değerlerinde öznitelik sayısının artması sınıflandırma performansını iyileştirirken, bazı açı değerlerinde sınıflandırma performansında bir değişime neden olmamakta ya da sınıflandırma performansının

eksilmesine neden olmaktadır. Çizelge 5.1'e bakıldığında 0° için öznitelik sayısı 1'den 2'ye çıkarıldığında başarımda mRMR ve MIFS için başarımlarım %2.2 iyileşirken MIFS-U için başarımlarım %0.6 iyileşmekte ve ileri yönlü wrapper içinse başarımlarım %3.5 iyileşmektedir. Öznitelik sayısı 2'den 3'e çıkarıldığında ise mRMR, MIFS ve ileri yönlü wrapper için başarımlarım düşerken MIFS-U için başarımlarım artmaktadır. Öznitelik sayısı 3'ten sırasıyla 6'ya kadar arttırılırsa başarımlarımın düzenli olarak arttığı görülebilir. Öznitelik sayısı 6'dan 7'ye çıkarıldığında ise başarımlarımın her üç yöntem için düştüğü ama ileri yönlü wrapper için değişmediği görülebilir. Aynı şekilde farklı açı değerleri ve tüm öznitelik sayılarına bakıldığı zaman da benzer değişimlerin yaşandığı görülebilir.

Öznitelik seçimi için bu problemde bulunan karşılıklı bilgi miktarı tabanlı en iyi algoritma olan mRMR tüm açılar için düşünüldüğünde optimum öznitelik kümesi çıkarılan on öznitelikten değil, bunun yerine üç öznitelikten oluşmaktadır. Bu durum Çizelge 5.1'e bakıldığında öznitelik sayılarındaki başarımdan görülebilir. Çizelge 5.1'e ya da Şekil 5.1 ve Şekil 5.2'ye bakıldığında bu durum micro-Doppler sınıflandırmada 90° gibi micro-Doppler izlerinin kötüleşeceği zorlayıcı açı değerlerinde öznitelik seçiminin sınıflandırma başarımlarım üzerindeki önemini vurgulamaktadır. Mesela Çizelge 5.1'den dikkatli ve özenli şekilde seçilen tek bir öznitelik için başarımlarımın topluca tüm özniteliklerin kullanımıyla elde edilen başarımlarım 0° 'de, 90° 'de ve ortalama başarımda çok yakın ya da 45° 'de daha yüksek olduğu görülebilir. Aynı zamanda, öznitelik sayısı üç ya da dörde getirildiğinde ise diğer öznitelik sayılarına göre başarımlarımın optimuma ulaştığı görülebilmektedir. Bahsedilen sonuçlar incelendiğinde ise özniteliklerin tamamının değil belli bir sayıda bir alt kümesinin kullanımının önemi daha rahat bir şekilde görülmektedir. Bu sonuçta öznitelik seçiminin önemini vurgulamaktadır.

Buraya kadar öznitelik seçimlerinin başarımlarım gösterildi ve hangi öznitelik sayısında başarımlarımın nasıl değiştiği sunuldu. Bölüm 4.2'te çıkarılan öznitelikler sunulmasına rağmen Bölüm 4.2'te bahsedilen özniteliklerden hangilerinin verilen başarımlarım sağladığından bahsedilmedi. En iyi sınıflandırma başarımlarımın üç öznitelikle sağlandığından bahsedilmişti. Çizelge 5.2'te on defa tekrarlamada rastgele verilerle,

bu on tekrarlama da toplamda en çok seçilen üç öznitelik farklı açı değerleri için verilmiştir. Bu bölümün başında bahsedilen her bir açı değeri için özniteliklerin tekrar hesaplandığı ve her açı değeri için özniteliklerin tekrar seçildiğinin vurgulanması iyi olacaktır.

Çizelge 5.2’de hedef radardan uzaklaşırken yani 0° ’de tüm yöntemler tarafından 1 no.lu özniteliğın (Gövde Doppler Frekansının Ortalaması) ve 2 no.lu özniteliğın (Gövde Salınımının Bant Genişliğı) seçildiğı görölmektedir. 1 ve 2 no.lu özniteliklerin yanında 7 no.lu özniteliğında (Alt Zarfın Ortalama Değeri) bu iki öznitelikten sonra en çok seçilen öznitelik olduğı görölmektedir. Ancak görüş açısı arttıkça 2 no.lu özniteliğın daha az seçilmeye başladığı da Çizelge 5.2’den rahatça görölebilmektedir. Bu sonuç, beklendiğı gibi Doppler bant genişliğinin açıyla ne kadar hızlı değıştiğini ya da düştüğünü ve böylece önemini yitirdiğini belirtmektedir. Buradaki durum özniteliğın insan hareket sınıfından daha çok hedef-anten geometrisiyle daha ilintili olduğunu göstermektedir. Çizelge 5.2 incelediğı zaman açı değıştikçe hiçbir özniteliğın sürekli olarak seçilmediğı ve değışik açı değerlerinde bu açılarla daha ilintili özniteliklerin seçildiğı görölebilir. Ayrıca Çizelge 5.2 genel bağlamda tüm açılar üzerinden incelendiğinde tüm açılar için en sık seçilen özniteliklerin 1 no.lu öznitelik, 9 no.lu öznitelik (Alt ve Üst Zarf Ortalamalarının Ortalaması), 7 no.lu öznitelik, 6 no.lu öznitelik (Üst Zarfın Ortalama Değeri) ve 2 no.lu öznitelik olduğı rahatça görölebilir. Burada 7 ve 6 no.lu özniteliklerin seçimleri konusunda bir vurgu yapılması gerekmektedir. Açı 90° gelinceye kadar 6 no.lu öznitelik yerine 7 no.lu öznitelik seçilmektedir. Açı 90° ’yi geçince 7 no.lu özniteliğın seçimi yerini 6 no.lu özniteliğın seçimine bırakmıştır. Bunun nedeni olarak Şekil 4.8’te gösterilen ve öncesinde anlatılan radara yaklaşma ve radardan uzaklaşma sonucunda Dopplerin negatif-pozitif değeri alması olarak gösterilebilir. Aslında yöntemler 90° ’den sonra fiziksel olarak değışerek 6 no.lu özniteliğın dönen ama anlam olarak aynı kalan 7 no.lu özniteliğın seçmeye devam etmektedir. Buda 7 ve 6 no.lu özniteliklerin açıya göre ifade ettikleri bilginin önemini vurgulamaktadır. Ancak en çok seçilen özniteliklerin sürekli bir arada seçilmediğinin ve açıya göre bu seçimlerin farklılık gösterdiğinin de vurgulanması gerekmektedir.

Çizelge 5.2: Hedefle radar arasındaki açı biliniyorken en sık seçilen öznitelikler (● işareti özniteliğin seçildiğini, ○ işareti ise özniteliğin seçilmediğini göstermektedir.)


