

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**SİLÜETLERDEN ÜRETİLEN YÜRÜYÜŞ BİYOMETRİSİNE
DAYALI KİMLİKLENDİRME**

DOKTORA TEZİ

Bil. Yük. Müh. Eyüp GEDİKLİ

**EKİM 2010
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

SİLÜETLERDEN ÜRETİLEN YÜRÜYÜŞ BİYOMETRİSİNE

DAYALI KİMLİKLENDİRME

Bil. Yük. Müh. Eyüp GEDİKLİ

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"Doktor (Bilgisayar Mühendisliği)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih: 17.08.2010
Tezin Savunma Tarihi : 12.10.2010**

Tez Danışmanı: Doç. Dr. Murat EKİNCİ

Jüri Üyesi : Prof. Dr. Vasif V. NABİYEV

Jüri Üyesi : Doç. Dr. Ali GANGAL

Jüri Üyesi : Prof. Dr. Ahmet Enis ÇETİN

Jüri Üyesi : Doç. Dr. Cemal KÖSE

(Handwritten signatures of the jury members and advisor)

Enstitü Müdürü : Prof. Dr. Salih TERZİOĞLU

ÖNSÖZ

Biyometrik özelliklere dayalı sistemler, hızlı, güvenilir ve otomatik bir şekilde kimlik doğrulama ve tanıma yapabilirler. Ancak mevcut sistemler, çoğu zaman cihazla teması gerektirerek yüksek çözünürlüklü görüntülerle kimliklendirme işlemini gerçekleştirirler. Çok uzaktan, düşük çözünürlükteki görüntülerde ölçülebilen, bilinen tek biyometrik özellik yürüyüş şeklidir. Yürüyüş şekline dayalı kimliklendirme sistemleri, yeterli başarı sağlanabildiği takdirde, oldukça geniş kullanım alanına sahip olacaktır. Bu tez çalışmasında, silüetlere dayalı olarak üretilen yürüyüş örüntülerinden biyometrik özellik çıkarımıyla insanların kimliklerinin tespit edilmesine çalışılmıştır.

Çalışmalarımda danışmanlığımı üstlenip ilgisini ve desteğini esirgemeyen sayın Doç. Dr. Murat EKİNCİ'ye sonsuz teşekkürlerimi bir borç bilirim. Doktora süresince fikirlerine başvurduğum tez izleme komitesine ayrıca teşekkür ederim. Ayrıca, ilgi, yardım ve özellikle hoşgörülerinden ötürü, sevgili aileme ve değerli arkadaşlarıma çok teşekkür ederim.

Eyüp GEDİKLİ
Trabzon 2010

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET.....	VI
SUMMARY	VII
ŞEKİLLER DİZİNİ.....	VIII
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ	XIII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Yürüyüş Biyometrik Özelliklerinin Çıkarılması	7
1.2.1. Algılayıcı Sistemlere Dayalı Yürüyüş Biyometrik Özelliği.....	8
1.2.2. Makine Görmesine Dayalı Ölçülen Yürüyüş Biyometrik Özelliği	9
1.2.2.1. Nesne Algılama ve Takip Etme.....	10
1.2.2.2. Yürüyüş Karakteristiğinin Belirlenmesi.....	11
1.2.2.2.1. Yürüyüş Periyotunun Hesaplanması	12
1.2.2.2.2. Model Tabanlı Yürüyüş Örüntüsü Üretme Yaklaşımları	14
1.2.2.2.3. Modelden Bağımsız Siluet Tabanlı Yöntemler	17
1.3. Örüntülerde Öznitelik Çıkarma ve Boyut İndirgeme	29
1.3.1. Doğrusal Uzayda İstatistiksel Ayırıştırma Analizi Yaklaşımları	31
1.3.1.1. Temel Bileşen Analizi	32
1.3.1.2. Doğrusal Ayırıştırma Analizi	33
1.3.2. Doğrusal Olmayan Uzayda İstatistiksel Analiz Yaklaşımları	35
1.3.2.1. Çekirdek Hilesi	36
1.3.2.2. Çekirdekli Temel Bileşen Analizi	38
1.3.2.3. Çekirdekli Ayırma Analizi	42
1.4. Örüntü Sınıflandırma.....	43
1.4.1. Uzaklık Ölçütleri	43
1.4.2. En Yakın Komşuluk Sınıflandırıcıları.....	45

1.4.2.1.	Standart En Yakın Komşuluk	46
1.4.2.2.	k-En Yakın Komşuluk	46
1.4.3.	Destek Vektör Makineleri	47
1.4.4.	Sınıflar Arası Uzaklığa Dayalı EYK	50
2.	YAPILAN ÇALIŞMALAR.....	53
2.1.	Yürüyüş Veritabanlarının Düzenlenmesi	55
2.2.	Yürüyüş Örüntüsü Üretme.....	58
2.2.1.	Yürüyüş Periyodu Hesabı.....	58
2.2.2.	Yürüyüş Enerji İmgesi.....	59
2.2.3.	Önerilen p Çerçeve Farkı Enerji İmgesi	60
2.2.4.	Silüete 4-Yönden Bakıştaki Uzaklıklara Dayalı Yürüyüş Örüntüsü	62
2.2.5.	Temel Bileşenlerle Yürüyüş Örüntüsü Üretme	63
2.2.6.	DCT ile Yürüyüş Örüntüsü Üretme	64
2.3.	Örüntülerden Özellik Çıkarımı	65
2.3.1.	Doğrusal Ayırıştırma Analizleri	66
2.3.1.1.	Direk Doğrusal Ayırıştırma Analizi	67
2.3.1.2.	TBA+DAA	69
2.3.1.3.	2-Boyutlu Temel Bileşen Analizi	69
2.3.2.	Doğrusal Olmayan Ayırıştırma Analizleri.....	70
2.3.2.1.	Gauss Çekirdek Parametresinin Kestirimi.....	70
2.3.2.2.	Çekirdekli Direk Ayırıştırma Analizi	71
2.4.	Örüntü Sınıflandırma.....	75
2.4.1.	EYK İçin Uzaklık Ölçütü	76
2.4.2.	Sınıflandırıcıya Giren Verilerin Normalize Edilmesi.....	77
3.	BULGULAR VE İRDELEME.....	78
3.1.	Yürüyüş Veritabanları	79
3.1.1.	CMU MoBo Yürüyüş Veritabanı	79
3.1.2.	SOTON Yürüyüş Veritabanı	80
3.1.3.	USF Yürüyüş Veritabanları	80
3.1.4.	CASIA Yürüyüş Veritabanları	82
3.2.	Özniteliklerin Sınıflandırılması	83
3.2.1.	Özniteliklerin Normalizasyonu.....	84
3.2.2.	Uzaklık Ölçütlerinin ve Sınıflandırıcıların Karşılaştırılması.....	87

3.3.	Özellik Çıkarma Yaklaşımları	91
3.3.1.	Öznitelik Boyutlarının Sınıflandırmaya Etkisi	92
3.3.2	Öznitelik Çıkarma Yaklaşımlarının Değerlendirilmesi.....	95
3.3.3.	2B-TBA Özellik Çıkarıcısının İncelenmesi	98
3.4.	Yürüyüş Örüntüsü Üretme Yaklaşımları	99
3.4.1.	Önerilen Yürüyüş Örüntülerinin Performansları	99
3.4.2.	DCT ile Sıkıştırılmış Örüntülerin Performansı	100
3.4.3.	pCFEI’de p Parametresinin Etkisi	102
3.4.4.	YEİ ve pCFEI’nin Performans Değerlendirmesi	104
3.5.	Önerilen Yaklaşımların Literatür Karşılaştırmaları.....	113
3.5.1.	CMU Veritabanı Literatür Sonuçları	114
3.5.2.	SOTON Veritabanı Literatür Sonuçları.....	114
3.5.3.	CASIA-A Veritabanı Literatür Sonuçları.....	115
3.5.4.	USF V1 Veritabanı Literatür Sonuçları.....	116
3.5.5.	USF V2 Veritabanı Literatür Sonuçları.....	117
3.5.6.	CASIA-C Veritabanı Literatür Sonuçları	118
3.5.7.	CASIA-B Veritabanı Literatür ve Deneysel Sonuçları	119
4.	SONUÇLAR.....	123
5	ÖNERİLER	125
6.	KAYNAKLAR.....	127
7.	EKLER	139
ÖZGEÇMİŞ		

ÖZET

Güvenilir, hızlı ve otomatik şekilde, kimlik tespiti ve doğrulaması yapabilen biyometrik sistemler, kriminal vakalarda ve güvenlik gerektiren alanlarda, biyometrik özellikleri ilgi odağı haline getirmiştir. Son zamanlarda yüz ve yürüyüş şekli biyometrik özelliklerinin ölçülmesi çalışmalarıyla, güvenliği tehdit edici, terörizm gibi insan temelli olayları önceden tahmin edebilmek amaçlanmaktadır. Diğerlerine göre yürüyüş şekli, düşük çözünürlükteki kameralarla uzaktan, termal ve kızılötesi kameralarla karanlıkta ve karmaşık ortamlarda alınabilen, gizlenmesi ve taklidi zor olan bir biyometrik özelliktir. Bu özellikleriyle ilgi toplayan yürüyüş şekli, yakın gelecekte önemli güvenlik noktalarında biyometrik sistemlere hizmet edecektir.

Yürüyüş şeklini belirlemek için, video akışında kişinin modeli oluşturulur veya siluetten yürüyüş örüntüleri üretilir. Sonra model veya örüntülerdeki dinamik değişimlerin makine öğrenmesi yaklaşımlarıyla yürüyüş imzaları çıkartılır. Daha sonra çevrimiçi üretilen imzaların, referans imzalarıyla benzeşimleri hesaplanarak tanıma gerçekleştirilir.

Bu tezde, yürüyüş şeklinin siluetlerden üretilen yürüyüş örüntüsüne dayalı belirlenmesine ve tanınmasına çalışılmıştır. Bunun için yürüyüş örüntülerinden doğrusal ve doğrusal olmayan uzaylarda yapılan analizlerle, küçük boyutlarda yürüyüş imzaları üretilip, birbirine benzeşimleri en yakın komşuluk (EYK) ve destek vektör makineleri (DVM) ile hesaplanmıştır. Bu çalışmada yürüyüş örüntüsü üretme, Gauss çekirdek fonksiyonu için otomatik parametre kestirimi, sınıflandırılacak özniteliklerin normalizasyonu ve örnekler arası uzaklık hesaplamalarında katkılar yapılmıştır. Ayrıca özellik çıkarımı için yürüyüş örüntülerinde daha önce denenmemiş direk doğrusal ayrıştırma analizi (D-DAA) ve çekirdek direk ayrıştırma analizi (ÇDAA) yaklaşımları uygulanmıştır. Geliştirilen gerçek zamanlı sistemlere uyarlanabilir uygulamalarla, yaygın kullanılan CMU, SOTON, USF ve CASIA uluslar arası yürüyüş veritabanlarında performans artışı sağlanmıştır.

Anahtar Kelimeler: Yürüyüş Şekli Tanıma, Biyometri, Temel Bileşen Analizi, Doğrusal Ayrıştırma Analizi, Çekirdek Hilesi, Destek Vektör Makinesi, En Yakın Komşuluk

SUMMARY

Human Identification Based on Gait Patterns Extracted from Silhouettes

Biometric systems capable of performing reliable, fast and autonomous human identification and identity verification focused scientific attention on biometric feature extraction especially in criminal cases and other events demanding high level of security. The goal of recent studies on face and gait recognition is to foresee and prevent human-based unlawful incidents such as terrorism threatening security. Gait is a biometric feature with differentiating characteristics including remote profile formation by using low resolution video cameras, measurability in dark and complicated environments via thermal and infrared video cameras, and imitation and concealment hardness. Due to its distinguishing attributes, in the near future, human identification based on gait is expected to serve as the core component of biometric systems located at critical security points.

First, style of walking is determined using either model-based or silhouette-based approaches. Subsequently, walking signatures of dynamic changes in models or patterns are constructed by means of machine learning techniques. Finally, human identification is accomplished by calculating the similarities between constructed and reference signatures.

This work focused on gait recognition based silhouettes. Walking signatures have been created using feature extraction methodologies on gait patterns. The similarities among walking signatures have been estimated using nearest-neighbor and support vector machine learning algorithms. This study contributed to the areas including gait pattern production, automatic parameter estimation for Gaussian kernel, attribute normalization and distance calculation. Furthermore, direct linear discrimination and its kernel approaches have been applied for feature extraction. By means of the application of the methods developed in this work which can be adopted in real-time systems, a performance increase has been observed in widely used CMU, SOTON, USF and CASIA databases.

Key Words: Gait Recognition, Biometry, Pattern Recognition, Principal Component Analysis, Linear Discriminant Analysis, Kernel Trick, Support Vector Machine, Nearest Neighbour

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1.	Biyometrik özellikler [1] , (a) DNA, (b) Kulak, (c) Yüz, (d) Termografik yüz, (e) Termografik el, (f) Toplardamar, (g) Parmak izi, (h) Yürüyüş şekli, (i) El geometrisi, (j) İris, (k) Avuç izi, (l) Retina, (m) El yazısı (imza), (n) Ses 2
Şekil 1.2.	Bazı yürüyüş veritabanlarından örnek görüntüler 5
Şekil 1.3.	Algılayıcı sistemler: (a) zemin algılayıcı, (b) ve (c) giyilebilir algılayıcı 9
Şekil 1.4.	Yürüyüş şekline dayalı kişi tanıma sistemi 10
Şekil 1.5.	Model-tabanlı yürüyüş ölçümleri, (a) [28], (b) [29, 30], (c) [32, 39] , (d) [38] 15
Şekil 1.6.	Model-tabanlı yöntemler, (a) [33], (b) [36, 41], (c) [37] 16
Şekil 1.7.	Siluet tabanlı örüntü üretme teknikleri, (a) kendine benzerlik, (b) genişlik vektörü, (c) yatay-dikey izdüşümler, (d) radon, (e) sınır uzaklıkları, (f) 4yön. 21
Şekil 1.8.	Bazı model bağımsız yaklaşımların yürüyüş örüntüleri, (a) simetri, (b) YEİ, (c) SST, (d) MSCT, (e) GHI, (f) MHI, (g) MEI, (h) FDEI, (ı) AEI... 26
Şekil 1.9.	Giriş uzayı ve doğrusal olmayan öznitelik uzayı 35
Şekil 1.10.	Minkowski ölçütünde değişik p değerleri için orijinden 1.0 uzaklığındaki noktaları kapsayan bölgeler 45
Şekil 1.11.	(a) En yakın komşuluk, (b) k-en yakın komşuluk sınıflandırıcıları 45
Şekil 1.12.	Öznitelik uzayında doğrusal DVM 48
Şekil 1.13.	Doğrusal olmayan uzay, (a) Doğrusal DVM (b) Doğrusal olmayan DVM 49
Şekil 1.14.	Çoklu DVM, (a) bire-karşı-bir DVM, (b) bire-karşı-hepsi DVM 50
Şekil 1.15.	İki sınıf arasındaki uzaklık hesabı 51
Şekil 2.1.	Yürüyüş biyometrik özelliğine dayalı kişi tanıma sistemi 54
Şekil 2.2.	Veritabanlarındaki bazı bozuk silüetler, (a) USF, (b) SOTON, (c) CASIA-C (kızılötesi kamera), (d) CASIA-B 57
Şekil 2.3.	YEİ'nin üretilişi 60
Şekil 2.4.	pCFEİ'nin üretilişi 61
Şekil 2.5.	Siluet sınırları ile silüet etrafına konuşlandırılan dikdörtgen sınırları arasındaki uzaklığa dayalı uzaysal-zamansal hareket temsilleri 62
Şekil 2.6.	TBA ile üretilmiş USF V1 eğitim setinden örnek örüntüler 64
Şekil 2.7.	DCT Bileşenleri ile yürüyüş üretme, (a) DC bileşen, (b) AC bileşenlerin birincisi, (c) AC bileşenlerin ikincisi, (d) AC bileşenlerin, AC bileşen sayısının yarısına kadar toplamı 65

Şekil 3.1.	CMU yürüyüş veritabanında kullanılan yönler ve etiketlemeleri.....	79
Şekil 3.2.	Özniteliklerin normalize edilmesi: CMU, V1-HY setinde YEİ örüntülerinden TBA ile çıkarılan özniteliklerin normalizasyonu	84
Şekil 3.3.	Özniteliklerin normalize edilmesi: CASIA-B, Set-NM setinde YEİ örüntülerinden ÇTBA ile çıkarılan özniteliklerin normalizasyonu	85
Şekil 3.4.	Özniteliklerin normalize edilmesi: USF V1, Set-A setinde YEİ örüntülerinden TBA ile çıkarılan özniteliklerin normalizasyonu	86
Şekil 3.5.	Özniteliklerin normalize edilmesi: USF V2, Set-A setinde YEİ örüntülerinden ÇTBA ile çıkarılan özniteliklerin normalizasyonu	86
Şekil 3.6.	Uzaklık ölçütlerinin karşılaştırılması: SOTON veritabanında, TBA ile çıkarılan özniteliklerin EYK yaklaşımıyla sınıflandırılması	87
Şekil 3.7.	Uzaklık ölçütlerinin karşılaştırılması: USF V2 veritabanında, ÇTBA ile öznitelik çıkartılarak EYK yaklaşımıyla sınıflandırılması	88
Şekil 3.8.	Uzaklık ölçütlerinin karşılaştırılması: USF V2 veritabanında, ÇDAA ile öznitelik çıkartılarak EYK yaklaşımıyla sınıflandırılması	88
Şekil 3.9.	Sınıflandırıcıların karşılaştırılması: USF V1 veritabanında YEİ örüntülerinden, ÇTBA ile çıkarılan özniteliklerin sınıflandırılması.....	89
Şekil 3.10.	Sınıflandırıcıların karşılaştırılması: CASIA-B veritabanı, 90°'lik (profil) kamera yönünde pCFEİ örüntülerinden ÇDAA ile çıkarılan özniteliklerin sınıflandırılması	90
Şekil 3.11.	Sınıflandırıcıların karşılaştırılması: USF V2 veritabanında her sınıftan bir pCFEİ örüntü örneği alınarak, ÇTBA ile çıkarılan özniteliklerin sınıflandırılması	90
Şekil 3.12.	Özellik çıkarma yöntemleri: SOTON veritabanında, YEİ örüntülerinin kKAU+EYK ile sınıflandırması	92
Şekil 3.13.	Özellik çıkarma yöntemleri: CASIA-B veritabanında, PCFEİ örüntülerinin kKAU+EYK sınıflandırması	93
Şekil 3.14.	Özellik çıkarma yöntemleri: CMU veritabanında, YEİ örüntülerinin kKAU+EYK sınıflandırması	94
Şekil 3.15.	Özellik çıkarma yöntemleri: USF V2 veritabanında, pCFEİ örüntülerinin kKAU+EYK sınıflandırması	94
Şekil 3.16.	Öznitelik çıkarma yaklaşımlarının değerlendirilmesi: USF V2 veritabanı YEİ örüntülerinde AÖU+EYK sınıflandırması	95
Şekil 3.17.	Öznitelik çıkarma yaklaşımlarının değerlendirilmesi: CASIA-B veritabanı YEİ örüntülerinde AÖU+EYK sınıflandırması	96
Şekil 3.18.	Öznitelik çıkarma yaklaşımlarının değerlendirilmesi: USF V1 veritabanı pCFEİ örüntülerinde mnkKAU+EYK sınıflandırması.....	97
Şekil 3.19.	Öznitelik çıkarma yaklaşımlarının değerlendirilmesi: CASIA-B veritabanı pCFEİ örüntülerinde mnkKAU+EYK sınıflandırması.....	97

Şekil 3.20. USF V2 veritabanında 2B-TBA'nın, görüntü boyutlarındaki değişimlerdeki performansı	98
Şekil 3.21. CASIA-B veritabanı profilden (90°'lik açıda), 2B-TBA'nın görüntü boyutlarındaki değişimlerdeki performansı	99
Şekil 3.22. Örüntü üretme yaklaşımlarının değerlendirilmesi: USF V2 veritabanı üzerinde ÇDAA+mknKAU+EYK ile başarımlar değerlendirilmesi	100
Şekil 3.23. Örüntülerin DCT'si: CASIA-B veritabanı 90°'lik açıda (profil), PCFEİ yürüyüş örüntüleri DCT'sinin sınıflandırılması	101
Şekil 3.24. Örüntülerin DCT'si: USF V2 veritabanında, YEİ yürüyüş örüntüleri DCT'sinin sınıflandırılması	101
Şekil 3.25. CMU V1-HY setinde farklı p parametreleri için başarımlar değerlendirilmesi ...	103
Şekil 3.26. CASIA-C veritabanında, fps'si dijital olarak artırılmış yürüyüş dizilerinde, p parametreleri için başarımlar değerlendirilmesi	104
Şekil 3.27. YEİ ve pCFEİ'nin karşılaştırılması: CMU veritabanında ÇDAA+kKAU yaklaşımıyla sınıflandırma.....	105
Şekil 3.28. YEİ ve pCFEİ'nin karşılaştırılması: CASIA-C veritabanında ÇTBA+mknKAU yaklaşımıyla sınıflandırma.....	106
Şekil 3.29. YEİ ve pCFEİ'nin karşılaştırılması: CASIA-B veritabanında ÇDAA+kKAU yaklaşımıyla sınıflandırma	107
Şekil 3.30. YEİ ve pCFEİ'nin karşılaştırılması: USF V1 veritabanında ÇDAA+mknKAU yaklaşımıyla sınıflandırma	107
Şekil 3.31. Yürüyüş örüntülerinin karşılaştırılması: USF V2 veritabanında ÇTBA+mknKAU yaklaşımıyla sınıflandırma.....	108
Şekil 3.32. Yürüyüş örüntülerinin ve özellik çıkarıcıların karşılaştırılması: CASIA-B veritabanı set-BG'de, pCFEİ ve YEİ'nin ÇTBA ve ÇDAA yaklaşımlarıyla başarımlar	109
Şekil 3.33. Yürüyüş örüntülerinin ve özellik çıkarıcıların karşılaştırılması: CASIA-B veritabanı set-CL'de, pCFEİ ve YEİ'nin ÇTBA ve ÇDAA yaklaşımlarıyla başarımlar	110
Şekil 3.34. Yürüyüş örüntülerinin karşılaştırılması: CASIA-B Set-NM'de komşu aç test sonuçları	111
Şekil 3.35. Yürüyüş örüntülerinin karşılaştırılması: CASIA-B Set-BG'de komşu aç test sonuçları	112
Şekil 3.36. Yürüyüş örüntülerinin karşılaştırılması: CASIA-B Set-CL'de komşu aç test sonuçları	113
Ek Şekil 1. CMU MoBo veritabanı için kameraların konumu.....	139
Ek Şekil 2. CMU MoBo veritabanı örnek resimler.....	140
Ek Şekil 3. SOTON büyük veritabanı, (a) normal yürüme, (b) yürüme bandında normal yürüme, (c) dışarıda normal yürüme	142

Ek Şekil 4. SOTON küçük veritabanı yürüyüş senaryoları.....	142
Ek Şekil 5. USF yürüyüş veritabanları değişken tablosu	143
Ek Şekil 6. USF Veritabanı için kayıt sahneleri.....	144
Ek Şekil 7. CASIA-A veri setindeki senaryolar.....	145
Ek Şekil 8. CASIA-B veri setindeki senaryolar	145
Ek Şekil 9. CASIA-C veri setindeki senaryolar	146

TABLolar DİZİNİ

Sayfa No

Tablo 2.1.	Yürüyüş veritabanlarının siluet görüntü boyutları.....	56
Tablo 3.1.	USF Veritabanlarının USF-NIST formatı.....	81
Tablo 3.2.	CMU veritabanında elde edilen sonuçların literatürle karşılaştırılması	114
Tablo 3.3.	SOTON veritabanında elde edilen sonuçların literatürle karşılaştırılması .	115
Tablo 3.4.	CASIA-A veritabanında elde edilen sonuçların literatürle karşılaştırılması	116
Tablo 3.5.	USF V1 veritabanında elde edilen sonuçların literatürle karşılaştırılması .	116
Tablo 3.6.	USF V2 veritabanında elde edilen sonuçların literatürle karşılaştırılması .	117
Tablo 3.7.	CASIA-C veritabanında elde edilen sonuçlar	118
Tablo 3.8.	CASIA-B veritabanında elde edilen sonuçların literatürle karşılaştırılması	120
Tablo 3.9.	CASIA-B veritabanında, YEİ+ÇDAA+mnkKAU aynı açı ve komşu açı test sonuçları.....	120
Tablo 3.10.	CASIA-B veritabanı Set-NM, ÇDAA+mnkAU ile yapılmış çapraz test sonuçları	121
Tablo 3.11.	CASIA-B veritabanı Set-BG, ÇDAA+mnkAU ile yapılmış çapraz test sonuçları	121
Tablo 3.12.	CASIA-B veritabanı Set-CL, ÇDAA+mnkAU ile yapılmış çapraz test sonuçları	122
Ek Tablo 1.	CMU yürüyüş veritabanı özeti.....	139
Ek Tablo 2.	CMU yürüyüş veritabanı kayıt düzeni.....	140
Ek Tablo 3.	Doğrusal olmayan uzaya eşleme yaparken kullanılan çekirdekler	147
Ek Tablo 4.	CMU farklı özellik çıkarma yaklaşımlarının deney sonuçları.....	149
Ek Tablo 5.	SOTON farklı özellik çıkarma yaklaşımlarının deney sonuçları.....	150
Ek Tablo 6.	CASIA-A farklı özellik çıkarma yaklaşımlarının deney sonuçları.....	150
Ek Tablo 7.	USF V1 farklı özellik çıkarma yaklaşımlarının deney sonuçları.....	150
Ek Tablo 8.	USF V2 farklı özellik çıkarma yaklaşımlarının deney sonuçları.....	151
Ek Tablo 9.	CASIA-C farklı özellik çıkarma yaklaşımlarının deney sonuçları	152
Ek Tablo 10.	CASIA-B farklı özellik çıkarma yaklaşımlarının deney sonuçları	152

SEMBOLLER DİZİNİ

AEİ	: Aktif enerji imgesi (active energy image)
AÖS	: Az örnek sayısı problemi (small sample size)
AÖU	: Ağırlıklandırılmış Öklid uzaklığı
BBA	: Bağımsız bileşen analizi
CASIA	: Institute of Automation Chinese Academy of Sciences
CMU	: Carneige Mellon University
CAA	: Çekirdek ayrıştırma analizi (kernel discriminant analysis)
CDAA	: Çekirdek direk ayrıştırma analizi (kernel direct discriminant analysis)
CTBA	: Çekirdek temel bileşen analizi (kernel principal component analysis)
DAA	: Doğrusal ayrıştırma analizi (linear discriminant analysis)
DARPA	: The Defense Advanced Research Projects Agency
DCT	: Ayırık kosinüs dönüşümü (discrete cosine transform)
DCV	: Ayırıcı ortak vektör (discrete common vector)
D-DAA	: Direk doğrusal ayrıştırma analizi (direct linear discriminant analysis)
DFT	: Ayırık Fourier dönüşümü (discrete Fourier transform)
DTW	: Dinamik zaman uyarlaması (dynamic time warping)
DVM	: Destek vektör makinesi (support vector machine)
DYEİ	: Değişken yürüyüş enerji imgesi (dynamic gait energy image)
EYK	: En yakın komşuluk (nearest neighbour)
FDA	: Fisher ayrıştırma analizi (Fisher discriminant analysis)
FED	: Çerçeve model uzaklığı (frame to exemplar distance)
FFT	: Hızlı Fourier dönüşümü (fast Fourier transform)
GaTech	: Georgia Institute of Technology
GHI	: Yürüyüş tarihi imgesi (gait history image)
HumanID	: Human Identification at a Distance
HMM	: Saklı Markov modeli (hidden Markov model)
IPTO	: Information Processing Techniques Office
KAU	: Kosinüs açısı uzaklığı
kDVM	: Tam denetimli DVM
k-EYK	: k -en yakın komşuluk (k -nearest neighbour)

kKAU	: Kaydırılmış vektörler arasındaki kosinüs açı uzaklığı
LPP	: Bölge korumalı izdüşüm (locality preserving projection)
MDA	: Çoklu ayrıştırma analizi (multiple discriminant analysis)
mdAÖU	: Sınıflar arası medyana dayalı ağırlıklandırılmış Öklid uzaklığı
mdKAU	: Sınıflar arası medyana dayalı kosinüs açı uzaklığı
mdkKAU	: Sınıflar arası medyana dayalı kaydırılmış kosinüs açı uzaklığı
mdÖU	: Sınıflar arası medyana dayalı Öklid uzaklığı
MFA	: Marjinal Fisher analizi (marginal Fisher analysis)
MHI	: Hareket tarihçesi imgesi (motion history image)
MIT	: Massachusetts Institute of Technology
mnAÖU	: Sınıflar arası ortalamaya dayalı ağırlıklandırılmış Öklid uzaklığı
mnKAU	: Sınıflar arası ortalamaya dayalı kosinüs açı uzaklığı
mnkKAU	: Sınıflar arası ortalamaya dayalı kaydırılmış kosinüs açı uzaklığı
mnÖU	: Sınıflar arası ortalamaya dayalı Öklid uzaklığı
MSI	: Hareketli siluet imgesi (motion silhouette image)
NIST	: National Institute of Standards and Technology
ÖU	: Öklid uzaklığı
pCFEİ	: p adımlı çerçeve farkları enerji imgesi
PLD	: Işıklı nokta görüntüleme (point-light displays)
RBF	: Açısal temelli fonksiyon (radial bases function)
RGB	: Kırmızı, yeşil, mavi renk formatı
SOTON	: University of Southampton
TBA	: Temel bileşen analizi (principal component analysis)
UCSD	: University of California, San Diego
UMD	: Univeristy of Maryland
USF	: University of South Florida
YnEİ	: Yürüyüş enerjisi entropi imgesi (gait energy entropy image)
YSA	: Yapay sinir ağları
2B-DCT	: 2-boyutlu ayrık kosinüs dönüşümü
2B-TBA	: 2-boyutlu temel bileşen analizi
2DLPP	: 2-boyutlu bölge korumalı izdüşüm

1. GENEL BİLGİLER

1.1. Giriş


Biyometri genel olarak “istatistiksel yöntemlerin tıp ve biyoloji alanına uygulanması” şeklinde tanımlanmıştır. Daha özel olarak biyometri, insanların fiziksel ve davranışsal özelliklerini değerlendirerek, kişinin biyometrik karakteristiklerin belirlenmesi çalışmaları ve bu alanda geliştirilen ölçme teknikleridir [1, 2]. Biyometrik ölçümlerle elde edilebilen biyometrik özellikler, kişiye ait tekil özellik olduğundan kimlik tespitinde kullanılabilir. Şekil 1.1’de verilen, DNA, retina ve iris, parmak izi, el geometrisi, avuç izi, toplardamar çizgileri, ses, koku, yüz, kulak memesi, burun yapısı, el yazısı ve yürüyüş şekli ölçülebilir biyometrik özelliklerden bazılarıdır [1].

Biyometrik özelliklerden DNA analizi ve karşılaştırması, pek çok olayın aydınlatılmasında, kriminal laboratuarlarda, doğruluğundan şüphe edilmeden kullanılan bir yöntem haline gelmiştir. Ebeveyn doğrulama ve suç ortamlarından alınan örneklerin mahkemelerde delil olarak sunulması, DNA’nın kullanıldığı alanlardan bazılarıdır. Özellikle güvenlik birimlerince suçluların tespitinde yaygın bir şekilde parmak izi biyometrik özelliği kullanılmaktadır. Günümüzde, ülkeler arası vize işlemlerinde biyometrik fotoğrafın yanı sıra, el geometrisini de içeren el görüntülerinin parmak izleri ile beraber alınması yaygınlaşmaktadır [1, 3]. Biyometrik özelliklerin ölçülmesi alanındaki gelişmeler, yakın gelecekte çok farklı biyometrik özelliklerin de kullanılacağına göstergesidir. Yakın gelecekte, biyometrik özelliklere dayalı otomatik kimlik tespit etme teknolojileriyle, özellikle terörizme karşı büyük avantaj sağlanması hedeflenmektedir [3].

Biyometrik özelliklerin kullanımının, insanoğlunun yaradılışına dayandığını söylemek mümkündür [4]. O zamanlar bu işlem, kişilerin fiziksel ve davranışsal özelliklerinin tanımlanmasıyla gerçekleştirilmekteydi. Örneğin, x sınıfındaki kişi için, kısa siyah saçlı, esmer, kısa boylu ve yapılı erkek şeklinde bir tanımlama ile seçenekler azaltılabilir. Bu teknikler çok güvenilir olmasa da, dâhil olduğu küme içerisindeki kişi sayısını azaltmış olur ve karşılıklı özellik çıkarmaya devam edilerek kimlik tespiti yapılabilir.