AÇI	Algoritma/Öznitelik	1	2	3	4	5	6	7	8	9	10
0°	mRMR	●	●	○	○	○	○	●	○	○	○
	MIFS	●	●	○	○	○	○	●	○	○	○
	MIFS-U	●	●	○	○	○	○	○	○	●	○
	Wrapper	●	●	○	●	○	○	○	○	○	○
15°	mRMR	○	●	○	○	○	○	●	○	●	○
	MIFS	○	●	○	○	○	○	●	○	●	○
	MIFS-U	●	●	○	○	○	○	○	○	●	○
	Wrapper	●	●	○	○	○	○	○	○	●	○
30°	mRMR	●	○	○	○	○	○	●	○	●	○
	MIFS	○	○	○	●	○	○	●	○	●	○
	MIFS-U	●	○	○	○	○	○	●	○	●	○
	Wrapper	●	○	○	○	○	○	●	○	●	○
45°	mRMR	●	○	○	●	○	○	○	○	●	○
	MIFS	●	○	○	●	○	○	○	○	●	○
	MIFS-U	●	○	○	○	○	●	○	○	●	○
	Wrapper	●	○	○	○	○	○	●	○	●	○
60°	mRMR	●	●	○	○	○	○	○	○	●	○
	MIFS	●	●	○	●	○	○	○	○	○	○
	MIFS-U	●	●	○	○	○	○	○	○	●	○
	Wrapper	●	○	○	○	○	○	●	○	●	○
75°	mRMR	●	○	○	●	○	○	○	○	●	○
	MIFS	●	○	○	●	○	○	○	○	○	●
	MIFS-U	●	○	○	○	●	○	○	○	●	○
	Wrapper	●	●	○	○	○	○	●	○	○	○
90°	mRMR	○	○	○	○	○	○	○	●	○	●
	MIFS	○	●	○	○	○	○	○	●	○	●
	MIFS-U	○	●	○	○	○	○	●	●	○	○
	Wrapper	○	●	○	○	○	●	●	○	○	○
105°	mRMR	●	○	●	●	○	○	○	○	○	○
	MIFS	●	○	●	○	●	○	○	○	○	○
	MIFS-U	●	○	○	●	○	○	○	○	●	○
	Wrapper	●	○	○	○	○	●	○	○	●	○
120°	mRMR	●	○	●	○	○	○	○	○	●	○
	MIFS	○	●	●	○	○	○	○	○	●	○
	MIFS-U	●	○	○	○	●	○	○	○	●	○
	Wrapper	●	○	○	○	○	●	●	○	○	○
135°	mRMR	●	○	●	○	○	○	○	○	●	○
	MIFS	●	○	●	○	○	○	○	○	●	○
	MIFS-U	●	○	○	○	○	○	●	○	●	○
	Wrapper	●	○	○	○	○	●	○	○	●	○
150°	mRMR	●	○	○	○	○	●	○	○	●	○
	MIFS	○	●	●	○	○	○	○	○	●	○
	MIFS-U	●	●	○	○	○	○	○	○	●	○
	Wrapper	●	○	○	○	○	●	○	○	●	○
165°	mRMR	●	○	○	○	○	●	○	○	●	○
	MIFS	○	○	●	○	○	●	○	○	●	○
	MIFS-U	●	○	○	○	○	●	○	○	●	○
	Wrapper	●	○	●	○	○	●	○	○	○	○
180°	mRMR	●	●	○	○	○	●	○	○	○	○
	MIFS	●	●	○	○	○	●	○	○	○	○
	MIFS-U	●	●	○	○	○	○	○	○	●	○
	Wrapper	●	○	●	○	○	○	●	○	○	○

5.2 Hedefle Radar Arasındaki Açının Bilinmemesi

Bölüm 5.1’de gösterilen sonuçlar anten-hedef görüş açısının bilinmesi varsayımı altında elde edilmiş ve gösterilmiştir. Ancak radarın mesafe çözünürlüğü çok büyük ya da radarın hedef takip yeteneğinin bulunmaması durumlarında, görüş açısı sınıflandırma için belirlenemez ya da tahmin edilemez. Böyle bir durum için yapılan çalışmalar ve elde edilen sonuçlar bu kısımda verilecektir.

Bu bölümde yapılan çalışmanın daha iyi anlaşılabilmesi için Şekil 5.3’te yapılan çalışmanın bir organizasyon şeması yer almaktadır. Bu kısımda öncelikle her bir açı için o açının verilerinin %60’ı rastgele seçilerek o açı için eğitim seti ve geri kalan %40’lı veri çekilerek test seti oluşturulmuştur. Daha sonrasında her bir açıdan elde edilen eğitim verileri eğitim ve test verileri ise test adı altında toplanmıştır. Böylece hem sınıflandırma için her açı değerinde gereken eğitim ve test verileri oluşturulmuş hem de veriler birleştirilerek öznitelik seçimi için gereken açıdan bağımsız veri kümesi oluşturulmuştur. Rastgele veri kümesi oluşturulduktan sonra özniteliklerin seçilmesi amacıyla eğitim ve test verilerinin işlenmesi için mRMR, MIFS, MIFS-U ve ileri yönlü wrapper algoritmaları çalıştırılmıştır. İleri yönlü wrapper sınıflandırma sonucuna göre seçtiği için hem eğitim hem de test verileri bu yöntemle gönderilmiştir. Karşılıklı bilgi tabanlı yöntemler sınıflandırma yapmadığı için sadece eğitim verileri gönderilerek işlem yapılmıştır. Böylece oluşturulan algoritma öznitelikleri seçmektedir. Sınıflandırma işleminin daha net olması için rastgele veri seçiminden öznitelik seçimine kadar olan kısım on kez tekrarlanmıştır. Böylece farklı verilerde öznitelik seçimi netleştirilmeye çalışılmıştır. On kez tekrar işlemi bittikten sonra algoritma on farklı veri kümesi ile çalıştığı için on farklı öznitelik kümesi oluşturulmuştur. Algoritma bu aşamadan sonra on farklı öznitelik kümesini işleyerek en çok seçilen öznitelikleri bu öznitelik kümesini kullanarak bulmaktadır. Algoritma bu aşamadan sonra bulunan öznitelikleri, en başta oluşturulan açığa göre rastgele eğitim ve test verilerine uygulayarak sınıflandırma yapmaktadır. Sınıflandırmada başarımlar, farklı eğitim ve test verileri ile farklı olmaktadır. Bu amaçla başarımın net elde etmesi için algoritma tarafından işlem başında oluşturulan açı açı farklı veri setleri kullanılarak

sınıflandırma işlemi on kez tekrarlanmıştır. Elde edilen başarımın ortalaması alınarak başarımın net bir değere oturması sağlanmıştır. Önceden bahsedildiği gibi algoritmanın organizasyon şeması Şekil 5.3'te görülebilir.