Günümüzde kimlik tespiti genel olarak 3 farklı şekilde yapılabilir: gizli bilgi (şifre, parola vb.), kişiye ait taşınabilir eşya (akıllı kart, hüviyet, klasik anahtar vb.) ve biyometrik

özellik. Bilgi ve eşyalar, unutulabilir, kaybedilebilir veya çalınabilir. Biyometrik özellikler insanın bir parçasıdır, unutulamaz ve kaybedilemezler. Biyometrik özelliklerin çalınması imkânsızdır. Ancak bazı biyometrik özelliklere dayalı sistemler, biyometrik özellikleri kopyalama veya taklit etme gibi bir takım yöntemlerle kandırılabilir. Bunu yapabilmek, kullanılan biyometrik sistemin çok iyi bilinmesini gerektirdiğinden diğer kimlik doğrulama yaklaşımlardaki anahtar/bilginin çalınmasından daha kolay değildir.



Şekil 1.1. Biyometrik özellikler [1] , (a) DNA, (b) Kulak, (c) Yüz, (d) Termografik yüz, (e) Termografik el, (f) Toplardamar, (g) Parmak izi, (h) Yürüyüş şekli, (i) El geometrisi, (j) İris, (k) Avuç izi, (l) Retina, (m) El yazısı (imza), (n) Ses

Bir biyometrik özelliğin kimlik doğrulama ve tanımda kullanılabilir olması için standartlaştırılmış bir takım özelliklere sahip olması gerekir. Bunlar [2]:

- Biyometrik veri evrensel olmalıdır: Her bir bireyin biyometrik özelliği vardır. Ancak bazı istisnai durumlarda (parmağın olmayışı veya çeşitli hastalıklarla parmak izinin silinmiş olması) ölçülemeyebilir.

- Biyometrik özellik tekil olmalıdır: İki veya daha çok insanın biyometrik özellikleri aynı olamaz. Pratik çalışmalarda, eşleştirmeler sonucu benzese bile, hata olasılığı kabul edilebilir seviyede olmalıdır.
- Zamanla değişen özellikler biyometrik özellik değildir: Yaralanma ve yanma gibi durumlarda kuşkusuz veriler geçici olarak kaybedilebilir.
- Biyometrik özellikler, kolayca elde edilebilir ve uygulanabilir olmalıdır: Değişik koşullarda çalışabilmeleri için biyometrik düzeneklerin basit olması avantaj sağlar.
- Biyometrik verilerin başarımı yüksek olmalıdır: Sistemin genel başarımı, hızlı veri toplama, yüksek hassasiyet ve hatalara karşı dayanıklılık ile ölçülür.
- Biyometrik özellikler kabul edilebilir olmalıdır: Çeşitli nedenlerle kullanılan biyometrik özelliğe karşı tepki oluşabilir (bazı insanlar yüz fotoğraflarının alınmasını istemeyebilir).

Değişik biyometrikler, bu özelliklere farklı derecelerde sahip olabilir. Yüz, el geometrisi, duruş veya yürüyüş şekli kolayca toplanabilmelerine karşın başarımları diğer biyometrik özelliklere göre daha azdır. Diğer taraftan, retina, iris tarama ve DNA gibi özelliklerin toplanabilmesi oldukça zordur. Yıllarca, parmak izi yukarıdaki karakteristiklerin tamamını en iyi derecede sağlayan biyometrik özellik olmuştur. Parmak iziyle kimlik tespit etme 19. yüzyılın sonlarına denk gelmektedir [5]. Ancak Babil ve Çin’de yapılan arkeolojik çalışmalarda, kil tabletler üzerindeki yazılarda parmak izleri onaylama işaretlerine rastlandığı rapor edilmiştir [4]. Parmak izi, günümüzde teknolojik gelişmelere ayak uydurmuş cihazlarıyla, kimlik tespiti ve doğrulanması için en geçerli yöntemdir [5].

Diğer taraftan, biyometrik özelliklerin kullanım alanlarını sadece giriş-çıkış kontrolü gibi uygulamalarla sınırlamak yanlış olur. Suçluların veya teröristlerin yakalanması amacıyla askeri alanlar, havalimanları, market gibi kamuya açık alanlarda biyometrik özellikler kullanılabilir. Bunun için en ideal donanımsal çözüm, hâlihazırdaki güvenlik kameralarıdır. Bu amaçla en çok yüz tanıma alanında çalışmalar yapılmıştır. Yüz, cihazla teması gerektirmediği gibi uzaktan seçilebilir. Fakat istenilen yüz ayrıntılarının elde edilebilmesi ancak yüksek çözünürlükteki kameralarla sağlanabilir. Son zamanlarda, yüz tanıma alternatif olarak, yürüyüş şekli davranışsal biyometrik özelliği incelenmeye başlanmıştır. Yürüyüş şekli, uzaktan, düşük çözünürlükteki görüntülerden belirlenebilir. Kızılötesi veya termal kamera ile yürüyen kişinin yürüyüş modeli karmaşık ve karanlık


ortamlarda çıkarılabilir. Yürüyüş biyometrik özelliği, cihazla teması gerektirmediği gibi kişinin rızasını da gerektirmez. Yürüyüşün diğer bir avantajı da, bütün eylemlerin temelinde olmasıdır. Kişi mevcut biyometrik sistemleri kullanmak için bile yürümek zorundadır. Yürüme esnasında, kişi her zaman bütün olarak görülemeyebilir veya taşınan bir eşya, fiziksel yapının bozulmasına neden olabilir. Fakat yürüyüş biyometrik özelliği diğer biyometrik özelliklerle karşılaştırınca, kullanılabilir alanlarının yaygınlığı ve verinin toplanması bakımından avantajlar sağlar.

Biyometrik sistemleri ikiye ayırmak mümkündür. Birincisi güvenlik hatlarında giriş çıkış kontrolünün sağlanmasıdır. Bu durumda kişi kendisini düzgün tanıtmak zorundadır. Yani, elini ve parmağını cihaza düzgün yerleştirdiği, yüzünü tam olarak gösterdiği veya düzgün yürüdüğü takdirde güvenlik hattından geçebilir. İkinci sistem suçluların yakalanmasında devreye girer. Bu sistemlerde kullanılacak biyometrik özellikler gizlenemeyen türden olmalıdır. Bu sistemlere şimdilik en uygun biyometrik özellik, düşük çözünürlükteki görüntülerle uzaktan algılama avantajlarıyla yürüyüş şeklidir.

Yürüyüş şekli biyometrik özelliğinin temeli, tıbbi çalışmalardan gelmektedir. Murray vd.'nin çalışmasında, fotoğraflama tekniği kullanılarak normal olmayan yürüyüşlerin belirlenmesi amacıyla yürüyüşler incelenmiştir [6]. Çalışmalarının sonucunda, yürüyüş şekline dair 24 bileşen belirlenmiş ve tüm bileşenlerin beraber düşünüldüğünde, yürüyüşün tekil bir özellik olduğu öne sürülmüştür. Daha gelişmiş bir teknolojiyle, bu alandaki ilk görsel çalışma Johansson tarafından yapılmıştır [7]. Johansson, ışıklı noktaların görünümü (point-light displays, PLD) diye bilinen yöntemi geliştirmiştir [7]. Oluşturduğu sistemde, karanlık bir odada koyu elbiseler giyinmiş kişilerin yürüme/koşma anlarındaki hareketleri, kişilerin eklem yerlerine yerleştirilen ışıklarla izlenmiştir. Psikoloji alanında çalışmalar yapan Cutting ve Kozlowski de, PLD yöntemini kullanarak arkadaşlarını tanımayı başarmıştır [8].

Bilgisayarla görme alanında ilk yürüyüş tanıma çalışması olarak Niyogi ve Adelson'un standart yöntemlerle silueti incelemesi düşünülebilir [9, 10]. Onların çalışmasında, silüete eğriler oturtularak etiketlemeler yapılmış ve bu etiketler üzerinden yürüyüş işareti oluşturulmuştur. Sonraki yıllarda Murasa ve Sakai tarafından hareketli nesnelerin tanınması amacıyla temel bileşen analizi (TBA) kullanılmıştır [11].

2000 yılı öncesi yürüyüş şeklinden kişi tanıma çalışmalarında elde edilen başarılı sonuçlar, zamanla gelişen teknolojiyle zengin içeriğe sahip veritabanlarının oluşturulmasına vesile olmuştur.

		
UMD	Georgia Tech.	CMU
		
CASIA A	CASIA B	CASIA C
		
SOTON Large	SOTON Large	USF

Şekil 1.2. Bazı yürüyüş veritabanlarından örnek görüntüler

Yürüyüş alanındaki ilk veritabanı olarak, California Üniversitesi, Görsel Hesaplama Grubu tarafından 6 kişiyle oluşturulan UCSD¹ yürüyüş veritabanı bilinir [12]. Ardından Southampton Üniversitesi'nin, haziran 1998'de 6 kişiden oluşturduğu birinci versiyon yürüyüş veritabanı (SOTON²) gelir [13]. Yürüyüş biyometrisinde, DARPA³'nın, IPTO⁴

¹ UCSD : University of California, San Diego

² SOTON : University of Southampton

acenteliği tarafından HumanID (Human Identification at a Distance) programının sponsor edilmesi en büyük gelişme olarak kabul edilebilir. HumanID programında, uzaktan (150 m) otomatik kimlik tespiti yapabilen sistemlerin geliştirilmesi amaçlanmaktadır [3, 14]. Bu hedef doğrultusunda, Georgia Teknoloji Enstitüsü (GaTech)⁵, Southampton Üniversitesi (SOTON), Carnegie Mellon Üniversitesi (CMU)⁶, Massachusetts Teknolojisi Enstitüsü (MIT)⁷, South Florida Üniversitesi (USF)⁸, Chinese Bilimler Akademisi Otomasyon Enstitüsü (CASIA)⁹ vb. gibi pek çok uluslar arasında ünlü üniversite ve araştırma enstitüleri, HumanID programı tarafından teşvik edilmiştir [3]. Yürüyüş veritabanları için deney standartları enstitüsü (NIST¹⁰) kurulmuştur.

GaTech, yön, zaman ve uzaklık değişkenleriyle 20 kişilik [15], CMU yön, hız ve eşya değişkenleri ile yürüme bandında 25 kişilik [16], MIT, yön ve zaman değişkenleri ile 24 kişilik, Maryland Üniversitesi (UMD)¹¹ yön değişkeni ile 25 ve 55 kişilik 2 veritabanı [17, 18], USF yön, zemin, zaman, elbise değişikliği ve eşya taşıma değişkenleri ile 122 kişilik [13, 15], CASIA, yön değişkeni ile 20 kişilik [21] ve SOTON yön değişkeni ile 115 kişilik veritabanları oluşturmuştur [13]. Son olarak 2005 yılında CASIA [21] tarafından 2 yeni yürüyüş veritabanı daha kullanıma açılmıştır. CASIA-B diye geçen sürümünde, 11 farklı kamerayla eş zamanlı 124 kişinin yürüyüş kayıtları vardır. Bu veritabanında, kişiler normal, çantalı (omuz veya el çantası) ve kalın elbiseli (montlu) olarak yürümüşlerdir. CASIA-C diye geçen diğer yürüyüş veritabanında, 153 kişinin sabit konuşlandırılmış tek bir kızılötesi kamera ile karanlıkta oluşturulmuş kayıtları mevcuttur. Her bir kişi, normal, çantalı, hızlı ve yavaş yürüyüşler yapmıştır. Tezde kullanılan CMU, SOTON, USF ve CASIA veritabanları hakkında daha ayrıntılı bilgilere ekler bölümünde yer verilmiş olup, Şekil 1.2’de bazı veritabanlarına ait örnek görüntüler görülmektedir.

Bu tez çalışmasında, basit güvenlik kameralarıyla kimlik tespiti yapabilmek amacıyla, yürüyüş şekli biyometrik özelliği incelenmiştir. Statik konuşlandırılmış kameralar aracılığıyla alınan video kayıtlarından üretilen silüet dizilerinden yürüyüş şeklini temsil edecek yürüyüş örüntülerinin oluşturulması ve yürüyüş örüntüsü tanıma amaçlı

³ DARPA : The Defense Advanced Research Projects Agency

⁴ IPTO : Information Processing Techniques Office

⁵ GaTech : Georgia Institute of Technology

⁶ CMU : Carnegie Mellon University, Robotic Enstitute

⁷ MIT : Massachusetts Institute of Technology

⁸ USF : University of South Florida

⁹ CASIA : Institute of Automation Chinese Academy of Sciences

¹⁰ NIST : National Institute of Standards and Technology

¹¹ UMD : Univeristy of Maryland

örüntü tanıma ve sınıflandırması hedeflenmiştir. Yürüyüş örüntüsü üretmek için, yürüyüş dizilerindeki silüetlerin özlük analizi, ayrık kosinüs dönüşümü (discrete cosine transform, DCT), silüetlere 4-farklı yönden (sağ, sol, alt, üst) bakış (4Yön) ve silüetlerin p aralıklı mutlak farklarının enerjisi (pCFEI) hesaplanmıştır. Önerilen yürüyüş örüntülerinden pCFEI en iyi performansı vermiştir. Örüntü tanıma aşamasında, TBA, doğrusal ayrıştırma analizi (DAA, linear discriminant analysis (LDA)), çekirdek temel bileşen analizi (ÇTBA, kernel principal component analysis (KPCA)) ve çekirdek ayrıştırma analizi (ÇAA, kernel discriminant analysis (KDA)) gibi istatistiksel yaklaşımlarla ham örüntülerin öznitelikleri boyut indirgeme ve özellik ayrıştırma yapılarak çıkarılmıştır. Böylece yürüyüşler daha az veri ile temsil edilebilmiştir. Sınıflandırma aşamasında, destek vektör makineleri (DVM, support vector machine (SVM)) ve en yakın komşuluk (EYK, nearest neighbour (NN)) yaklaşımları kullanılmıştır.

Çalışmada, yürüyüş örüntüsü üretiminde, öznitelik uzayının yeniden düzenlenmesinde (sınıflandırma işleminden önce veri uzayının normalize edilmesinde) ve EYK sınıflandırıcısının kullandığı uzaklık ölçütlerinde önerilen yeni yaklaşımlarla katkılar kazandırılmaktadır. Ayrıca, yüz tanımda kullanılan öznitelik çıkarma yöntemleri, yürüyüş örüntüleri için düzenlenmiş ve farklı şartlardaki yürüyüşlerin, yüz tanımda karşılaşılan mimik, gülme gibi ifadelerle karşılık geldiği gözlemlenmiştir. Önerilen yaklaşımların performansı, CMU, SOTON, USF ve CASIA yürüyüş veritabanları üzerinde yaygın referans-test setlerine göre yapılan deneysel çalışmalar ve sonuçlarıyla desteklenmiştir.

Takip eden bölümlerde, yürüyüş biyometrik özelliklerini ölçme amacıyla, gözetleme sistemlerinde nesne algılama ve takip etme yöntemlerine değinilecektir. Ardından, kamera tabanlı yürüyüş şeklini ölçme sistemlerinde, yürüyüş örüntüsü üretme ve öznitelikleri çıkarma aşamalarını içeren yürüyüş karakteristiğinin belirlenmesi ve sınıflandırılması üzerinde durulacaktır.

1.2. Yürüyüş Biyometrik Özelliklerinin Çıkarılması

Yürüyüşten kişi tanıma sistemleri, teknolojik açıdan 2 farklı gruba ayrılabilir. Bunlar algılayıcı ve makine görmesine dayalı sistemlerdir.


1.2.1. Algılayıcı Sistemlere Dayalı Yürüyüş Biyometrik Özelliği

Algılayıcı sistemler, zemin algılayıcı ve giyilebilir algılayıcı olmak üzere iki gruba ayrılabilir. Zemin algılayıcı kullanılan sistemlerde, adım boyu, ayaklar arasındaki açı gibi özellikler, yürüyüş alanına yerleştirilen algılayıcılarla çıkarılır. Giyilebilir algılayıcı kullanan sistemlerde ise, adım boyu, alt karın bölgesinin yürüyüş esnasındaki dalgalı hareketi gibi özellikler, kişinin üzerindeki algılayıcılarla elde edilir. Şekil 1.3.(a)'da algılayıcıların olduğu bir yürüyüş zemini, Şekil 1.3.(b-c)'de ayak bileği ve bele takılabilen algılayıcı sistemleri görülmektedir.

Orr ve Abowd'un çalışmasında, zemin algılayıcısı kullanılarak 15 kişiden 1680 adım toplanmış ve %93 tanıma başarısı elde edilmiştir [22]. Suutala ve Roning'in çalışmasında, 31 farklı özellik (ayağın yerde kalma süresi, ayağın yere değme genliği vb.) kullanılarak 11 kişinin 200 adımından %70.2 tanıma başarısı elde edilmiştir [23]. Middleton'nin çalışmasında, 3 farklı özellik kullanılmıştır: adım boyu, adım ritmi ve topuk ile ayak ucunun yerde kalma sürelerinin oranı. Bu özellikler kullanılarak, 15 kişiden 12'si yürüyüşünden tanınmıştır [24].

Giyilebilir algılayıcı sistemlerde, hareket algılayıcılar kişinin üzerine monte edilirler. Bilinen ilk giyilebilir algılayıcı çalışması, Morris tarafından yapılmıştır [25]. Morris'in çalışmasında, yürüyüşün daha çok klinik yönleriyle ilgilenilmiştir. Ailisto vd.'nin çalışmasında, kemer bölgesine monte edilen hareket algılayıcılarıyla, 36 kişilik veritabanında %6.4 EER başarısı elde edilmiştir [26]. Gafurov vd.'nin çalışmasında, bel bölgesine hareket algılayıcısı takılmış ve 22 kişiyle %16 EER tanıma başarısı elde edilmiştir [27]. Gafurov vd.'in diğer bir çalışmasında, ayak bileğine takılan algılayıcıyla %86.3 tanıma başarısı sağlanmıştır [28].

Kullanım alanı açısından değerlendirildiklerinde, algılayıcı kullanılan sistemler kimlik doğrulama için kullanılabilirken, görme tabanlı sistemler doğrulama ve tanılama alanlarında daha çok yer alabilmektedir. Zemin algılayıcı sistemler, kapı girişlerinde herhangi bir rahatsızlık teşkil etmeden kullanılabilir. Giyilebilir algılayıcı sistemlerle, özellikle tıbbi alanlarda tanı ve teşhisler yapılabilir. Kameralı görme tabanlı sistemler ise uzaktan, gözetleme sistemlerinde düşük çözünürlükteki görüntülerle güvenlik önlemlerinde büyük avantajlar sağlayabilir.




Şekil 1.3.Algılayıcı sistemler: (a) zemin algılayıcı, (b) ve (c) giyilebilir algılayıcı

1.2.2. Makine Görmesine Dayalı Ölçülen Yürüyüş Biyometrik Özelliği

Günümüzde, yüz, kulak, yürüyüş biyometrik özelliği denilince akla gelen ilk veri tipi görüntüdür. Kamera ile bilgisayara aktarılan görüntü/ler üzerinde biyometrik özelliği niteleyebilecek ölçümler kimlik tespitinde kullanılabilir.

Kameralı yürüyüş tanıma sisteminde yürüyüş biyometrik özelliğinin ölçümü, genelde gözetleme sistemlerindeki düşük çözünürlükteki kameralarla alınan gözetleme görüntülerinden üretilen yürüyüş siluet dizileri üzerinde gerçekleşir. Siluetlerin statik yapısı ve yürüyüş esnasında oluşan dinamik değişimleriyle belirlenen yürüyüş karakteristiği, yürüyüş görüntü dizilerinde, beden ölçümleri, uzuvlar arasındaki açılar veya siluetin bütününden oluşturulan şablonlar incelenerek çıkarılır. Kimlik tespiti, önceden depolanmış yürüyüş karakteristikleriyle anlık belirlenen karakteristikler karşılaştırılarak yapılır. Şekil 1.4'te, bir yürüyüş tanıma sistemi genel hatlarıyla verilmiştir.



Şekil 1.4. Yürüyüş şekline dayalı kişi tanıma sistemi

1.2.2.1. Nesne Algılama ve Takip Etme

Yürüyüşünden kişi tanıma sistemleri, gözetleme sistemleri üzerine inşa edilir. Yani öncelikle hareketli nesnelerin algılanması, yürüyen insanların belirlenip takip edilmesi gerekir. Otomatik gözetleme sistemlerinin bu yeteneğe sahip olması beklenir.

Gözetleme sistemlerinde hareketin varlığını anlamamanın en basit yolu, ardışık çerçevelerin farkını almaktır. Diğer bir yaklaşım, anlık çerçevelerin arka plan modeli ile karşılaştırılmasıdır. Hesaplama maliyeti yüksek diğer bir yöntem de, optik akışların kontrol edilmesidir. Hareketin varlığından sonra, hareket olan kısımda nesneyi bulmak ve tanımlamak gerekir. Algılanan nesneler, nesnelere ait özelliklerin belirlenip tarihçesinin oluşturulması ile izlenebilir [29-31].

Arka plan ile karşılaştırma yöntemi, karşılaştırma esnasında silueti doğrudan üretir. Bu özellik, optik akış ve ardışık çerçeveler arası fark alma yöntemlerinde yoktur. Hesaplama ve gürültü açısından da değerlendirme yapıldığında, yürüyüşten kişi tanıma çalışmaları için gözetleme sistemlerinde kullanılması en uygun hareket algılama ve nesne belirleme yöntemi, arka plan modeli ile karşılaştırmadır.

Görüntü akışında arka plan modeli, video akışında durağan değerlerin belirlenmesine dayanır. Arka plan modeli basit olarak, görüntü dizisinin ortalaması veya medyanı alınarak

üretilebilir. Günümüzde arka plan modelini ileri istatistiksel yaklaşımlarla daha iyi belirleyen yöntemler kullanılmaktadır [29-31].

Arka plan modeline dayalı hareket algılamada, nesne neredeyse bütün olarak elde edilir. Boşluk doldurma, gürültülerin kaldırılması için basit görüntü işleme teknikleriyle ön işlemler kolayca yapılır. (1.1)'de arka plan modeli ile karşılaştırma işleminin genel hali verilmiştir.

$$ikili_goruntu_t = \begin{cases} 1, & \text{Eger } |I_t - B| > k\sigma \\ 0, & \text{degilse} \end{cases} \quad (1.1)$$

Denklem (1.1)'de B arka plan modeli, I , t anındaki çerçevelerdir. Karşılaştırma sonucu elde edilen ikili görüntüde, gürültü eliminasyonu için morfolojik işlemler yapılır. Sonra, ikili görüntünün yatay-dikey projeksiyonları, piksel komşuluk ilişkileri gibi yöntemlerle nesneler ayrıştırılır. Çalışmalarda insan yürüyüş şekli incelendiğinden, ikili görüntüdeki nesnenin insan silueti olup olmadığı araştırılmalıdır [29].

Eklemli yapıdaki canlılar için hareket, merkez konumunun ve uzuv konumlarının birbirine göre değişmesiyle gerçekleşir. Bunun sonucu olarak canlılardaki yürüyüşlerde siluet sürekli değişir. İnsan hareketlerini diğer canlı hareketlerinden ayıran en önemli özellik, siluet iskeletin yıldız topolojisine (Kafa, ayaklar ve kollar) sahip olmasıdır ve genelde insan siluetlerinde, siluet yüksekliği, genişliğinden daha büyüktür. Diğer bir ayırıcı özellik, hareket halinde iken insan iskelet topolojisindeki değişim hayvanlarınkinden farklı olmasıdır. Eklemsiz bir yapıya sahip olan araçların siluetlerindeyse, akış halindeyken bir değişim olmaz [29-31].

Video akışında izleme, algılanan nesnenin konumu, yapısı ve renk bilgisine göre yapılır. Kapanma ve anlık kaybolma problemleri, bu özelliklerin tutulduğu tarihçe ile çözülür. İzleme esnasında arka plan ve nesne özellikleri zamanla oluşan ışık, yapı, ortam gibi değişimler nedeniyle sürekli güncellenir [29-31].

1.2.2.2. Yürüyüş Karakteristiğinin Belirlenmesi

Bir yürüyüşün analizinde iki önemli bileşen göze çarpar. Birincisi kişinin vücut boyutları, kol-bacak uzunlukları gibi vücut şeklinden gelen fiziksel yapı; ikincisi bir

yürüyüş periyodu süresince bedenin değişken hareketidir [32]. Yürüyüşünden kişi tanıma çalışmalarındaki amaç, bu bileşenleri kişiye özel belirleyebilmektir.

Murray'ın çalışmalarında, fotografik görüntülerde insan beden hareketlerini incelemek için beden üzerinde 24 nokta belirlenmiş ve bu noktaların tümünün değerlendirilmesi durumunda yürüyüşün biyometrik özellik olabileceği üzerinde durulmuştur [6]. 2000'li yılların öncesindeki yürüyüş analizi çalışmalarında kullanılan veritabanlarındaki kişi sayısı azdır ve ölçülmesinde hata payı yüksek, az sayıdaki özelliklerle, başarılı sonuçlar elde edilmiştir. Ancak daha sonraları, bu ilkel yöntemler, doğal ortamlardaki problemleri yansıtabilecek şartlarda oluşturulmuş, büyük sayıda kişi içeren veritabanlarında yetersiz kalmıştır. Böylece yürüyüşünden kişi tanıma çalışmalarında, özellikleri küçük hatalarla ölçebilen, fazla sayıdaki örnek ve büyük boyutlu ölçümler için fazlalıkları atıp öznelilikleri belirleyen yaklaşımlar geliştirilmiştir. Literatürde, bu yürüyüş özelliği çıkartma yaklaşımlarını, model-tabanlı ve modelden-bağımsız olmak üzere iki ana grupta toplamak mümkündür.

Model tabanlı yöntemlerde, yürüyen insan görüntülerinde yürüme eyleminden dolayı oluşan; bazı noktalardaki; kol, bacak, beden uzunluklarında ve/veya eğimlerdeki; insan bedenine ve uzuvlarına oturtulan elips, yamuk gibi şekil yapılarındaki değişimlerinden kişisel olanları, yürüme karakteristiği olarak çıkarabilmek amaçlanır [33-48]. Modelden bağımsız yöntemlerde ise, kişisel yürüyüş karakteristiğinin, yürüyüş içeren insan silüetlerinin bir takım izdüşüm ve/veya dönüşümlerine dayalı olarak belirlenmesine çalışılır [49-127]. Her iki tür yaklaşımlarda da, yürüyüş görüntü dizileri üzerinde bir süre ölçümler yapılır ve yürüyüş karakteristiğini barındıran vektörler veya örüntüler üretilir. Sonra bu veriler yürüme periyoduna göre örneklenerek gözlem paketi haline getirilir. Anlık yürüme periyotları genellikle ölçüm vektörleri veya bazı örüntü tipleri üzerinden hesaplanır. Bazı yaklaşımlardaki örüntü üretme tekniklerinde zaman bilgisi kaybolur [57]. Bu nedenle örüntü üretme aşamasından önce silüet ve/veya kutusu üzerinden yürüme periyodu hesaplanır.

1.2.2.2.1. Yürüyüş Periyotunun Hesaplanması

Yürüyüş, belirli aralıklarla benzer karakteristikler gösteren periyodik bir harekettir [6, 32]. Bir yürüyüş periyodu, bir ayağın yerden kesilip aynı ayağın tekrar yere değmesi ile tamamlanır. Yürüyüşünden kişi tanıma çalışmalarında, bu süre yürüme periyodu olarak

tanımlanır ve tam bir adıma denktir. Kameralı sistemlerde süre birimi olarak kameranın saniyede aldığı çerçeve sayısı kullanılmaktadır. Yani kişinin yürüyüş periyodu, tam bir adımı gerçekleştirdiği görüntü çerçevesi sayısıdır. Yürüyüşten kişi tanıma çalışmalarında, örnekleri oluşturan yürüyüş görüntü dizisi parçaları, video görüntülerinin yürüyüş periyoduna göre örneklenmesi ile üretilir.

Yürüyüşten kişi tanıma alanındaki ilk çalışmalarda, yürüyüş videoları genelde aynı ölçek ile örneklenmiştir (çoğunlukla saniyede alınan çerçeve sayısı kadar) [92]. Bu durumda, kişinin yürüyüş hızı diğer kişilerden farklı olabileceğinden normal yürüyüşlerde tanıma daha kolay olabilmektedir. Ancak kişinin kendi hızını değiştirerek yürümesi durumunda, tanıma performansının düşmesi beklenir. Sonuç olarak kişi sayısının fazla olduğu doğal ortam şartlarının bulunduğu alanlarda oluşturulan veritabanlarında, yürüyüş periyoduna göre örnekleme yapılması kaçınılmaz olmuştur.

Diğer bir tanımla yürüyüş periyodu, kişiye ait tüm noktalardan elde edilen zamana bağlı değişim işaret periyotlarının en küçük ortak katıdır (OKEK). Bu nedenle periyot hesabında herhangi bir noktayı değerlendirmek yanlış olur. Ya tümü veya merkez noktası, en/boy oranı, hacimsel değişim vb. gibi, bütün noktaların etkileyebileceği fiziksel özellikler değerlendirilir.

Benabdelkader vd.'in çalışmasında [50], yürüyüş periyodunu tahmin etmek için, siluet kutusunun enindeki değişimler kullanılmıştır [62]. Zamanla elde edilen işaretin öz-ilişkisi hesaplanarak, işaretin minimum değerlerinin birbirine olan zaman uzaklığı, yürüyüş periyodu olarak değerlendirilmiştir. Bir başka çalışmada da, siluetin üzerindeki önplan bilgileri her çerçevede toplanmıştır [68]. Ardışık çerçeveler için minimum toplamlar arasındaki uzaklıklar, periyot tahmini için kullanılmıştır. Benzer yaklaşımla başka bir çalışmada, ardışık siluetlerin yürüyüş ritminin daha net algılandığı alt yarısındaki önplan bilgilerinin toplamlarındaki pikler değerlendirilmiştir [122]. Collins vd.'nin çalışmasında, ayakların yere değme anlarıyla oluşturulan zaman tarihçesinden yürüyüş periyodu hesaplanmıştır [54]. [68]'deki gibi siluet üzerindeki noktaların toplamına göre periyotu tahmin eden Boulgouris vd.'nin çalışmasında, toplamların oluşturduğu zamanla değişen işaretin normalizasyonundan (ortalamasını çıkarıp standart sapmasına bölerek) sonra öz-ilişkisi hesaplanmıştır [92].

Yürüyüş periyodu belirlendikten sonra yürüme görüntü dizileri yürüme periyoduna veya katlarına göre parçalara ayrılır. Elde edilen parçaların her birinden kişisel yürüyüş karakteristikleri üretilebilir.

1.2.2.2.2. Model Tabanlı Yürüyüş Örüntüsü Üretme Yaklaşımları

Model tabanlı yöntemlerde, bedenin yapısal ve hareket modeli çıkarılarak izleme ve özellik çıkarma gerçekleştirilir. Yürüyüş karakteristiği, hareket esnasında model parçalarındaki ve topolojik yapıdaki değişimlere dayalı olarak üretilir.


Yürüyüşün en belirgin karakteristikleri bel ve bacak bölgelerinden elde edilir. Bundan hareketle model tabanlı yöntemlerin bir kısmında bu bölgelerin hareketi modellenmeye çalışılmıştır [33, 35, 36, 38, 41, 44, 45].

Model tabanlı yöntemlere en temel örnek olarak, BenAbdelkader vd.'nin yapısal ölçümlere dayalı çalışması verilebilir [33]. Onların yaklaşımında, periyodikliğine dayalı olarak yürüyüşün ritmi bulunmuş ve alınan yola göre adım boyu hesaplanmıştır. UMD veritabanı üzerinde yaptıkları ölçümlerde adım boyunun ve ritminin, farklı kişiler için doğrusal ve benzersiz olabileceği, kimlik doğrulamaya dayalı olarak bulunmuştur.

Bobick ve Johnson'nun çalışmasında [34], yürüyüş esnasındaki iki ayak arasındaki mesafe, baş ile pelvis (leğen kemiği) arasındaki mesafe, kişinin boyu ve bacak uzunluğu yapısal parametreler olarak kullanılmıştır (Şekil 1.5.(a)). Yapısal parametrelerin sınıf içi ve sınıflar arası değerlendirmelerinde, adım boyunun diğer parametrelere göre daha az etkili olduğu gösterilmiştir. Yapısal özelliklere dayalı diğer bir yaklaşımda, ayak ve göğüs kısmına konulan işaretçilerle eklem açılarının yörüngeleri, zemin referans alınarak belirlenmiştir [40].


Cunado ve diğerlerinin model tabanlı yaklaşımında (Şekil 1.5.(b)), bacakların hareketi bir sarkaca benzetilmiştir [35, 36]. Zamanla elde edilen açısal değişimler, Fourier tayfında incelenmiştir. Bu yaklaşım daha sonra Yam [44] tarafından, yürüme ve koşma esnasında yürüyüş parametrelerinin elde edilmesi için kullanılmıştır (Şekil 1.5.(d)).

Yoo ve Nixon'un çalışmasında [45], insan bedeni modeli, 2-boyutlu çubuk figürle (stick figure) temsil edilmiştir (Şekil 1.5.(c)). Mevcut figür, anatomik değerlere göre silüetlere oturtulmuş ve figürün çubukları arasındaki açıların yörüngesi saklanmıştır [45]. Diğer bir çalışmada, aynı model üzerinde, bacakları oluşturan sarkaç yapının uçlarını birleştiren çizgideki orta nokta, bacakları ve periyodikliği temsil etmek için kullanılmıştır [38]. Urtasum ve Fua'nın çalışmasında, hareketleri yapılandırma ve izleme 3-boyutlu beden modeliyle yapılmıştır [41].