Şekil 5.3: Hedefle radar arasındaki açının bilinmemesi durumunda kullanılan algoritmanın organizasyon şeması

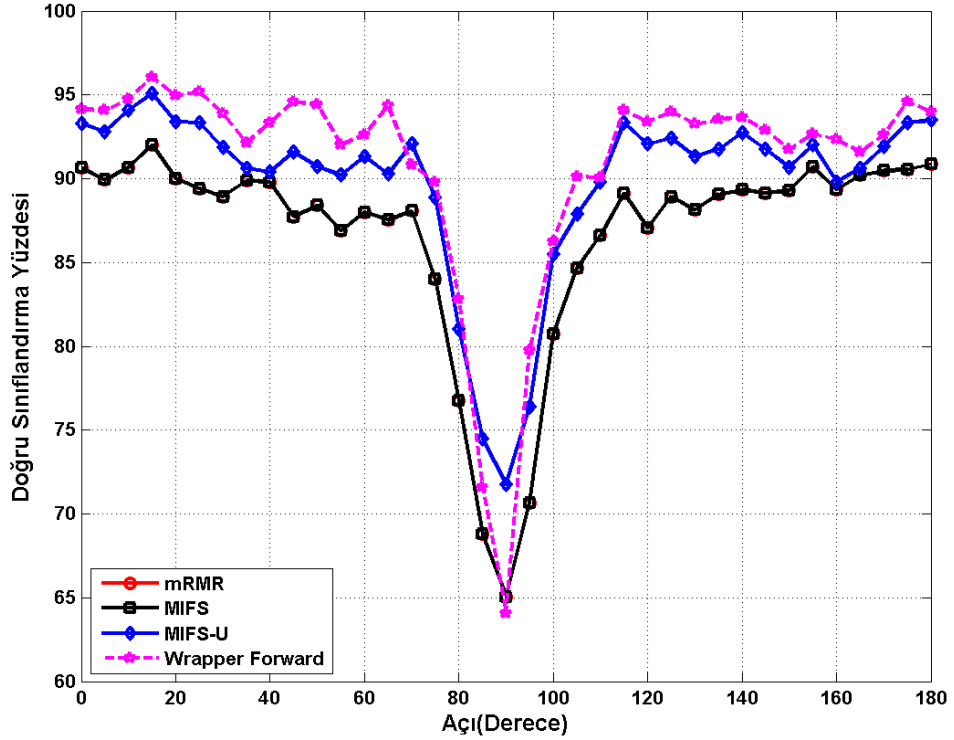
Bu kısımdaki başarımlar eğiliminin ya da değişiminin Bölüm 5.1'deki başarımla ulaşamasa da Bölüm 5.1'dekine benzer olduğu elde edilen sonuçlar incelendiğinde görülebilir. Bölüm 5.1'de olduğu gibi sonuçlar incelendiğinde bu kısımda da önemli gözlem ve çıkarımlar yapılabilir. İlk gözlem olarak, başarımların açısı 90°'ye ilerlerken düştüğü ve açısı 90°'yi geçtikten sonra arttığı söylenebilir. Bölüm 5.1'den görüldüğü ve Bölüm 2.3'te bahsedildiği gibi en kötü sonucun 90°'de gelmesi beklenmektedir. Çizelge 5.3, Şekil 5.4 ve Şekil 5.5 incelendiğinde bu sonuç görülebilir. Çizelge 5.3'te 0° başarımların %90 civarında olmasına rağmen açı değeri 45° geldiğinde başarımların %88 civarlarına düştüğü, açı değeri 90°'ye geldiğinde ise başarımların %60 seviyelerine gerilediği görülebilir.

Çizelge 5.3: Hedefle radar arasındaki görüş açısının bilinmediği durumda yöntemlerin seçtiği öznelitelere göre sınıflandırma başarımları

Hedefle Radar Arasındaki Açısı	Method	Seçilen Öznelikelik sayısı									
		1	2	3	4	5	6	7	8	9	10
0°	mRMR	91,7	89,7	90,7	90,9	91,3	91,6	92,3	92,7	93,1	93,2
	MIFS	91,7	89,7	90,7	91,7	91,8	91,5	92,8	92,7	93,1	93,2
	MIFS-U	91,7	91,6	93,3	90,4	90,9	91,6	92,3	92,7	93,1	93,2
	Wrapper	79,6	92,7	94,1	93,8	93,8	93,9	93,1	93,1	93,4	93,2
45°	mRMR	87,6	88,3	87,7	89,9	90,1	90,7	90,6	90,6	90,3	90,7
	MIFS	87,6	88,3	87,7	88,7	89,1	89,4	90,7	90,6	90,3	90,7
	MIFS-U	87,6	89,3	91,6	88,5	89,4	90,7	90,6	90,6	90,3	90,7
	Wrapper	78,1	91,0	94,6	93,9	93,3	94,0	91,3	91,7	91,8	90,7
90°	mRMR	45,5	58,1	65,1	66,9	71,1	72,1	71,6	70,9	69,5	69,7
	MIFS	45,5	58,1	65,1	66,8	68,8	67,6	69,3	70,9	69,5	69,7
	MIFS-U	45,5	69,3	71,7	68,3	71,8	72,1	71,6	70,9	69,5	69,7
	Wrapper	60,8	62,0	64,1	72,9	73,2	75,3	74,9	75,3	72,4	69,7
Tüm Açısı Değerleri Üzerinden Ortalama	mRMR	87,5	86,1	86,7	88,1	89,6	89,7	89,6	89,4	89,2	89,5
	MIFS	87,5	86,1	86,7	87,5	88,7	88,4	89,2	89,4	89,2	89,5
	MIFS-U	87,5	89,0	89,8	87,8	89,1	89,7	89,6	89,4	89,2	89,5
	Wrapper	75,7	89,4	91,0	91,6	91,0	91,5	90,8	90,8	90,3	89,5

Bölüm 5.1'de en iyi yöntemin mRMR olduğu gösterilmesine rağmen burada en iyi sonuç %89,8'lik başarımla MIFS-U yöntemi ile sağlanmaktadır. İkinci gözlem olarak, Bölüm 5.1'de en iyi başarımların mRMR ile sağlanmasına rağmen burada MIFS-U ile sağlanması gösterilebilir. MIFS-U ile sağlanan bu başarımlar üst sınır olarak karşılıklı

bilgi miktarı tabanlı yöntemlerin başarımının kıyaslanması için kullanılan ileri yönlü wrapperdan %1,2 geridedir. Bu başarım oranı Çizelge 5.3'te tüm açı değerleri üzerinden ortalamaya bakıldığında üç öznitelikle sağlanan başarım sonucunda görülebilir. Burada MIFS-U yönteminin en başarılı yöntem olduğu söylenmesine rağmen sonuçlara bakıldığı zaman, MIFS-U'nun diğer karşılık bilgi miktarı tabanlı yöntemlere baskın olduğu söylenemez. Şekil 5.4 ve Çizelge 5.3 incelendiğinde karşılıklı bilgi miktarı tabanlı yöntemlerin başarımlarının birbirlerine yakın olduğu ama içlerinde MIFS-U'nun başarımlarının daha iyi olduğu rahatça görülebilir.