Şekil 1.5. Model-tabanlı yöntemler, (a) [34], (b) [35, 36], (c) [38, 45], (d) [44]

Model tabanlı yaklaşımların bir diğerinde [39], yapısal özellikler elipslerle modellenmiştir (Şekil 1.6.(a)) ve elips bölgelerindeki momentler yürüyüş özelliği olarak alınmıştır. Benzer şekilde, Huang ve Boulgouris'in çalışmasında 8 beden parçası el ile seçilmiştir [48]. Her bir parçanın, gövdeye göre eğimi, merkezi ve alanı yürüyüş parametresi olarak değerlendirilmiştir. Sınıflandırma esnasında her bir parçanın uzaklığı ayrı ayrı hesaplandıktan sonra ağırlık katsayıları kullanılarak birleştirilmiştir. Sınıflandırma, birleştirilmiş uzaklıklara dayalı olarak yapılmıştır. [40]'taki ölçüm parametrelerinin kullanıldığı diğer bir çalışmada, çapraz ilinti ile sınıflandırma yapılmıştır [37]. Onların çalışmasında, kızılötesi kamera teknolojisiyle görüntüler yakalanmıştır.



Şekil 1.6. Model-tabanlı yöntemler, (a) [39], (b) [42, 47], (c) [43]

Zhang vd.'nin çalışmasında, insan uzuvlarının birbirine uyumu ile ilgilenilmiştir [47]. Önerilen yaklaşımda, alt uzuvlar yamuklarla, kolsuz üst kısım elips yüzeylerle modellenmiştir (Şekil 1.6.(b)). Çalışmada, insan bedeninin duruşu, bedeni oluşturan parçaların eğimleri ve göğüs kafesine göre normalize edilmiş uzaklıkları ile temsil edilmiştir. Sonra eklem noktalarının koordinatlarının uzaysal-zamansal tarihçesi hesaplanmıştır. Tarihçelerin Fourier tayfında analizinin ardından saklı Markov modelleri (HMM) ile sınıflandırma yapılmıştır. Yaklaşımın değerlendirmesi, CMU ve USF yürüyüş veritabanlarında yapılmıştır. Aynı model üzerinde farklı ölçümler yapılan diğer bir çalışmada, açık ve kapalı ortamlardaki yürüyüşler için ANOVA analizi uygulanmıştır [42]. Onların çalışmasında, ayak bilekleri, diz altı ve diz üstündeki mesafeler, bel genişliği ve yürüyüş frekansı F-istatistiği ile incelenmiştir. Elde ettikleri sonuçlarla, yürüyüş ritminin [33] ve ilk zamanlarda kullanılan [33, 34] beden ölçümlerinin, yürüyüş karakteristiğini daha iyi temsil ettiği savunulmuştur. Ölçümü yapılan diğer parametrelerin, giyilen elbiseden çok fazla etkilenmesi bunun nedeni olarak verilmiştir [42].

Wang ve diğerlerinin çalışmasında, beden uzuvlarının yörüngelerinin değişimiyle yürüyüş dinamikliği modellenmiştir [43]. Onların çalışmasında, uzuvları temsil etmek için insan bedenine 14 tane esnek olmayan şekil oturtulmuştur (Şekil 1.6.(c)). Sonra yürüyüş esnasında uzuv bağlantı noktalarının yörüngeleri ile dinamiklik eğrisi ve oturtulmuş şekillerin zamanla değişiminin saklandığı kompleks vektörlerin Procrustes şekil analizi ile sabit beden yapısı üretilmiştir. Üretilen eğrilerin bağımsız ve birleştirilmiş halde analizleri

sonucunda, beden eklemlerindeki açısal yörüngelerden üretilen dinamik bilginin, kimlik tanıma ve doğrulama için daha uygun olduğu ileri sürülmüştür [43].

Zhang ve diğerlerinin çalışmasında, Bayes'in grafik modeline dayalı olarak, esnek, 2-boyutlu beden sınırları modeli önerilmiştir [46]. Çalışmada, imgedeki lokal eğriler bulunmuş ve 2-boyutlu model her çerçevede, Monte Carlo yöntemi ile hareketli nesneye oturtulmuştur.

Model tabanlı yöntemlerde tanıma için kullanılan parametre sayısı azdır ve genellikle birkaç noktadan yapılan ölçümlerin zamanla değişimi, yürüyüş imzası olarak belirlenir. Bu yaklaşımlarda, modellerin oturtulması ve/veya uzuvların ölçümü doğru yapılabilirse yürüyüşten kişi tanıma gerçekleştirilebilir [7].

İnsan bedeni karmaşık bir hareket esnekliğine sahiptir ve yürüyüş esnasında beden parçaları sıkça birbirinin görünüşünü engelleyebilir. Ayrıca, doğal ortamlarda, insanların giyimindeki değişiklikler ve taşıdıkları eşyalar insan bedeninden farklı bir yapının oluşmasına neden olabilir. Modellerin doğru oturtulabilmesi ve doğru uzuv ölçümleri için, gürültülerden etkilenmeyen ve izleme esnasında oluşabilen kapanma gibi problemleri çözebilen ileri seviyeli görüntü işleme teknikleri ve yapay zekâ algoritmaları kullanılmalıdır. Bu, modelleme esnasında işlem yükünün artmasına sebep olur ve video işlemlerinde kaçınılan bir durumdur. Sonuç olarak model tabanlı yürüyüş şekli belirleme yaklaşımlarında, bilgiyi yerel değerlendirme işlem yükü, araştırmacıları, video işlemede daha çok tercih edilen, bilginin global yorumlanmasına dayalı yöntemlere yöneltmiştir. Bu durum, yürüyüşün biyometrik özellik olduğunun model tabanlı yöntemlerle kanıtlanmasının ardından [33-35, 45], yürüyüşteki biyometrik karakteristiklerin belirlenmesi çalışmalarının, görünüme dayalı, silüet tabanlı ve modelden bağımsız yaklaşımlar yönünde gelişmesine sebep olmuştur [119].

1.2.2.2.3. Modelden Bağımsız Silüet Tabanlı Yöntemler

Bedenin anatomik yapısını kullanmadan, kişisel yürüyüş karakteristiğini görünüme dayalı olarak belirleme yaklaşımlarına, modelden bağımsız yöntemler denir. Modelden bağımsız yöntemler, silüete dayalı üretildiği için silüet tabanlı yaklaşım olarak ta adlandırılmaktadır.

Yürüyüşünden kişi tanıma çalışmalarının en yoğun olduğu alan, modelden bağımsız yaklaşımlardır. Modelden bağımsız yaklaşımlar, modele dayalı yaklaşımlara göre

gürültüden daha az etkilenmekte ve işlem yükü açısından daha kolay uygulanabilmektedir [119]. Bu yaklaşımlarda siluetten faydalanılır ve önceki çerçevede yapılan ölçüm veya model oturtma parametreleri gibi bilgilere ihtiyaç duyulmaz. İşlemler, anlık çerçevelerde yapıldığından, önceden yapılan hatalı ölçümlerden etkilenmezler. Modelden bağımsız yöntemler görünüme dayalıdır ve hammadde olarak siluetin tamamı kullanılır. Bunun sonucu olarak, yapılan ölçümdeki veri sayısı, model-tabanlılara göre oldukça fazladır. Böylece yürüyüşün karmaşık yapısından ve doğal ortamlarda izlemedeki kapanmalardan dolayı oluşan hatalı ölçümlerin doğru ölçümlere oranının az olması beklenir.

Modelden bağımsız yöntemlerde bir yürüme periyodundaki yürüyüş siluet görüntüleri, 2-boyutlu halde ilinti [7, 54, 11, 68, 94], vektöre çevrildikten sonra frekans analizi [121, 122], Radon dönüşümü [98] gibi yöntemlerden sonra sınıflandırılabilir. Bu tür yaklaşımlar, verilerin siluet formatında büyük kapasitelerde saklanmasını gerektirir. Fakat farklı kişilerin siluetlerinde bile ortak özellikler, yani ayrıştırıcı kullanılmayan bilgiler vardır. Bu durumda yürüyüş siluet dizilerini, tekrarlılıklardan kurtarıp yalnızca ayrıştırıcı özelliğe sahip bilgilerle saklamak avantaj sağlar. Ayrıca, tekrarlılıkların atılmasıyla sınıflandırıcıların işlem ve başarı performansı artar. Bunun için siluetlerin uzaysal izdüşümlerine [79, 93, 94], genişliklerine [92, 100, 101], siluetin sınırları ile siluet kutusu arasındaki mesafelere [78], siluet sınır noktalarının konum, merkeze olan uzaklık veya açısal bilgilerine [32, 70, 74, 75, 107, 124, 103] dayalı olarak, bir yürüyüş periyodu boyunca alınan ölçümlerden yürüyüş örüntüsü üretilir. Diğer yürüyüş örüntüsü üretme tekniklerinde, dizideki siluetlerin çeşitli formlarda bir periyot boyunca enerjisi hesaplanır [49, 55-59, 63, 64, 66, 69, 73, 80-89, 95, 97, 98]. Yürüyüş örüntülerinde de tekrarlı bilgiler mevcuttur. Bu nedenle, yürüyüş örüntülerinin ayrıştırıcı özellikleri istatistiksel yöntemlerle belirlenip küçük kapasitelerde saklanabilir.

Yürüyüşten kişi tanıma amacıyla, Niyogi ve Adelson tarafından yapılmış bilinen ilk çalışmada, baş ve bacaklar XT boyutlarında ayırıcı özellik olarak düşünülmüştür [9]. Onların yaklaşımını destekleyen, çok sonraları yapılmış bir çalışmada, XT-boyutlarında, baş ve bacakların farklı örüntülerini üretmek için sınır çizgileri belirlenip beş etiket yerleştirilerek model uydurulmuştur [67]. Niyogi ve Adelson'un başka bir çalışmasında, XYT örüntüsü, yürüyüş periyodikliğini yaklaşık yansıtan uzay-zaman düzlemine uydurulmuştur [10].

Little ve Boyd'nin çalışmasında, optik akış dağılımıyla yürüyüş özellikleri tanımlanmıştır [12]. Hareketin biçimi, akış ölçümlerinin birkaç kümesi tarafından

karakterize edilen akış dağılımı olarak üretilmiştir. Akış ölçümleri olarak hareketli noktalar ve akış değerleri alınır. Akışın özellikleri, merkezleri ve dağılımın ikinci momentlerini içerir. Dağılımlar, her bir skaler için zaman serisi formunda düzenlenmiştir. Onların çalışmasında, skaler dizilerindeki faz özelliklerinin, bir kişi için tutarlı ve kişiler arasında önemli bir istatistiksel değişime sahip olduğu belirlenmiştir. Bundan hareketle faz özellik vektörleri, kişisel tanıma için kullanılmıştır [12]. Bir diğer optik akışa dayalı yaklaşım, Nixon ve ekibi tarafından uygulanmıştır [99]. Onlar Öklid uzaklığını kullanarak EYK sınıflandırması yapmıştır.

Murasa ve Sakai'nin çalışmasında, siluet imgelerinden özdeğer ayrıştırması ile özvektörler hesaplanmıştır [11]. Bir yürüyüş imgesi, özvektörlerin yayıldığı özuzaydaki bir noktaya haritalanmış ve düşük boyutlu özuzayda, yürüyüş tarihçesi bir yürüyüş dizisi için elde edilmiştir. Sonra yürüyüşleri ayırt etmek için özuzaydaki temsillere dayalı olarak şablon eşleştirme yapılmıştır. Bu yaklaşım, daha sonra Huang vd. tarafından geliştirilmiştir [60]. Onların çalışmasında, TBA'ne dayalı özuzay dönüşümü ve kanoniksel analize (canonical analysis) dayalı kanonik uzay dönüşümü birleştirilerek farklı yürüyüş dizileri için daha iyi sonuçlar elde edilmiştir. Huang vd.'nin siluet sınırlarının genişliğini kullandığı diğer bir çalışmada, HMM kullanılmıştır [61]. Onların çalışmasında, şekil ve hareket bilgisini elde etmek için çerçeve örnek uzaklığı önerilmiştir. Çerçevenin örneğe uzaklığı, nesnenin şekil ve hareket bilgisini üretmek için kullanılmıştır. Çalışmada, öncelikle HMM her bir kişi için eğitilmiş ve sonra, verilmiş test dizisinin olasılığı parçalı HMM ile hesaplanarak tanıma gerçekleştirilmiştir.

HMM, Kale vd. ve Sundaresan vd.'nin yürüyüş şekline göre kişi tanıma çalışmalarında da kullanılmıştır [32, 70, 100]. Onların çalışmalarında, ikili siluet sınırlarının genişliği (dolaylı) ve siluetin kendisi (doğrudan) özellik olarak kullanılmıştır. Önerilen dolaylı yaklaşımda, nesnenin şeklinden ve hareketinden hesaplanan çerçeve model uzaklığı (Frame to exemplar distance (FED)) HMM'de kullanılır. HMM ile belirlenen FED vektörler veriyi daha küçük boyutlarda temsil eder [32]. Doğrudan yöntemde, özellik vektörleri orijinal siluetten HMM ile hesaplanmıştır. Model ve özellik vektörleri arasında uzaklık kullanılarak, olayın gerçekleşme olasılığı hesaplanmıştır [32, 70]. Çalışmalar UMD, CMU MoBo ve USF yürüyüş veritabanlarında test edilmiştir.

Cuntoor ve ekibinin çalışmasında [79], önden ve yandan görüşlerindeki siluet dizilerinde, ayak ve el dinamiklerinin, beden hareketlerinin ve yapısının, siluet

genişliğinin, siluet sınırının sağ ve sol izdüşümlerinin, kişi tanımadaki başarısı yine HMM ile incelenmiştir.


Southampton Üniversitesi'nin yaklaşımlarında, Foster vd. tarafından siluete uygulanan dikdörtgen maskelerle alanların ölçümü [55] ve Shutler vd.'nin istatistiksel momentleri [69], yürüyüş örüntüsünün üretilmesinde kullanılmıştır. Bu yaklaşımlarda, bir periyot boyunca hareket bilgisi ile şekil bilgisi birleştirilmiştir.

BenAbdelkader ve arkadaşlarının çalışmasında [49], siluet dizilerinden siluetlerin birbirine benzerlik değerleri matrisi, yürüyüşteki kişisel farklılığı belirlemek amacıyla hesaplanmıştır (Şekil 1.7.(a)). Onların iddiasına göre, kendine benzerlik matrisi yürüyüşün frekans ve fazını kodlamaktadır. Önerilen yaklaşımla, UCSD yürüyüş veritabanı üzerinde elde edilen yürüyüş karakteristikleri, k -en yakın komşuluk (k -EYK, k -nearest neighbour (k -NN)) kriterine göre sınıflandırılmıştır. Daha sonraki çalışmalarında, CMU MoBo ve UMD yürüyüş veritabanlarında ürettikleri kendine benzerlik matrislerinin, TBA ile boyut indirgemesi ve yine k -EYK kriterine göre ayrıştırılması yapılmıştır [50].

Kale ve diğerlerinin başka bir çalışmasında [101], siluet satırlarının genişliğinden yürüyüş örüntüsü üretilmiştir (Şekil 1.7.(b)). Sonra her bir örüntünün özvektörleri, özellik vektörü olarak ele alınmıştır. Son olarak Öklid uzaklığına dayalı sınıflandırma yapılmıştır. Benzer yürüyüş örüntüsü üretme yaklaşımı Su ve arkadaşları tarafından da kullanılmıştır [123]. Onlar L1-TBA ile boyut indirgeyip DAA ile öznelilik çıkarmıştır. Çalışmalarında, yürüyüş örüntüleri için L1-TBA ile, geleneksel TBA'ya göre daha iyi sonuçlar elde edilmiştir.

USF yürüyüş veritabanının sağlayıcısı Sarkar ve ekibinin yaptığı bazı çalışmalarda [68, 108] Baseline yaklaşımı önerilmiştir. Baseline yaklaşımında, yürüyüş periyoduna göre parçalanmış siluet dizilerinde, gürültülerden arındırılıp normalize edilmiş siluetler arasında ilintiler hesaplanmış ve ilinti değerlerinin benzerliğine göre sınıflandırma yapılmıştır. Önerilen Baseline yaklaşımı, USF ve CMU MoBo veritabanlarında test edilmiştir.

Vega ve Sarkar'ın çalışmasında, belirlenmiş imge özellikleri arasında, ilişkisel istatistikteki değişimleri kullanan görünüme dayalı hareket analizi yapılmıştır [72]. İlişkisel istatistik, bir imgede görülebilir parçalı ilişkilerin random gruplanması ile oluşan dağılımın modellenmesidir. Bu dağılımlar, olasılık fonksiyonlarının uzayında temsil edilir. Yine Sarkar'ın ekibinden Liu ile yaptığı çalışmasında [96], siluet dizilerinde duruşu modellemek amacıyla HMM kullanılmış ve ayırt edici özellikler TBA ve DAA yaklaşımıyla elde edilmiştir.