Şekil 5.4: Bilinmeyen açı için farklı algoritmalarla seçilen üç öznitelik için başarımların karşılaştırması

Şekil 5.4'te tüm yöntemlerin en iyi başarımlarını veren üç öznitelik için başarımları görülmektedir. Burada mRMR ve MIFS yöntemleri için üç öznitelikte her iki yöntemde aynı başarımları verdiği ve Şekil 5.4 üzerinde üst üste bindiği görülmektedir. Çizelge 5.4 incelendiği zaman bu iki metodunda üç öznitelik için aynı öznitelikleri seçtikleri görülebilir. Ayrıca farklı öznitelik sayıları için Çizelge 5.3

incelendiğinde bu iki yöntemin başarımlarının farklı olduğu rahatça görülebilir. Şekil 5.4'e bakıldığında MIFS-U yönteminin ileri yönlü wrapper'a yakın sonuçlar verdiği görülmektedir. Buda buradaki durum için MIFS-U'nun ne kadar iyi çalıştığını ispatlamaktadır. Ancak burada MIFS-U için söylenenler Bölüm 5.1'de geçerli değildir.

Şekil 5.4'te üç öznitelik için MIFS-U'nun başarımı mRMR ve MIFS'ten çok daha iyi olsa da Çizelge 5.3 incelendiğinde farklı öznitelik sayıları için yöntemlerin başarımlarının yakın olduğu görülebilir. Üçüncü sonuç olarak, Çizelge 5.3 ve Şekil 5.5 incelendiğinde sınıflandırmada kullanılan özniteliklerin sayısındaki bir artış olması başarımın iyileşmesini garantilememesi ya da sağlamaması gösterilebilir. Şekil 5.5'te en iyi başarımı veren üç öznitelik sayısının komşuluğu olan öznitelik sayılarındaki MIFS-U yönteminin başarımları verilmiştir.



Şekil 5.5: En iyi başarımı veren üç öznitelik sayısının komşuluğu olan öznitelik sayılarındaki MIFS-U yönteminin başarımları


Şekil 5.5'te görüldüğü gibi öznitelik sayılarındaki artış performans üzerinde çok fazla olumlu etkiler oluşturmamaktadır. Verilen sonuçta üç özniteliğin en iyi sonuç verdiğini gözlemlemek mümkün olmakla beraber üç özniteliğin komşuluğunda olan öznitelik sayılarında başarımın çok değiştiğini söylemek mümkün değildir. Sadece bir öznitelik için başarımın 90°'e etrafında çok etkilendiği ve düştüğü görülmektedir. Ancak bu durumun dışında, başarım öznitelik sayılarında hemen hemen aynı olmakla beraber önceden söylendiği gibi en iyi sonuç üç öznitelik sayısı ile alınmıştır.

En iyi başarım üç öznitelikle MIFS-U yöntemiyle elde edilmiştir. Bu yöntem ve diğer yöntemler tarafından seçilip Çizelge 5.3 ve Şekil 5.4'te başarımları gösterilen öznitelikler Çizelge 5.4'te verilmiştir. Çizelge 5.4 incelendiğinde 1 ve 2 no.lu özniteliklerin tüm algoritmalar tarafından seçildiği gözlemlenebilir. Bölüm 5.1'de de nerdeyse tüm açılarda 1 no.lu özniteliğin tüm yöntemler tarafından seçildiği verilmiştir. Burada da 1 no.lu özniteliğin tüm yöntemler tarafından seçilmesi, 1 no.lu özniteliğin sınıflandırma işlemi için ne kadar önemli olduğunu vurgulamaktadır. 2 no.lu öznitelik ise Bölüm 5.1'de insan hareket sınıflandırmasından daha çok hedef-anten geometrisiyle ilgili olduğu sonucuna varılmıştı. Ancak 2 no.lu özniteliğin burada tüm yöntemler tarafından seçilmesi açılı bilgisi olmadan öznitelik seçimi için 2 no.lu özniteliğin azalan geometrik bağımlılığın etkilerinden daha çok insan hareket sınıflandırmasına daha çok katkı sağladığını ve daha önemli olduğunu göstermektedir. 1 ve 2 no.lu özniteliklerden sonra en çok seçilen öznitelik 5 no.lu (Toplam Bant Genişliği) özniteliktir. 5 no.lu öznitelik 4 yöntemden ikisi tarafından seçilmiştir. Diğer seçilen öznitelikler sekiz (Alt ve Üst Zarf Ortalamaları Arasındaki Bant Genişliği) ve 9 no.lu özniteliklerdir.

Çizelge 5.4: Hedefle radar arasındaki açı bilinmiyorken en sık seçilen öznitelikler (● işareti özniteliğin seçildiğini, ○ işareti ise özniteliğin seçilmediğini göstermektedir.)

Yöntem/Öznitelikler	1	2	3	4	5	6	7	8	9	10
mRMR	●	●	○	○	●	○	○	○	○	○
MIFS	●	●	○	○	●	○	○	○	○	○
MIFS-U	●	●	○	○	○	○	○	●	○	○
İleri yönlü wrapper	●	●	○	○	○	○	○	○	●	○


Açının bilinmesi ve bilinmemesi durumları ayrı ayrı incelendi. Şekil 5.6 ve Şekil 5.7’de iki durum için dikkat çeken yöntemlerin başarımları verilerek her iki durum kıyaslanmaya çalışılmıştır. Şekil 5.6’da açının bilinmesi ve bilinmemesi durumları için mRMR ve ileri yönlü wrapperın sonuçları paylaşılmıştır. Şekil 5.6’dan her iki durum içinde yeni bilgi varken(açı bilinirken) ve bilgi eksikliğinde(açı bilinmezken) çalıştırılan ileri yönlü wrapper yönteminin belli bir açı değerine kadar benzer sonuçlar verdiği ve bu açı değerinden sonra ileri yönlü wrapperın her iki durum içinde başarımının değiştiği gözlemlenebilir. Buradan ileri yönlü wrapperın birbirine benzer sonuçlarındaki açı verilerinin öznelik seçimi üzerinde bir önemi olduğu belki söylenebilir. Ayrıca diğer tüm yöntemlerin etkilendiği gibi mRMR’ında bilgi eksikliğinden etkilendiği Şekil 5.6’ya bakıldığında çok rahat bir şekilde gözlemlenebilir.



Şekil 5.6: Bilinen ve bilinmeyen açı durumlarında mRMR ve ileri yönlü wrapperın başarımları

Bölüm 5.1’de bilgi, her açı değerinde ayrı ayrı hesaplanarak öznelikler seçilirken burada ise tüm açılar için içine katılarak bilgi hesaplanmaktadır. Bu durumda bilgi

eksikliğine sebep olmakta ve sonuç olarak başarımlar Şekil 5.6’da görüldüğü gibi düşmektedir. Ayrıca mRMR için başarımın gözlemlenen en baskın düşüşü %17 civarında 90° için olduğu rahatça Çizelge 5.3’ten görülebilir. Şekil 5.7’de açının bilinmesi durumunda seçilen yöntem olan mRMR ve açının bilinmemesi durumunda seçilen yöntem olan MIFS-U’nun başarımlar sonuçları gösterilmiştir.