Şekil 1.7. Siluet tabanlı örüntü üretme teknikleri, (a) kendine benzerlik, (b) genişlik vektörü, (c) yatay-dikey izdüşümler, (d) radon, (e) sınır uzaklıkları, (f) 4yön

Collins vd. çalışmasında, bakış noktasına bağlı olarak, dizilerin eşleştirilmesinde anahtar çerçeve analizi kullanılmıştır [54]. Anahtar çerçeveler, normalizeli ilinti kullanılarak eğitim çerçeveleri ile karşılaştırılır ve nesneler, çapraz-ilinti skorlarına dayalı olarak EYK kriteriyle sınıflandırılır. Çalışmada, CMU MoBo, MIT, UMD ve SOTON

yürüyüş veritabanları kullanılmıştır. CMU'dan önerilen başka bir yaklaşımda Liu vd. [65], siluet dizisindeki siluetlerin satır ve sütunlarını ayrı ayrı toplamış ve toplam değerlerini yürüyüş örüntüsü sütunlarına yerleştirmiştir (Şekil 1.7.(c)). Bu yürüyüş örüntüsüne şavak örüntü (frieze pattern) adı verilmektedir. Daha sonra Tolliver vd., kişilerin gürültülü siluetlerden de şekilsel yapısına göre tanınabileceğini göstermiştir [71]. Diğer bir çalışmada, orijinal ve yeniden boyutlandırılmış siluetlerden, yatay, dikey ve köşegenel şavak örüntüler üretilmiştir [93].

Wang ve diğerlerinin çalışmasında [74], açılmış siluetlerin özuzaya dönüşümü geliştirilmiştir. Çalışmalarında, siluet dizilerindeki her bir siluetin sınırları, kompleks vektörlerle temsil edilir ve zamansal olarak ortak koordinat sisteminde toplanır. Sonra yürüyüş imzası için şeklin ortalaması, Procrustes şekil analiziyle çıkarılır. Sınıflandırma için Procrustes uzaklığının tamamının kullanıldığı EYK kriteri kullanılmıştır. Bu yaklaşımda, şekil eğrilerinden yürüyüşün yapısal karakteristiği dolaylı olarak temsil edilmiştir. Wang vd.'nin neredeyse aynı zamanda yaptıkları diğer bir çalışmada, siluet sınırlarından elde edilen uzaklık işaretlerinin özuzaya dönüşümü kullanılmıştır [75]. Diğer bir çalışmada, siluet dizisindeki 2-boyutlu siluetler vektöre çevrilip yürüyüş örüntüsünün sütunlarına yerleştirilmiştir. Sonra doğrusal olmayan uzayda, bağımsız bileşen analiziyle (BBA) öznitelikler çıkarılmıştır [103].

Lu ve Zhang'ın çalışmasında, siluet sınırlarına dayalı, Fourier, wavelet ve pseudo-Zernike momentlerle yürüyüş örüntüsü üretilmiştir [105]. Özellik vektörlerini çıkarmak için BBA kullanılmıştır. Öklid uzaklığına dayalı EYK, DVM ve genetik bulanık DVM ile sınıflandırma yapılmıştır. Yöntemlerin başarısı ayrı ayrı ve birleştirilerek (fusion) test edilmiştir. Diğer bir çalışmada [107], siluet sınırlarının Canny algoritmasıyla belirlenmesi önerilmiştir. Sınır ilintilerinin meydana göre sınıflandırma yapılmıştır. Chen vd.'leri [126], siluetleri polar koordinat sisteminde göstermiş ve belirlenen bir noktaya göre açısıl enerjiyi hesaplamıştır. Yine siluet sınırlarının kullanıldığı bir çalışmada, kompleks vektöre çevrilen sınırlar bütün siluet dizisi boyunca ardı sıra getirilmiş ve ayrık Fourier dönüşümü hesaplanmıştır [124].

Lee vd.'nin çalışmasında, siluetler yeniden düzenlenmiştir. Kopukluklar ve eksikler tamamlanarak Baseline algoritması ile başarımlar değerlendirilmesi yapılmıştır [104]. DVM sınıflandırıcısını kullanan Bissacco [125]'nin çalışmasında, siluet affine momentlerle temsil edilmiştir. Das ve diğerlerinin çalışmasında, koşma ve zıplamaları tanımak amacıyla yürüme bandında yürüyen kişilere alıcılar takılmış ve altı özellik seçilmiştir [128].

Ioannidis ve diğerlerinin çalışmasında [90], önerdikleri 3-boyutlu açısal ve yüzeysel siluet dağılımı dönüşümleri ile yürüyüş şekli temsil edilmiştir. Radon dönüşümüne dayalı, açısal (radial integration transform-RIT) ve dairesel bütünleştirme(circular integration transform-CIT) dönüşümleri ve ağırlıklandırılmış Krawtchouck momentleri yürüyüş özelliği olarak değerlendirilmiştir. Bu 3 farklı özellik çıkarma yönteminin çıktıları, genetik algoritmalarla birleştirilmiştir.

Boulgouris ve Chi'nin çalışmasında [91], yeniden boyutlandırılmış siluetler, Radon dönüşümüne tabi tutulmuştur (Şekil 1.7.(d)). Radon siluet dizilerinden, yürüyüş dinamiğini ve yapısal bilgilerin zamanla değişimini hesaplayan fonksiyon ile yürüyüş örüntüleri üretilmiştir. Ayırıştırıcı özellikleri çıkarmak için DAA kullanılmıştır. Onların Öklid uzaklığına dayalı sınıflandırıcısında, Radon dönüşümünde kullanılan açı sayısının başarı performansına etkisi incelenmiştir.

Boulgouris'in diğer bir çalışmasında [92], siluet sınırlarının açısal dönüşümü yapılmıştır (Şekil 1.7.(e)). Test aşamasında test örüntüleri, karşılaştırma yapılan eğitim örneklerinin yürüyüş periyoduna göre, dinamik zaman uyarlaması (dynamic time warping (DTW)) ile ayarlanmıştır. Sınıflandırma işleminde, test sınıfındaki her bir periyotluk örnek ile eğitim sınıfındaki örneklerin uzaklıklarının ortalaması/medyanı, aynı şekilde eğitim sınıfındaki her bir periyotluk örnek ile test sınıfındaki örneğin ortalaması/medyanı hesaplanmış ve her iki ortalama/medyan değerinin ortalaması alınarak minimum uzaklık prensibi kullanılmıştır.

Ekinci ve diğerlerinin çalışmalarında [78, 109-117], her bir siluet için siluet kutusu ile siluet sınırları arasındaki uzaklık, siluete sağ, sol, alt ve üst yönlerden hesaplanmıştır (Şekil 1.7.(f)). Sonra her bir uzaklık vektörünün yürüyüş şablonunun sütunlarına yerleştirilmesiyle yürüyüş örüntüleri üretilmiştir. Yürüyüş örüntüleri, TBA ile öznitelik uzayına taşınarak ağırlıklandırılmış Öklid uzaklığının (AÖÜ) kullanıldığı EYK kriteri ve DVM ile sınıflandırılmıştır [78].

Hayfron Acquah vd. [59]'nin çalışmasında, insan hareketleri, siluetlerin simetrik yapısına dayalı olarak modellenmiştir (Şekil 1.8.(a)). Sobel operatörü ile her bir yürüyüş siluetinde sınırların kenar haritası çıkarılıp, genelleştirilmiş simetri operatörü uygulanmıştır. Yürüyüş örüntüsü olarak simetri haritalarının ortalaması alınmıştır. Hayfron Acquah vd. diğer bir çalışmalarında ise yürüyüş şekli, optik akış ile temsil edilmiştir [58]. Onların daha ileri analizi sonucunda, simetrik yapının diğerlerine göre gürültüye daha

duyarsızken, eksik imge çerçevesi ve/veya eksik uzaysal verinin elde edilmesinde daha iyi olduğu tespit edilmiştir.

Yürüyüş örüntüsü üretimine en basit yaklaşım, siluet dizilerinin ortalamasının alınmasıdır [56, 66, 73, 80]. Huang ve Boulgouris'un çalışmasında, CMU MoBo veritabanında farklı yönler için ağırlıklar belirlenmiş ve ağırlıklara göre farklı yönlerdeki ortalama yürüyüş örüntüleri birleştirilmiştir [80].

Bhanu ve Han'ın çalışmasında, 2-boyutlu silüetlere oturtulan 3-boyutlu kinematik modellerle, 3-boyutlu yürüyüş parametreleri tahmin edilerek, durağan ve hareketli özellikler kullanılmıştır [51]. Dinamiklik ve yapısalılık ayrı ayrı belirlenip daha sonra tanıma için birleştirilmiştir. Han ve Bhanu'nun diğer çalışmasında [57], silüetlerin ortalamasıyla elde edilen Yürüyüş Enerji İmgesi (YEİ) kullanılmıştır (Şekil 1.8.(b)). YEİ'deki her bir pikselin parlaklığı, yürüyüş anında önplan bilgilerinin ilgili pozisyonda kalma süresini gösterir. YEİ'de, hareket anındaki dinamik ve fiziksel özellikler, tek bir imgede temsil edilir. Sonra özellik çıkarmak için TBA ve çoklu ayrıştırma analizi yapılmıştır. Bu yaklaşımla, USF yürüyüş veritabanında yapılan testlerde, Baseline yönteminden daha başarılı sonuçlar elde edilmiştir. YEİ gürültüye karşı durması, uygulanma basitliliği ve başarı performansı açısından daha sonra pek çok araştırmacı tarafından da kullanılmıştır [55-57, 63, 64, 66, 69, 73, 76, 81-89]. Kişi tanımadan farklı olarak [63, 76]'deki çalışmalarda YEİ, cinsiyet tanıma için birkaç bölgeye ayrılmıştır ve insan bedeninin farklı parçalarının birleşimi analiz edilmiştir.

Chai'nin çalışmasında ise silüetteki her bir pikselin bir periyot boyunca ayrı ayrı varyansı hesaplanmıştır [98]. Benzerlik hesabı, EYK ve k -EYK kriterlerine göre yapılmıştır.

Yu vd. tarafından, CASIA-B yürüyüş veritabanının test formatları dizayn edilmiştir [81]. Onların çalışmasıyla, normal yürüme dizilerinin ilk dördü eğitim, sonraki ikisi test set-A, montlu yürümeler test set-B ve çantalı yürüme dizileri test set-C olarak literatüre kazandırılmıştır. Oluşturdukları YEİ örüntüleri, Öklid uzaklık ölçütü ile sınıflandırılmıştır.

Zhao ve diğerlerinin çalışmasında, beden duruşunun ortalama genliğinde türetilen anahtar çerçeve kullanılmıştır [77]. Lee vd.'nin çalışmasında, bölge korumalı izdüşüm (locality preserving projection (LPP)) tekniği ile yürüyüş dizileri yeniden boyutlandırılmış ve yürüyüş, içerik ve şekil olarak iki kısımda incelenmiştir [62]. Body'nin çalışmasında, model tabanlı ve modelden bağımsız yaklaşımlar beraber değerlendirilmiştir [52]. Yönlü istatistik ve Procrustes Analizinin uygulandığı örüntülerde, piksel parlaklığının

osilasyonlarının senkronizasyonu ile faz-kilitlemesi yapılmıştır. Yaklaşımın performansı, CMU MoBo ve SOTON veritabanlarında ölçülmüştür.

Görünüşe dayalı bir başka yaklaşımda, iki ardışık çerçeve arasında değişmeyen bölgelerin bir periyottaki ortalaması ile uzaysal-zamansal sabit (static spatio-temporal, SST) diye adlandırdıkları örüntüsü (Şekil 1.8.(c)) ve bir periyottaki, her bir silüet sınırlarının ortalaması ile elde ettikleri hareketli silüet sınırlarının şablonu (motion silhouette contour template, MSCT) örüntüsü (Şekil 1.8.(d)) üzerinden, ayrı ayrı öklid uzaklığına göre benzerlik ölçülmüştür [89]. Sonra bu iki şablon benzerliğinin ortalaması, benzerlik oranı olarak değerlendirilmiştir.


Tao ve arkadaşlarının çalışmasında [97], silüet ortalamasından Gabor filtresi ile yürüyüş özellikleri üretilmiştir. Sonra DAA'ya dayalı genelleştirilmiş gergi ayrıştırma analizi (general tensor discriminant analysis, GTDA) özellik çıkarıcı olarak kullanılmıştır.

Lee vd.'nin çalışmasında, silüet dizisinden bir anahtar çerçeve seçilip diğer çerçevelerle farkları alınmıştır [94]. Ayrıca her bir silüet dizisinde, kendine benzerlik matrisi oluşturulmuştur. Sonra, fark ve kendine benzerlik imgelerinin satır ve sütun toplamları hesaplanmıştır. Yürüyüş karakteristiği, bu dört izdüşüm vektöründen tek bir maliyet fonksiyonu ile üretilmiştir.

Xu vd.'nin çalışmasında, silüet ortalamaları üzerinde, her bir çiftin alt uzay analizi ve gergi ayrıştırma analizi önerilmiştir [95]. Baseline yaklaşımındaki gibi benzerlik hesabı yapılmıştır.

Xu vd.'nin çalışmasında, silüet dizisinin ortalamaları, marjinal Fisher analizi (Marginal Fisher Analysis, MFA) ile daha düşük boyutlu uzaya ayırt edici özelliklerin belirlenmesi için taşınmıştır [102]. Test aşamasında, eğitim kümesindeki en küçük uzaklıklarından oluşan test sınıfındaki uzaklıkların medyanı alınmıştır.

Cheng ve arkadaşlarının SOTON ve CASIA-A veritabanı üzerinde yaptığı testlerde, izometrik haritalama yöntemiyle yürüme örüntüsü üretilmiştir [106]. Yürüyüş yönünün belirlenmesi ve eğitim için HMM uygulanmıştır.



Şekil 1.8. Bazı model bağımsız yaklaşımların yürüyüş örüntüleri, (a) simetri, (b) YEİ, (c) SST, (d) MSCT, (e) GHI, (f) MHI, (g) MEI, (h) FDEI, (i) AEI

Chen vd.'nin çalışmasında, farklı yürüyüş özelliklerini kaynaştırmak için özellik-seviyeli birleştirme, çarpınım (factorial) HMM kullanılarak tertiplenmiştir [53]. Paralel HMM ise karar seviyeli birleştirmeyi yapmak için kullanılmıştır.

Liu ve Zheng'in çalışmasında [64], yürüyüş örüntüsü için yürüyüş tarihi imgesi (GHI, Şekil 1.8.(e))¹² önerilmiştir. Onlar, GHI'nin performansını, hareket tarih imgesi (MHI, Şekil 1.8.(f))¹³, hareket enerji imgesi (MEI, Şekil 1.8.(g))¹⁴ ve YEİ ile karşılaştırmıştır.

Bashir vd.'nin çalışmasında [88], YEİ'deki statik alanlar ve ayak kısımları ayrı ayrı yürüyüş özelliği olarak ele alınmıştır. Özelliklerin boyutlarını küçültmek için TBA ve özellik seçimi için çoklu ayrıştırma analizi (MDA) kullanılmıştır. CASIA-B veritabanında profil görüntüleri üzerinde yapılan deneylerde EYK kriteriyle sınıflandırma yapılmıştır.

Yang ve diğerlerinin çalışmasında [86], YEİ'deki dinamik bölgeler, sınıf içindeki YEİ örüntülerinin standart sapmalarından belirlenen katsayılarla bulunmuştur. Bu bölgelerin özellikleri, Gabor dönüşümüyle belirlenmiştir. Sonra, sınıftaki özellikleri tek bir vektör ile tanımlamak için ayırıcı ortak vektör (DCV) yöntemi kullanılmış ve TBA yapılmıştır. Son olarak Öklid uzaklıklarına dayalı EYK kriterine göre sınıflandırma yapılmıştır.

Lee ve arkadaşlarının çalışmasında [87], yürüyüş örüntüsü için hareketli siluet imgesi (motion silhouette image, MSI) yaklaşımı önerilmiştir. MSI örüntüsü, yüz, üst beden ve alt beden şeklinde 3 bölgeye ayrıldıktan sonra, her bir bölge için TBA ile öznitelik seçilmiştir (CASIA-A veritabanı için 20'şer özvektör). Bu öznitelikler yapay sinir ağının (YSA) eğitiminde kullanmıştır.