Şekil 5.7: Açının bilinmesi durumunda seçilen yöntem mRMR ve açının bilinmemesi durumunda seçilen yöntem MIFS-U’nun başarımlar sonuçları

Şekil 5.7 incelendiğinde çoğu açı değerinde açının bilinmesi durumunda seçilen yöntem mRMR’ın açının bilinmemesi durumunda seçilen MIFS-U’ya göre daha başarılı olduğu görülebilir. Ayrıca 70° ile 115° arasında açının bilinmemesi durumu daha başarılı sonuçlar vermiştir. Buda bu açının oluşturduğu negatif durumun açı verileri ile değil genel olarak tüm açılardan gelen verilerle daha iyi bir şekilde analiz edilebileceği sonucuna götürmektedir. Bu aralığının tek istisnasının 90° olduğu söylenebilir. Burada neredeyse hiçbir hareket bilgisi olmadığından bu kısmın kendi içinde değerlendirilmesi daha iyi sonuç vermiştir. Düşünüldüğünde neredeyse hareket verisinin hiç olmadığı bir kısım verinin kendi içinde değerlendirilmesinin hareket

verilerinin bulunduğu bir kümeyle değerlendirilmesinden daha mantıklı olduğu görülebilir.

5.3 Sınıflandırma Karşılaştırma Matrisi

Bölüm 5.1 ve 5.2’de hedefle radar arasındaki açının bilinmesi ve bilinmemesi durumlarının sınıflandırma başarımları verildi. Bölüm 5.1 ve 5.2’de verilen ve işlenen iki durumun başarı performansını nasıl etkilediği incelendi. Ancak hangi hareketlerin sınıflandırmada birbirleriyle karıştığı ve hareketlerin nasıl bir başarımla doğru sınıflandırıldığı hakkında bilgi verilmedi. Bu bölümde görüş açısı 0° ve 90° ’de olduğu zaman her iki durum içinde hareketlerin birbirlerinden ayrılma başarımları verilecek ve bu konudan bahsedilecektir.

Önceki iki bölümde verilen sonuçlardan elde edilen hareketlerin birbirinden ayrılma başarımlarının ya da karışma ve yanlış sınıflandırma yüzdelerinin gösterildiği Çizelge 5.5 ve 5.6’nın incelenmesiyle hangi hareketlerin birbiriyle daha sık karışabileceği yahut karışmayacağı fikri üretilebilir. Bu iki çizelgede sırasıyla açının bilinmesi ve bilinmemesi durumlarında, hareketlerin doğru sınıflandırılma ve yanlış sınıflandırılma başarımları verilmiştir. Çizelgelerde herhangi bir açı değerinde herhangi bir hareketin doğru sınıflandırılma başarımları, o açının sol üst başarımlarından sağ alt başarımlara bir köşegen çizildikten sonra, o hareket için bu köşegen üzerine düşen başarımlara bakılarak görülebilir. Bu köşegen üzerindeki her bir başarımlar doğru sınıflandırılma başarımlarıdır. Mesela, Çizelge 5.5’te 0° için köşegen üzerindeki ilk doğru sınıflandırılma yürüme hareketine aittir. Diğerler başarımlar sırasıyla koşma, emekleme ve sürünme hareketlerinin doğru sınıflandırılma başarımlarına aittir. Bu köşegen dışındaki sınıflandırılma başarımları yanlış sınıflandırılma yani hareketlerin başka hareketlerle karıştırılma yüzdeleridir. Mesela, 0° ’de Çizelge 5.5’e bakıldığında yürüme hareketinin %98.72’lik başarımla doğru sınıflandırılmış olduğu, %1.28’lik yüzdeyle emekleme hareketi ile karıştırılmış ve koşma ile sürünme hareketi ile karıştırılmadığı rahatça görülebilir.

Çizelge 5.5: Bilinen açı durumunda hareketlerin 0° ve 90° için karşılaştırılma matrisleri

		SINIFLAR			
		YÜRÜME	KOŞMA	EMEKLEME	SÜRÜNME
Görüş Açısı 0°'de Hedef Hareketi					
HAREKET	YÜRÜME	98,72	0	1,28	0
	KOŞMA	3,57	96,43	0	0
	EMEKLEME	6,90	0	72,41	20,69
	SÜRÜNME	0	0	6,67	93,33
Görüş Açısı 90°'de Hedef Hareketi					
HAREKET	YÜRÜME	82,05	1,28	12,82	3,85
	KOŞMA	14,29	82,14	0	3,57
	EMEKLEME	34,48	0	58,62	6,90
	SÜRÜNME	20	0	26,67	53,33

Çizelge 5.5'ten açının bilinmesi durumunda ve 0°'de yürüme %98.72, koşma %96.43, emekleme %72.41 ve sürünme %93.33'lik başarımla doğru sınıflandırılmıştır. Çizelge 5.5 incelendiği zaman bu doğru sınıflandırma başarımlarının dışında yanlış sınıflandırılma durumları da mevcuttur. Burada 0°'de en düşük doğru sınıflandırılma başarımlarına sahip olan emekleme hareketi %20.69'lu yüzdeyle sürünme hareketi ile karışmıştır. Bu çizelgeden çıkarılan diğer bir sonuçta yürüme hareketi koşma hareketi ile karışmaz, koşma hareketi yürüme hareketi ile %3.57'lik bir yüzdeyle karışmaktadır. Bu durumun sebebi olarak koşma hareketinde micro-Doppler izleri yürüme hareketinden daha geniş bir frekans bandında kayabilmesi gösterilebilir. Yürüme hareketi için ise böyle bir durumdan bahsedilemez. 90°'de verilerin kötü olmasından ve bu durumdan kaynaklı doğru bir öznitelik kümesi seçilememesi yanlış sınıflandırma veya hareketlerin karışma yüzdelerinin arttığı 0° ve 90° için Çizelge 5.5 incelenerek görülebilir. Bahsedilen yanlış sınıflandırılma yüzdelerinin artmasındaki tek istisna koşma ve emekleme hareketlerinin karışmaması olarak gösterilebilir. Bu iki hareket iki açı değerinde de birbirleriyle hiç karışmamışlardır.

Çizelge 5.5'te bahsedilen benzer durumlardan, açının bilinmemesi durumu içinde bahsedilebilir. Çizelge 5.6'da açının bilinmemesi durumu için hareketlerin ayrımı için elde edilen sınıflandırılma sonuçları 0° ve 90° için gösterilmiştir. Burada 0° için yürüme hareketi %98.72 ve koşma hareketi %96.43 doğru sınıflandırılma başarımları ile Çizelge 5.5 ile aynı olarak bulunmuştur. Bu durumun aksine emekleme %86.21 ile ilk durumdan %13.8'lik bir artışla doğru sınıflandırılmıştır. Sürünme hareketi ise %40'lık bir azalmayla %53.33'lük bir başarıma gerilemiştir. Burada bu %40'lık yanlış sınıflandırılma yürüme ve emekleme ile karışmıştır. Çizelge 5.6 incelendiği zaman 0°'den 90°'ye gidildiğinde başarımda daha fazla bir düşüş meydana geldiği söylenebilir. Çizelge 5.5 için bahsedilen koşma ile emekleme hareketlerinin karışmaması durumu burada da her iki açı değeri içinde geçerlidir. Her iki Çizelge de incelendiği zaman açının bilinmesi durumuna göre açının bilinmemesi durumunda başarımın düştüğü ve karışmanın meydana gelmesinden yanlış sınıflandırmanın artmasından söz edilebilir.

Çizelge 5.6: Bilinmeyen açı durumunda hareketlerin 0° ve 90° için karşılaştırılma matrisleri

		SINIFLAR			
		YÜRÜME	KOŞMA	EMEKLEME	SÜRÜNME
Görüş Açısı 0°'de Hedef Hareketi					
HAREKET	YÜRÜME	98,72	0	1,28	0
	KOŞMA	3,57	96,43	0	0
	EMEKLEME	10,34	0	86,21	3,45
	SÜRÜNME	26,67	0	20	53,33
Görüş Açısı 90°'de Hedef Hareketi					
HAREKET	YÜRÜME	70,51	5,13	20,51	3,85
	KOŞMA	25	71,43	0	3,57
	EMEKLEME	68,97	0	24,14	6,90
	SÜRÜNME	13,33	6,67	33,33	46,67

6 SONUÇ ve GELECEK ÇALIŞMALAR

Bu tez kapsamında insan mikro-Doppler izlerinin daha iyi sınıflandırılabilmesi için yapılan çalışmalar ve elde edilen sonuçlar ayrıntılarıyla paylaşılmıştır. İnsan mikro-Doppler izlerinin sınıflandırılma başarımının optimuma çıkarılabilmesi için çıkarılan tüm özniteliklerin değil bu özniteliklerden oluşan optimum başarıyı veren bir alt kümenin kullanılmasının önemi vurgulanmıştır. Ayrıca bu alt kümenin oluşturulabilmesi için karşılıklı bilgi miktarı tabanlı algoritmalar çalıştırılmıştır. Çalıştırılan bu algoritmaların başarımlarının ölçülebilmesi için maksimum başarıyı verecek ileri yönlü wrapper algoritması çalışmaya dahil edilmiştir.

Bölüm 5.1 ve Bölüm 5.2’de belirtildiği gibi karşılıklı bilgi miktarı tabanlı yöntemler kendi durumları içinde birbirlerine üstünlük sağlayamamışlardır. Bu bölümlerde başarımların sonuçları incelendiğinde tüm özniteliklerin kullanılmasının, başarımları iyileştirebileceğinin garantisi bulunmamaktadır. Bu amaçla tüm açılar üzerinden alınan ortalamada optimum başarımları veren öznitelik sayısı seçilmiştir ki sonuçlara bakıldığında bu mantığın çalıştığı rahatça görülebilir. Ancak bu bölümlerde seçilen öznitelikler incelendiğinde durumların kendi içlerinde tüm yöntemlerin sıklıkla benzer öznitelikleri seçtikleri görülebilir. İki durum incelenirse ve seçilen öznitelikler kıyaslanırsa seçilen özniteliklerin çoğunlukla aynı olduğu rahatça söylenebilir.

Bu tez kapsamında farklı hareketlerin birbirlerinden ayrımı incelenmiş ve bu ayrım görüş açısının radarın kabiliyetini yitireceği 90° ’ye kadar getirilerek başarımın optimuma çekilmesi amaçlanmıştır. Görüş açısı 90° ’de iken en kötü durum senaryosunda, D. Tashmouh ve J. Silvious [39] sınıflandırma başarımının %40 olduğunu belirtmişlerdir. Tez kapsamında yapılan çalışma sonuçlarına bakıldığında %70 civarında elde edilen 90° ’deki başarımların gayet iyi bir sonuç olduğu görülebilir. Genel olarak hareketlerin kendi sınıfı olarak sınıflandırılması gayet iyi bir şekilde tasarlanan senaryo ve algoritmayla iyi çalışmaktadır.

Burada yapılan çalışmaların devamında yapılabilecek çalışmaları, görüş açısının bilinmediği durum senaryosu değiştirilip sonuçların kıyaslanması, öznitelik sayısının

arttırılarak 6znitelik se7iminin nasıl deęiřtięinin incelenmesi, burada yapılan 7alıřmalar monostatik bir 7alıřma olduęu i7in burada yapılan 7alıřmanın bir network kurularak farklı sens6rlerden 6znitelik se7imi, sens6r se7imi, 6zniteliklerin farklı sens6r kombinasyonları ile bařarım deęerlendirme olarak sayılabilir. Bu 7alıřmanın ilerletilmesi ve geliřtirilmesi network radar yapılarında bilgi temini, birleřtirmesi hakkında olumlu etkileri olacaktır.

KAYNAKÇA

- [1] J. C. Toomay ve P. Hannen, Radar Principles for the Non-Specialist, Third. Scitech Publishing, Inc., 2004.
- [2] “History of radar”, Wikipedia, the free encyclopedia. Erişim tarihi: 16-Tem-2014.
- [3] G. Greneker III, Very low cost stand-off suicide bomber detection system using human gait analysis to screen potential bomb carrying individuals, in Proc. of SPIE, c 5788, ss. 46, 2005.
- [4] L. M. Frazier, MDR for law enforcement [motion detector radar], IEEE Potentials, c 16, sayı 5, ss 23–26, Ara 1997.
- [5] Y. Li, L. Du, ve H. Liu, Moving vehicle classification based on micro-Doppler signature, 2011 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC), ss 1–4, 2011.
- [6] T. Thayaparan, S. Abrol, E. Riseborough, L. Stankovic, D. Lamothe, ve G. Duff, Analysis of radar micro-Doppler signatures from experimental helicopter and human data, IET Radar Sonar & Navigation, c 1, sayı 4, ss 289–299, 2007.
- [7] A. Cilliers ve W. A. J. Nel, Helicopter parameter extraction using joint time-frequency and tomographic techniques, 2008 International Conference on Radar, ss 598–603, 2008.
- [8] H. Sisan, Z. Yong-feng, Z. Hong-Zhong, Z. Jian-xiong, ve F. Qiang, Analysis of rotating structures for stepped frequency radar, 2008 International Conference on Radar, ss 386–390, 2008.
- [9] M. Anderson, Design of multiple frequency continuous wave radar hardware and micro-Doppler based detection and classification algorithms, PhD Thesis, University of Texas, Austin, 2008.
- [10] A.G.K. Janecek, W.N. Gansterer, M.A. Demel, ve G.F. Ecker, On the relationship between feature selection and classification accuracy, JMLR: Workshop and Conference Proceedings 4, ss 90–105, 2008.
- [11] A. W. Miller, C. Clemente, A. Robinson, D. Greig, A. M. Kinghorn, ve J. J. Soraghan, Micro-Doppler based target classification using multi-feature integration, IET Intelligent Signal Processing Conference 2013 (ISP 2013), ss 1–6, 2013.
- [12] M. Thoma, H. Cheng, A. Gretton, J. Han, H. Kriegel, A. Smola, L. Song, P. Yu, X. Yan, ve K. Borgwardt, Near-optimal supervised feature selection among frequent subgraphs, Proceedings of the 2009 SIAM International Conference on Data Mining, ss 1076–1087, 2009.
- [13] A. Jain ve D. Zongker, Feature selection: evaluation, application, and small sample performance, IEEE Trans. Pattern Analysis Machine Intelligence, c 19, sayı 2, ss 153–158, Şub 1997.
- [14] V.C.Chen, The Micro-Doppler Effect in Radar. Artech House, 2010.
- [15] T. M. Cover ve J. A. Thomas, Elements of Information Theory. Wiley-Interscience, Second Edition, 2006.
- [16] S. Z. Gürbüz, Ü. Kaynak, B. Özkan, O. C. Kocaman, F. Kılıçlı, B. Tekeli, Design study of a short-range airborne UAV radar for human monitoring, Asilomar Conference on Signals, Systems, and Computers, Pacific Grove, CA, 2014.