Singh vd.'nin çalışmasında [81], yüksekliği 100 piksele ölçeklenmiş siluetlerin YEİ örüntülerinden altın orana göre seçilen bölgeler ayırt edici özellik olarak kullanılmıştır. Sınıflandırmada özellikler arasındaki uzaklıklar mutlak farkla hesaplanmıştır.

Amin [122] ve arkadaşları tarafından yapılan çalışmada, siluetlerin alt yarısının toplamına 1-boyutlu ayrık dalgacık dönüşümü uygulanmış ve city-block uzaklığıyla EYK kriteri, sınıflandırma için kullanılmıştır.

Zhang ve arkadaşlarının çalışmasında, değişken yürüyüş enerji imgesi (DYEİ, dynamic gait energy image, DGEI) yürüyüş örüntüsü üretme yaklaşımı olarak önerilmiştir [127]. DYEİ'de, siluet dizilerinin ortalaması, her bir siluetten çıkarılıp mutlak farkı

¹² GHI : Gait History Image

¹³ MHI : Motion History Image

¹⁴ MEI : Motion Energy Image

hesaplanmıştır. N tane çerçeve ve Np yürüyüş periyodu olmak üzere, farkların toplamı $N+Np$ 'ye bölünmüştür. Son olarak, LPP yöntemi, TBA uzayında uygulanmıştır.

Jianyi Liu [85]'nin çalışmasında, siluet dizisinden siluet kalitesini ölçme (SQQ) yöntemi önerilmiştir. SQQ ile seçtiği kaliteli siluetlerden siluet kalite katsayıları (SQW) belirlenerek YEİ örüntüleriyle kullanılmıştır. Sınıflandırmada, Fisher doğrusal ayrıştırma analiziyle (FDA) belirlenen özellikler, EYK ve kaydırılan çerçevelerde korelasyon hesabına dayalı şablon eşleştirme yöntemleriyle sınıflandırılmıştır.

Chen ve arkadaşlarının çalışmasında [83], yürüyüş örüntüsü olarak siluet dizisinde kinematik ve statik bilgileri muhafaza eden, çerçeve farkı enerji imgesi (FDEI) önerilmiştir (Şekil 1.8.(h)). FDEI örüntülerini oluşturmak için, ardışık çerçevelerin farklarının pozitif parçaları, değerleri belirli bir eşikten geçirilerek gürültülerden arındırılmış YEİ imgeleri ile toplanmıştır. Tanıma için HMM kullanılmıştır.

Lu'nun çalışmasında, YEİ örüntüsü, siluetlerin siluet merkezine göre toplanmasıyla oluşturulmuştur [84]. Çalışmasında, görünüşten bağımsız yürüyüş sinyallerinin hesabı için yürüyüş dizisi sınıfları arasındaki uzaklıkları maksimize (yükselten) ve sınıf içindeki geometrik yapıları muhafaza eden ilişkisiz ayırt edici özelliklerin tek yönlü analizini (uncorrelated discriminant simplex analysis, UDSA) yapan denetim kısıtlamalı bir öğrenme algoritması önerilmiştir. Sınıf içi bilgiyi karakterize etmek için farklı yönlerdeki YEİ'lerin farkları toplanmıştır. k -EYK kriteri ile aynı yönlerdeki farklı sınıfların sınıflar arası bilgisi ve farklı yönlerdeki aynı sınıfların sınıf içi bilgisi üretilmiştir. Sonra aynı yöndeki farklı sınıfları ayırtıran ve farklı yöndeki aynı sınıfları yakınlaştıran düşük boyutlu özellik uzayı oluşturulmuştur. Eğitimde bire-karşı-diğerleri yöntemi ile farklı yönlerden öğrenme yapıp öznitelik belirleyici fonksiyon oluşturulmuş ve bu izdüşüm fonksiyonuyla, öğrenmede kullanılmayan nesnenin özellik vektörü çıkarılmıştır. Bu işlem toplam nesne sayısı kadar tekrar edilerek bütün nesneler için özellik vektörleri oluşturulmuştur. Sonra Öklid uzaklık ölçütü kullanılarak EYK ile sınıflandırma yapılmıştır. Yaklaşım, farklı yönlerde siluet dizileri olan CASIA-B veritabanının normal yürüyüşlerinde test edilmiştir.

Xue vd.'nin çalışmasında, kızılötesi görüntü dizilerinden üretilen YEİ yürüyüş örüntülerinin dalgacık dönüşümüyle değişmez momentleri, iskelet modeli ile yapısal parametreleri ayrıştırıcı özellik olarak kullanılmıştır [121]. Yürüyüş tanıma için DVM kullanılarak 23 kişilik veritabanında %78-%91 arasında doğru sınıflandırma başarısı elde

edilmiştir. Çalışmada çanta, parlaklık gibi problemleri çözdüğünden kızılötesi kameraların yürüyüşünden kişi tanıma için önemi vurgulanmıştır.

Bashir vd.'nin çalışmasında, yürüyüş enerjisi entropi imgesi (gait energy entropy image, GEnI) yürüyüş örüntüsü üretme yaklaşımı ve özellik çıkarmak için uyarlamalı bileşen ve ayrıştırma analizi (Adaptive Component and Discriminant Analysis, ACDA) önerilmiştir [120]. GEnI, YEİ'den Shanon entropi ölçümüne göre çıkarılmıştır. Sonra GEnI'ler üzerinden maske imgesi oluşturulup, YEİ imgelerine uygulanmıştır. ACDA yaklaşımıyla TBA+MDA'ya göre daha az işlem yükü oluşturulmuştur. Yaklaşımlar CASIA-B ve SOTON veritabanlarında değerlendirilmiştir.

Zhang vd.'nin çalışmasında [119], komşu silüetlerin farklarının toplamına dayanan aktif enerji imgesi (active energy image, AEİ) yürüyüş örüntüsü olarak önerilmiştir (Şekil 1.8.(ı)). AEİ'ler, 2-boyutlu bölge korumalı izdüşüm (2DLPP) yöntemi ile düşük-boyutlu özellik uzayına taşınmıştır. Çalışmada, CASIA-B ve CASIA-C veritabanları kullanılmıştır.

Modelden bağımsız yöntemler, işlem yükü ve uygulanabilirlik açısından gözetleme sistemlerine, model-tabanlı yöntemlere göre daha kolay monte edilebilir. Son zamanlarda yapılan modelden bağımsız yaklaşımlarda, YEİ örüntü üretme yöntemi gürültüye karşı gücü ve hesaplama avantajlarıyla beraber başarı performansı açısından araştırmacıların ilgi odağı olmuştur. YEİ örüntü üretme yaklaşımının geliştirilmesi veya benzer özellikleri taşıyan örüntü üretme teknikleri, günümüzdeki yürüyüşünden kişi tanıma çalışmalarının oldukça büyük bir kısmını teşkil etmektedir [55-57, 63, 64, 66, 69, 73, 76, 81-89, 94, 119, 120]. Sonuç olarak gözetleme sistemleriyle uzaktan kimlik tespiti yapabilmek amacıyla yürüyüş şeklinin kullanılmasında yürüyüşün silüete dayalı olarak temsil edilmesi, uygulanabilirlik ve maliyet açısından diğer yöntemlere göre daha avantajlı görülmektedir.

1.3. Örüntülerde Öznitelik Çıkarma ve Boyut İndirgeme

Yürüyüş şekli biyometrik özelliğinin araştırıldığı ilk veritabanlarında, kişi sayısı çok azdı (4, 6 kişi) ve ölçülen parametre sayısı kağıt kalemle hesaplanacak düzeyde idi [6-8]. Sonraki çalışmalarda, doğal ortamı temsil edebilecek, birkaç parametreyle ayrıştırılamayacak kadar kalabalık veritabanları oluşturulmuştur. Ayrıca, doğru ayrıştırma yapılabilmesi için fazla alınan ölçümler, yürüyüş örüntülerinin oluşturulmasına yol açmıştır.

Örüntü tanıma çalışmalarında, örüntülerin ortak özellikleri tanımda hiçbir faydası olmayan tekrarlı bilgilerdir. Ayrıca biyometrik özellik ölçümü yapılırken çeşitli ölçüm hataları meydana gelmektedir. Bunlar yürüyüş örüntüsünde küçük değişimlere neden olan gürültülerdir. Tekrarlılıkların atılıp gürültülerin kaldırılması ile daha performanslı sistemler geliştirilebilir. Diğer taraftan bazı özelliklerin tanımda ayrıştırıcı özelliği daha baskın olabilir. Bu özelliklerin de kuvvetlendirilmesi gerekir.

Mevcut çalışmalarda, örüntülerin kendi içindeki gürültülerden arındırılması ve baskın değerlerinin ön plana çıkarılması amacıyla, Fourier, dalgacık, Gabor, Radon dönüşümü gibi yöntemler kullanılmaktadır [90, 91, 97, 121]. Örüntüler arasındaki ilişkilere göre fazlalıkların atılması için YSA [87] ve HMM sıkça başvurulmuş yöntemler olmuştur [53, 61, 32, 70, 83, 96, 100, 106]. Diğer yaklaşımlarda ileri istatistiğe dayalı sistem çözümleri gerektiren ayrıştırma analizleri kullanılmaktadır. İstatistiksel ayrıştırma analizleri verinin temsil edilecek yönlerini belirleyerek minimum boyutlarda saklanmasını sağlar.

Fourier, görüntü işlemede sıkça kullanılan, görüntünün doğası ve biçimi hakkında bilgi veren ortogonal bir dönüşümdür. DFT Fourier dönüşümünün dijital veriler için geliştirilmiş özel bir halidir. Benzer şekilde Fourier dönüşümünden üretilen ve görüntü sıkıştırmada sıkça kullanılan DCT dönüşümünde, kompleks uzay kullanılmaz. Dalgacık tabanlı dönüşümlerde, görüntünün frekans ve faz tayfı bilgilerinin aynı anda temsil edilmesi amaçlanır. Radon dönüşümü, görüntünün farklı açılardan toplamsal (integral) izdüşümüdür ve görüntüdeki kırıklık, tuz-biber gibi gürültülerden daha az etkilenir. Geliştirilmiş hali R-dönüşümünde ölçekleme, döndürme gibi işlemler çok kolay gerçekleştirilebilir [91]. Fourier, Radon, dalgacık tabanlı dönüşümler, örüntüler arasında ilişki kurarak tekrarlı bilgileri atmazlar. YSA, Markov Modelleri gibi yöntemlerde bütün örüntüler değerlendirilerek katsayılar, eşik değerleri ve durum parametreleri belirlenir. Buna eğitim aşaması veya öğrenme denir. YSA ve Markov modellerinde öğrenmenin gerçekleştirildiği örüntüler arasındaki ortak özellikler, dolaylı olarak kaldırılmış olur. YSA'nın dezavantajı, başlangıç noktasının iyi belirlenemediği takdirde lokal minimumlara takılması, katman ve düğüm sayılarının başlangıçta belirlenmesi olarak verilebilir. Markov Modellerinde ise durum uzayının önceden belirlenmesi zorluğu vardır.

Yürüyüş şekli, çalışılması yeni sayılabilecek bir biyometrik özelliktir ve davranışı temsil edecek yürüyüş örüntüsü üretildikten sonra, problem, bilinen örüntü tanıma yaklaşımlarıyla çözülebilecek duruma gelir. Bu bağlamda, yürüyüşten kişi tanıma

çalışmalarında, yüz tanıma ve avuç izi çalışmalarındaki özellik çıkarma yaklaşımlarından oldukça faydalanılmaktadır.

İstatistiksel ayrıştırma analizi yaklaşımları, özellikle yüz örüntüsü tanıma problemlerinde diğer yöntemlere göre avantajlı yöntemler olmuştur. Bu yöntemlerin örüntüdeki ve örüntüler arasındaki gürültüleri ve tekrarlılıkları ortadan kaldırma yeteneği vardır. Bu yaklaşımlarda genellikle, boyut indirgeme yapılır ve veriyi temsil eden en iyi yöneyler belirlenir. Bu yaklaşımları doğrusallık ve danışmanlılık durumuna göre ikiye ayırmak mümkündür. Doğrusallık verinin temsil edildiği uzayla, danışmanlılık verideki sınıf bilgilerinin değerlendirilmesiyle alakalıdır. TBA danışmansız doğrusal, DAA danışmanlı doğrusal, ÇTBA danışmansız doğrusal olmayan ve ÇDA danışmanlı doğrusal olmayan analizlerdir.

İstatistiksel ayrıştırma yöntemlerinde temel fikir, öznitelik uzayının belirlenmesi ve bu uzaya eşleme veya taşımadır. Bunun için eğitim örnekleri analiz edilip, eşleme matrisi veya diğer adıyla eşleme fonksiyonu üretilir. Sonra bu fonksiyon aracılığıyla bütün örüntüler öznitelik uzayında temsil edilir. Öznitelik uzayında temsil edilen örüntünün boyutu küçük olduğundan örneklerin daha az kapasitede saklanması mümkün olur. Tanıma esnasında, öznitelik uzayında temsil edilen tanınacak örüntü, saklanan örüntü temsilleri ile karşılaştırılır.

T , eğitim kümesinin analiziyle belirlenen öznitelik uzayına eşleme fonksiyonu veya matrisi olsun. Bu durumda, bir örneğin öznitelik uzayına eşlenmesi (1.2) denklemi ile verilebilir. Bu işlem, verinin, öznitelik uzayını belirleyen ortogonal yöneylere izdüşürülmesine karşılık düşer.

$$\hat{x} = T^T x \quad (1.2)$$

Burada x ve $\hat{x}$ sırasıyla vektör halindeki örneği ve vektör halindeki özniteliğini ifade eder. Öznitelik, örüntünün alt uzaydaki temsidir.

1.3.1. Doğrusal Uzayda İstatistiksel Ayrıştırma Analizi Yaklaşımları

Verilerin bulunduğu uzayda analiz edilip, yöneylerinden eşleme matrisi üretiliyorsa yöntem doğrusaldır. Doğrusal ayrıştırma tekniklerinde, örüntülerin sınırları doğrularla belirlenmektedir.

1.3.1.1. Temel Bileşen Analizi

Temel bileşen analizi (TBA), aralarında ilişki bulunan çok değişkenli verileri, aralarındaki ilişkiyi kaldırarak başka bir uzaya (öz uzay, alt uzay) taşıma işlemi olarak tanımlanabilir [129]. Pek çok disiplinde yer edinen TBA, sayısal görüntülerde, görüntünün radyometrik (renk veya spektral) özellikleri üzerinde yapılan istatistiksel bir dönüşümdür. Dönüşüm sonucunda alt uzay, verinin birbirine dik olan temel bileşenleriyle (yöneyler) oluşturulur. Danışmansız ve parametresiz bir ayırıştırma analizi olan TBA ile oluşturulan alt uzayda, örüntüler arasındaki varyans maksimum olur [130].

TBA bilgisayarla görme alanında ilk kez Sirovich ve Kirby tarafından insan yüzlerinin temsili için kullanılmıştır [131]. Onların çalışmasında, yüz resimlerinin yaklaşık olarak yeniden oluşturulabileceği gösterilmiştir. Sonra, özresimler üzerinden yüz görüntülerinin izdüşümlerinin insan yüzlerini ayırt etmede kullanılması amacıyla, Turk ve Pentland özyüzler yöntemini ortaya atmıştır [153]. Onların yaklaşımında özyüzler, yüz-kovaryans matrisinin baskın özdeğerleri ile ilişkili özvektörlerle temsil edilmiştir [154].

Bir boyut indirgeme yaklaşımı olan TBA, örüntü tanıma alanında genel olarak örüntü özniteliklerinin çıkarılması amacıyla kullanılmıştır. Tekrarlılıkların atılması ve gürültülerin kaldırılması için yürüyüşten kişi tanıma çalışmalarında da uygulanan bir öznitelik çıkarma yöntemidir [56, 57, 78, 86, 93].