- [17] Y. Wang ve A. E. Fathy, Micro-Doppler signatures for intelligent human gait recognition using a UWB impulse radar, 2011 IEEE International Symposium on Antennas and Propagation (APSURSI), ss 2103–2106, 2011.
- [18] R. Boulic, N. M. Thalmann, ve D. Thalmann, A global human walking model with real-time kinematic personification, *Visual Computer*, c 6, sayı 6, ss 344–358, Kas 1990.
- [19] P. Van Dorp ve F. C. A. Groen, Human walking estimation with radar, *IEE Proc. Radar Sonar Navigation*, c 150, sayı 5, ss 356–365, Ekim 2003.
- [20] "Carnegie Mellon University - CMU Graphics Lab - motion capture library", erişim adresi: <http://mocap.cs.cmu.edu/>. Erişim Tarihi: 19-Tem-2014.
- [21] S. S. Ram, Y. Li, A. Lin, ve H. Ling, Doppler-based detection and tracking of humans in indoor environments, *Journal of the Franklin Inst.*, c 345, sayı 6, ss 679–699, Eylül 2008.
- [22] G. E. Smith, K. Woodbridge, C. J. Baker, ve H. Griffiths, Multistatic micro-Doppler radar signatures of personnel targets, *IET Signal Processing*, c 4, sayı 3, ss 224–233, Haz 2010.
- [23] S. Z. Gürbüz, W. L. Melvin, ve D. B. Williams, Spectrogram-Based Methods for Human Identification in Single-Channel SAR Data, *IEEE 15th Signal Processing and Communications Applications*, (SIU 2007)., ss 1–4, 2007.
- [24] P. Suresh, T. Thayaparan, S. SivaSankaraSai, K.S. Sridharan, ve K. Venkataramaniah, Gabor-Wigner transform for micro-Doppler analysis, 9th International Radar Symposium, Bangalore India, ss 10–14, 2013.
- [25] P. Suresh, K. Venkataramaniah, ve T. Thayaparan, Analysis of micro-doppler radar signatures of rotating targets using gabor wigner transform, *Int. J. Innov. Res. Sci. Eng. Technology*(IJIRSET), c 3, sayı Special Issue 1, Şub 2014.
- [26] T. Thayaparan, L. Stanković, ve I. Djurović, Micro-Doppler-based target detection and feature extraction in indoor and outdoor environments, *Journal of the Franklin Inst.*, c 345, sayı 6, ss 700–722, Eylül 2008.
- [27] D. Tahmouh ve J. Silvius, Remote detection of humans and animals, 2009 IEEE Applied Imagery Pattern Recognition Workshop (AIPRW), ss 1–8, 2009.
- [28] M. Otero, Application of a continuous wave radar for human gait recognition, in *Proc. of SPIE*, c 5809, ss 538–548, 2005.
- [29] Y. Yang, W. Zhang, ve C. Lu, Classify human motions using micro-Doppler radar, in *Proc. of SPIE*, c 6944, s 69440V, 2008.
- [30] L. Fei, H. Binke, Z. Hang, ve D. Hao, Human gait recognition using micro-doppler features, 2012 5th Global Symposium on Millimeter Waves (GSMM), ss 326–329, Mayıs 2012.
- [31] Y. Kim ve H. Ling, Human Activity Classification Based on Micro-Doppler Signatures Using a Support Vector Machine, *IEEE Transactions Geoscience Remote Sensing*, c 47, sayı 5, ss 1328–1337, Mayıs 2009.
- [32] Y. Kim ve H. Ling, Human activity classification based on micro-Doppler signatures using an artificial neural network, *IEEE Antennas and Propagation Society International Symposium (AP-S 2008)*, ss 1–4, 2008.
- [33] F. H. C. Tivive, A. Bouzerdoun, ve M. G. Amin, Automatic human motion classification from Doppler spectrograms, 2010 2nd International Workshop on Cognitive Information Processing (CIP), ss 237–242, 2010.

- [34] F. H. C. Tivive, A. Bouzerdoum, ve M. G. Amin, A Human Gait Classification Method Based on Radar Doppler Spectrograms, *EURASIP Journal on Advances in Signal Processing*, c 2010, ss 10:1–10:12, 2010.
- [35] J. Li, S. L. Phung, F. H. C. Tivive, ve A. Bouzerdoum, Automatic classification of human motions using Doppler radar, *The 2012 International Joint Conference on Neural Networks (IJCNN)*, ss 1–6, 2012.
- [36] D. Tahmoush ve J. Silvius, Stride rate in radar micro-doppler images, *IEEE International Conference on Systems, Man and Cybernetics (SMC)*, ss 4218–4223, 2009.
- [37] O. R. Fogle ve B. D. Rigling, Micro-range/micro-Doppler feature extraction and association, *2011 IEEE Radar Conference (RADAR)*, ss 167–171, 2011.
- [38] Y. Yang, J. Lei, W. Zhang, ve C. Lu, Target Classification and Pattern Recognition Using Micro-Doppler Radar Signatures, *Seventh ACIS International Conference on Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing. (SNPD 2006)*, ss 213–217, 2006.
- [39] D. Tahmoush ve J. Silvius, Radar micro-doppler for long range front-view gait recognition, *IEEE 3rd International Conference on Biometrics: Theory, Applications, and Systems(BTAS '09)*, ss 1–6, 2009.
- [40] H. Peng, F. Long, ve C. Ding, Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, c 27, sayı 8, ss 1226–1238, Ağustos 2005.
- [41] R. Kohavi ve G. H. John, Wrappers for feature subset selection, *Artificial Intelligence.*, c 97, sayı 1–2, ss 273–324, Aralık 1997.
- [42] G. Kumar ve K. Kumar, A novel evaluation function for feature selection based upon information theory, *2011 24th Canadian Conference on Electrical and Computer Engineering (CCECE)*, ss 000395–000399, 2011.
- [43] Y. Deng ve J. Liu, Feature Selection Based on Mutual Information for Language Recognition, *2nd International Congress on Image and Signal Processing (CISP '09)*, ss 1–4, 2009.
- [44] J. Huang, Y. Cai, ve X. Xu, A Wrapper for Feature Selection Based on Mutual Information, *18th International Conference on Pattern Recognition(ICPR)*, c 2, ss 618–621, 2006.
- [45] R. Battiti, Using mutual information for selecting features in supervised neural net learning, *IEEE Transactions on Neural Networks*, c 5, sayı 4, ss 537–550, 1994.
- [46] N. Kwak ve C.-H. Choi, Input feature selection for classification problems, *IEEE Transactions on Neural Networks*, c 13, sayı 1, ss 143–159, Ocak 2002.
- [47] P. A. Estevez, M. Tesmer, C. A. Perez, ve J. M. Zurada, Normalized Mutual Information Feature Selection, *IEEE Transactions on Neural Networks*, c 20, sayı 2, ss 189–201, 2009.
- [48] J. Martínez Sotoca ve F. Pla, Supervised feature selection by clustering using conditional mutual information-based distances, *Pattern Recognition*, c 43, sayı 6, ss 2068–2081, Haziran 2010.

- [49] A. A. Joshi, S. M. James, P. H. Meckl, G. B. King, ve K. Jennings, Information-Theoretic Feature Selection for Classification, American Control Conference (ACC '07), ss 2000–2005, 2007.
- [50] B. Fish, A. Khan, N. H. Chehade, C. Chien, ve G. Pottie, Feature selection based on mutual information for human activity recognition, 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), ss 1729–1732, 2012.
- [51] A. Ghaleb, L. Vignaud, ve J. M. Nicolas, Micro-Doppler analysis of wheels and pedestrians in ISAR imaging, IET Signal Processing, c 2, sayı 3, ss 301–311, Eylül 2008.
- [52] L. Vignaud, A. Ghaleb, J. Le Kernec, ve J.-M. Nicolas, Radar high resolution range & micro-Doppler analysis of human motions, Radar Conference - Surveillance for a Safer World. International, ss 1–6, 2009.
- [53] R. G. Raj, V. C. Chen, ve R. Lipps, Analysis of radar human gait signatures, IET Signal Processing, c 4, sayı 3, ss 234–244, Haziran 2010.
- [54] V. C. Chen, Detection and analysis of human motion by radar, IEEE Radar Conference (RADAR '08), ss 1–4, 2008.
- [55] S. Bjorklund, H. Petersson, ve G. Hendeby, On distinguishing between human individuals in micro-Doppler signatures, 2013 14th International Radar Symposium (IRS), c 2, ss 865–870, 2013.
- [56] V. C. Chen, Analysis of radar micro-Doppler with time-frequency transform, Proceedings of the Tenth IEEE Workshop on Statistical Signal and Array Processing, 2000, ss 463–466, 2000.
- [57] J. L. Geisheimer, W. S. Marshall, ve E. Greneker, A continuous-wave (CW) radar for gait analysis, Conference Record of the Thirty-Fifth Asilomar Conference on Signals, Systems and Computers, c 1, ss 834–838, 2001.
- [58] S. Z. Gürbüz, W. L. Melvin, ve D. B. Williams, Detection and identification of human targets in radar data, Proc. SPIE, c 6567, s 65670I, 2007.
- [59] J. L. Geisheimer, E. F. Greneker III, ve W. S. Marshall, High-resolution Doppler model of the human gait, Proc. SPIE, c 4744, ss 8–18, 2002.
- [60] S. S. Ram ve H. Ling, Simulation of human microDopplers using computer animation data, IEEE Radar Conference(RADAR '08), ss 1–6, 2008.
- [61] C. Karabacak, S. Z. Gurbuz, ve A. Gurbuz, Radar simulation of human micro-Doppler signature from video motion capture data, IEEE 21st Signal Processing and Communications Applications Conference (SIU), ss 1–4, 2013.
- [62] S. Z. Gurbuz, B. Tekeli, C. Karabacak, ve M. Yuksel, Feature selection for classification of human micro-Doppler, IEEE International Conference on Microwaves, Communications, Antennas and Electronics Systems (COMCAS), ss 1–5, 2013.
- [63] S. Z. Gurbuz, B. Tekeli, M. Yuksel, C. Karabacak, A. Gurbuz, ve M. B. Guldogan, Importance ranking of features for human micro-Doppler classification with a radar network, 16th International Conference on Information Fusion (FUSION), ss 610–616, 2013.
- [64] C. Karabacak, S. Z. Gurbuz, ve A. C. Gurbuz, Automatic human activity classification using radar, IEEE 22nd Signal Processing and Communications Applications Conference (SIU), ss 1051–1054, 2014.

- [65] B. Erol, C. Karabacak, ve S. Z. Gürbüz, A Kinect-Based Human Micro-Doppler simulator, IEEE Aerospace and Elektronik Systems Magazine, submitted Temmuz 2014.
- [66] B. Erol, C. Karabacak, S. Z. Gurbuz, ve A. C. Gurbuz, Radar simulation of different human activities via Kinect, IEEE 22nd Signal Processing and Communications Applications Conference (SIU), ss 1015–1018, 2014.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : TEKELİ, Bürkan
Uyruğu : T.C.
Doğum tarihi ve yeri : 09.08.1987 ANKARA
Medeni hali : Bekar
Telefon : 0 (555) 308 14 07
e-mail : burkantekeli@gmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	TOBB ETÜ/Elektrik-Elektronik Müh.	2011
Yüksek Lisans	TOBB ETÜ/Elektrik-Elektronik Müh.	2015

İş Deneyimi

Yıl	Yer	Görev
2014-.....	TOBB ETÜ	Proje Bursiyeri(TUBİTAK)
2012-2014	TOBB ETÜ	Burslu Yüksek Lisans Öğrencisi

Yabancı Dil

İngilizce

Yayınlar

Dergi Yayınları

1. B. Tekeli, S.Z. Gürbüz, M. Yüksel, "Information Theoretic Feature Selection for Human Micro-Doppler Signature Classification," IEEE Trans. Geoscience and Remote Sensing, submitted July 2014.

Konferans Bildirileri

1. S.Z. Gürbüz, M.B. Özcan, A.B. Parım, S. Demirhan, Z. Hayran, M.C. Karaduman, M.S. Seyfioğlu, B. Tekeli, B.Çağlıyan, "Target detection and ranging with the 2.4 GHz MIT coffee can radar," in Proc. IEEE Signal Processing and Communications Application Conference (SİU), Trabzon, 2014.
2. Gurbuz S.Z., Tekeli B., Karabacak, C. Yuksel M., "Feature selection for classification of human micro-Doppler," in Proc. IEEE International Conference on Microwaves, Communication, Antennas and Electronic Systems (COMCAS), Tel Aviv, Isreal, 2013.
3. S.Z.Gurbuz, B.Tekeli, M.Yuksel, C. Karabacak, A.C. Gurbuz, M.B. Guldogan, "Importance ranking of features for human micro-Doppler classification with a radar network", in Proc. IEEE International Conference on Information Fusion (FUSION), Istanbul, 2013.

4. B. Tekeli, S.Z. Gürbüz, M. Yüksel, B. Güldoğan, A.C. Gürbüz, “Classification of human micro-Doppler in a radar network,” in Proc. IEEE Radar Conference, Ottawa, Canada, 2013.
5. Tekeli B., Gurbuz S.Z., Yuksel M., “Mutual information of features extracted from human micro-Doppler,” in Proc. IEEE Signal Processing and Communications Application Conference (SİU), Kıbrıs, 2013.
6. Ataman A., Tekeli B., Gurbuz, A.C., “Development of a stepped frequency GPR prototype” in Proc. IEEE Signal Processing and Communications Application Conference (SİU), Kıbrıs, 2013.