TBA, veriyi, dağılımının maksimum varyanslarını bularak temsil etmeye çalışır. Bunun için örüntü tanıma uygulamalarında, örüntülerin varyans-kovaryans veya korelasyon matrislerinin QR, SVD gibi yöntemlerle özdeğer ve özvektörleri hesaplanır [133]. Örüntüler özvektörlere izdüşürülerek daha küçük boyutta temsil edilir. Matrisler simetrik olduğundan hesaplanan özdeğerler pozitifdir ve verinin temsilde yeterince söz sahibi olmayan çok küçük değerli özdeğerler gürültü ve tekrarlılık olarak kabul edilir. Gürültü ve tekrarlılık içeren özvektörler atılarak, kalan özvektörlerden izdüşüm (dönüşüm veya eşleme) matrisi oluşturulur [130, 134]. TBA'da, m adet n boyutlu örneklerin kovaryans matrisinden elde edilebilecek sıfırdan büyük özdeğer sayısı, en fazla $\min(m,n)$ olabilir. Örüntü tanıma problemlerinde boyut sayısı, örnek sayısından çok büyük olduğundan bir örneğin temsil edilmesi için gereken verinin boyutu oldukça küçülmüş olur. TBA'yı matematiksel olarak ifade edecek olursak: $d \times d$ boyutlarında M matrisinin özdeğer ve özvektörlerini içeren denklem (1.3)'te verilmiştir.

$$Mx = \lambda x \quad (1.3)$$

(1.3) eşitliğinde λ sayısı için eşitlik (1.4) 'te verildiği şekilde yazılabilir.

$$(M - \lambda I)x = 0 \quad (1.4)$$

(1.3) ve (1.4) eşitliklerinde I birim matris, “0” da sıfır vektörüdür. Çözüm vektörü $x=e_i$ ve karşı düşen $\lambda=\lambda_i$ sayısı, özvektör ve ilişkili özdeğeri olarak adlandırılır. Eğer M reel ve simetrik ise, d adet çözüm vektörü $\{e_1, e_2, \dots, e_d\}$ ve bunlarla ilişkili $\{\lambda_1, \lambda_2, \dots, \lambda_d\}$ özdeğerleri vardır. Bunlar QR veya SVD yöntemleri ile kolayca bulunabilir [134, 133].

Örüntü tanıma problemlerinde M matrisi genellikle kovaryans matrisi olarak alınır. X matrisi, vektöre çevrilmiş n boyutlu, M tane örneği olan eğitim kümesi olsun.

$$\mu = E(X) = \frac{1}{M} \sum_{k=1}^M x_k \quad (1.5)$$

(1.5) şeklinde bütün örneklerin ortalama vektörü bulunur. Sonra S_t dağılım (kovaryans) matrisi (1.6)'daki gibi hesaplanır.

$$S_t = \sum_{k=1}^n (x_k - \mu)(x_k - \mu)^T \quad (1.6)$$

S_t 'nin özdeğerleri ve özvektörleri sırasıyla λ_i ve e_i olsun. Özdeğerleri, onlara karşılık gelen özvektörlerle sıraladıktan sonra, özdeğerlerin toplamının belirli bir yüzdesini sağlayan özdeğer sayısı kadar özvektör, eşleme matrisini oluşturmak için kullanılır. Sonra her bir örnek eşleme matrisiyle alt uzaya izdüşürülerek $m \{ < \min(n, M) \}$ boyutlu vektörle temsil edilir.

1.3.1.2. Doğrusal Ayırıştırma Analizi

Gerçek hayatta yapılan gözlemlerde, aynı sınıfa ait örnekler arasında tıpatıp bir benzerlik yoktur. Örnek olarak kişi bıyıklı, sakallı, uzun saçlı gibi değişik durumlarda

fotoğraf çektirebilir veya avuç eğimi ve uzaklığı değişebilir. Bu durumlarda, sınıf içerisindeki örnekler arasında farklılıklar oluşur. Diğer taraftan her sınıfta aynı sayıda örnek olmaz. Az sayıda örnek bulunan sınıfın yöneylerin belirlenmesindeki etkisi, çok sayıda olan sınıfa göre daha az olur. Bu problemlerin üstesinden gelmek için doğrusal ayırıştırma analizi (DAA, Fisher ayırıştırma analizi (FDA) diye de geçer) önerilmiştir [135,136]. DAA’da, sınıf içi varyansları minimum, sınıflar arası varyansları maksimum yapmayı hedefler.

DAA matematiksel yönden irdelenecek olursa: N toplam örnek sayısı ve C sınıf sayısı olmak üzere, sınıflar arası (S_b) ve sınıf içi (S_w) varyansı hesaplayalım.

$$S_b = \sum_{i=1}^C N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (1.7)$$

$$S_w = \sum_{i=1}^C N_i \sum_{x_k \in X_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (1.8)$$

Buradaki N_i , sınıftaki örnek sayısı, μ_i , sınıf içi ortalama vektörü, μ , genel ortalamadır. Sınıf içindeki varyansı minimum ve sınıflar arasındaki varyansı maksimum yapmak için amaç fonksiyonu (1.9)’daki gibi olur [136].

$$J(W) = \frac{W^T S_b W}{W^T S_w W} \quad (1.9)$$

Burada, $S_w^{-1} S_b$ matrisinin temel bileşenleri, DAA için eşleme matrisini oluşturmada kullanılır. Açıkça görülmektedir ki; $S_w^{-1} S_b$ ’nin en fazla $C-1$ tane özdeğeri olabilir.

Örüntü tanıma problemlerinde genellikle boyut sayısı örnek sayısından büyüktür. Böyle olunca S_w matrisinin tersinin olmadığı durumlar oluşur (az örnek sayısı problemi, SSS¹⁵). Bu durumda genellikle matrise gürültü eklenir (σI) veya sahte (pseude) tersi alınır [136]. SSS problemi son zamanlarda, TBA uzayında DAA, boş-uzayın kaldırılması ile DAA (NLDA¹⁶), direk DAA (D-LDA¹⁷) gibi yöntemlerle de çözülmektedir [136-138].

¹⁵ SSS : Small Size Sample

¹⁶ NLDA : Null space linear discriminant analysis


¹⁷ D-LDA : Direct linear discriminant analysis

Örüntü tanıma çalışmalarında genelde sınıf bilgileri mevcut olduğundan DAA, TBA'ya göre daha çok tercih edilmektedir [85, 88, 91, 96, 97, 102].

1.3.2. Doğrusal Olmayan Uzayda İstatistiksel Analiz Yaklaşımları

Gerçek hayatta gözlemlenen olaylar benzer yapıya sahip olabilir ve uzayda bir doğru ile net olarak ayrıştırılamayabilirler. Çoğu zaman gözlemleri ayrıştıran bir eğri olur. Çoklu sınıf problemlerinde, her olayı ayıran bir eğri yerine doğrusal olmayan uzayda olayları temsil etme düşüncesi daha mantıklıdır. Yani doğrusal olmayan uzayda doğrusal ayrıştırma analizleri kullanılarak, doğrusal ayrıştırılamayan veriler ayrıştırılabilir.

Şekil 1.9'da 2-boyutlu doğrusal giriş uzayı ve verilerin eşlendiği 2-boyutlu doğrusal olmayan öznitelik uzayı gösterilmektedir. Bu uzayda, veriler doğrusal olarak ayrılabilir hale gelmiştir.



Şekil 1.9. Giriş uzayı ve doğrusal olmayan öznitelik uzayı

Doğrusal olmayan uzay (F), X giriş uzayından Φ fonksiyonu ile üretilebilir. Yani $F = \{\phi(x) \mid x \in X\}$ şeklinde verilebilir. Bu eşleme (1.10)'da daha açık olarak gösterilmiştir.

$$x = (x_1, x_2, x_3, \dots, x_n) \mapsto \phi(x) = (\phi_1(x), \phi_2(x), \dots, \phi_N(x)) \quad (1.10)$$

Doğrusal olmayan F uzayının boyutu, çok büyük hatta sınırsız olabilir. Bu durumda, F uzayında doğrusal öğrenme makinelerini kullanmak mümkün olmayabilir. Makineler ikili gösterimde ifade edilebilirse bu problem çözülebilir. Yani, hipotezler karar kuralının

sadece test ve eğitim noktaları arasındaki iç çarpımını kullanarak hesaplanabilir ve eğitim noktalarının doğrusal kombinasyonu olarak ifade edilebilirler (1.11).

$$f(x) = \sum \alpha_i y_i \langle \phi(x_i), \phi(x) \rangle + b \quad (1.11)$$

Eğer $\langle \phi(x_i), \phi(x) \rangle$ iç çarpımı, öznitelik uzayında orijinal giriş noktalarının bir fonksiyonu olarak doğrudan hesaplanabiliyorsa doğrusal olmayan öğrenme makinesinin inşası için gerekli iki adımı birleştirmek mümkün olur. Bu şekilde doğrudan hesaplama yöntemine çekirdek hilesi denir [139-141].

1.3.2.1. Çekirdek Hilesi

Çekirdek hilesi iç-çarpım yapılabilen (vektörler aynı boyda olmalı) herhangi bir algoritmaya uygulanabilir. Çekirdek fonksiyonuna yerleştirilmiş iç-çarpım sayesinde, doğrusal algoritmalar, özellik uzayında doğrusal olmayan algoritmalara dönüşür.

Seçilen çekirdek fonksiyonunun öznitelik uzayına eşleme yapabilmesi için bazı şartları sağlaması gerekir. $K(x, z)$ çekirdek fonksiyonu olsun. Çekirdek fonksiyonu öncelikle simetrik (1.12) olmalı ve Cauchy-Schwarz eşitsizliğini (1.13) sağlamalıdır.

$$K(x, z) = \langle \phi(x), \phi(z) \rangle = \langle \phi(z), \phi(x) \rangle = K(z, x) \quad (1.12)$$

$$\begin{aligned} K(x, z)^2 &= \langle \phi(x), \phi(z) \rangle^2 \leq \|\phi(x)\|^2 \|\phi(z)\|^2 \\ &= \langle \phi(x), \phi(x) \rangle \langle \phi(z), \phi(z) \rangle \\ &= K(x, x) K(z, z) \end{aligned} \quad (1.13)$$

Bu iki koşul öznitelik uzayının var olduğunu kesin olarak kanıtlamaz. Öznitelik uzayının varlığını Mercer teoremi ile kanıtlamak gerekir. Mercer Teoremine göre; X, ∇^n 'nin altkümesi ve K , (1.14) ifadesi pozitif olacak şekilde seçilen sürekli simetrik fonksiyon olmalı veya (1.15) eşitsizliği sağlanmalıdır.

$$(T_K f)(\nabla) = \int_X K(\nabla, x) f(x) dx, \quad T_K : L_2(X) \quad (1.14)$$

$$\int_{X \times X} K(x, z) f(x) f(z) dx dy \geq 0, \text{ bütün } f \in L_2(X) \text{ için} \quad (1.15)$$

Bu durumda $K(x, z)$ yeniden yazılırsa (1.16) elde edilir.

$$K(x, z) = \sum_{i=1}^{\infty} \lambda_i \phi_i(x) \phi_i(z) \quad (1.16)$$

Burada, $\lambda_i \geq 0$ ve $\phi_i \in L_2(X)$ sırasıyla T_K 'nin pozitif özdeğer ve özfonksiyonlarıdır. $K(x, z)$, $X \times X$ üzerinde düzgün yakınsayan serilerdir ve $\|\phi_i\|_{L_2} = 1$ olacak şekilde normalize edilmişlerdir.

Çekirdek yöntemler örüntü tanıma, sonlu oto-mata gibi alanlarda gittikçe popülerleşmekte ve pek çok araştırmacı tarafından karakteristikleri incelenmektedir [132, 139, 140, 142].

Doğrusal olmayan uzaya eşleme yaparken kullanılacak çekirdek fonksiyonu probleme uygun seçilmelidir. Örneğin polinom çekirdek, özellikleri polinom şeklinde dizerken, açısıl çekirdeklerin öznitelikleri ayrıştırmayı dairesel veriler üzerinde daha iyi yapar. Doğrusal çekirdek kullanıldığı takdirde en iyi ayrıştırma çizgilerle sağlanabilmektedir. Aşağıda literatürde geçen bazı çekirdek fonksiyonları verilmektedir¹⁸ [143]:

- i. Doğrusal çekirdek : en basit çekirdek fonksiyonudur ve teoride doğrusal yöntemden farklılık oluşturmaz (1.17).

$$K(x, y) = x^T y + c \quad (1.17)$$

- ii. Polinom çekirdek : normalleştirilmiş eğitim verilerine oldukça uygun, yaygın olarak kullanılan, durağan olmayan çekirdek fonksiyonudur. Ayarlanabilir parametreleri alfa eğim, c sabit terim ve d derece olarak verilmiştir (1.18).

$$K(x, y) = (\alpha x^T y + c)^d \quad (1.18)$$

¹⁸ Diğer çekirdek fonksiyonları için Eklere bakınız.

- iii. Gauss çekirdek (RBF) : açısız temelli çekirdek fonksiyonudur. (1.19) veya (1.20) şeklinde uygulanabilir. Gauss çekirdek fonksiyonunda sigma (σ) parametresi çekirdeğin ayırıştırma performansında önemli bir rol oynar. Eğer σ büyük seçilirse, fonksiyon veriyi iyi düzenleyemez ve karar sınırı gürültüye aşırı duyarlı olur. Başka bir deyişle σ ’nın yüksek değerlerinde üstel fonksiyon doğrusala yakın değer üretir ve yüksek boyutlarda doğrusal olmayan eşleştirme yetisini kaybeder. σ ’nın çok küçük değerlerinde veri küçük alanda temsil edilmeye çalışılır.

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (1.19)$$

$$K(x, y) = \exp(-\gamma\|x - y\|^2) \quad (1.20)$$

1.3.2.2. Çekirdekli Temel Bileşen Analizi

Çekirdekli temel bileşen analizi (ÇTBA), “doğrusal olmayan öznitelik uzayında TBA’nın uygulanması” şeklinde özetlenebilir. Doğrusal olmayan uzayda TBA uygulaması, doğrusal olmayan bir ayırıştırmaya denk düşer. ÇTBA öznitelik çıkartma tekniği, DVM ile yakından alakalı bir tekniktir. Çeşitli uygulamalar için gürültüyü kaldırma ve regresyon problemlerinde ön adım olma gibi yararları mevcuttur.

Schölkopf ve arkadaşları, çekirdek hilesini, TBA ile birleştirebilmiş ve öznitelik temsili için ÇTBA’yı geliştirmiştir [132]. Onların çalışmasında, giriş verisi gizli öznitelik uzayı F ’ye çekirdek hilesi ile izdüşürülür ve ardından giriş verilerinin doğrusal olmayan temel bileşenlerini çıkartmak için doğrusal TBA, F uzayında gerçekleştirilir. Bu yöntemin bir diğer adı da doğrusal olmayan alt uzay analizidir. Sonuç olarak ÇTBA, değişik doğrusal olmayan izdüşürümler için değişik çekirdeklerin kullanıldığı geleneksel TBA’nın genelleştirilmiş şeklidir [140].

ÇTBA’yı matematiksel olarak incelersek: d-boyutlu örneklerden n tanesi $(x_1, \dots, x_n)$ eğitim kümesi olarak verilsin. TBA, bu örneklerin S_i varyansını en büyük değere çıkaran izdüşüm yönünü bulmaya çalışır. Bu da kovaryans matristen özdeğerleri bulmaya denktir (1.21).

$$S_t e = \lambda e, \quad (1.21)$$

ÇTBA'da her bir x vektörü giriş uzayından çok boyutlu F öznitelik uzayına doğrusal olmayan eşleme fonksiyonu ile $(\phi: R^d \rightarrow F)$ izdüşürülür. Öznitelik uzayının boyutu çekirdek fonksiyonuna bağlı olarak büyüyebilir (Örneğin Gauss fonksiyonu için sonsuz boyut). Öznitelik uzayında problem (1.22)'deki şekli alır.

$$S_t^\phi e^\phi = \lambda e^\phi, \quad \text{burada } S_t^\phi = \frac{1}{N} \sum_{i=1}^N \phi(x_i) \phi^T(x_i) \quad (1.22)$$

Denklem (1.22)'de S_t^ϕ , F uzayında kovaryans matrisidir. $\lambda \neq 0$ koşulunu sağlayan bütün e^ϕ çözümleri $\phi(x_1), \dots, \phi(x_n)$ 'lerin kapsadığı alanda uzanırlar. Diğer bir deyişle e^ϕ , öznitelik vektörlerinin doğrusal kombinasyonu şeklinde yazılabilir (1.23).

$$e^\phi = \sum_{i=1}^n \alpha_i \phi(x_i) \quad (1.23)$$

(1.22) denkleminde (1.23) yerine yazılırsa (1.24) elde edilir.

$$\sum_{i=1}^N \sum_{j=1}^N \alpha_j \phi(x_i) k(x_i, x_j) = N \lambda \sum_{j=1}^N \alpha_j \phi(x_j) \quad (1.24)$$

(1.24)'te, $k(x_i, x_j) = \phi^T(x_i) \phi(x_j)$ şeklinde tanımlanan iç çarpım çekirdeğidir. (1.24)'te her iki taraf $\phi^T(x_k)$ ile çarpılırsa, denklemde sadece $k(x_i, x_j)$ 'li terimleri kalır (1.25).

$$\sum_{i=1}^N \sum_{j=1}^N \alpha_j k(x_k, x_j) k(x_i, x_j) = N \lambda \sum_{j=1}^N \alpha_j k(x_k, x_j) \quad (1.25)$$

K , ij . elemanı $k(x_i, x_j)$ olan $n \times n$ 'lik çekirdek matris, $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$ olsun. Bu durumda (1.25) eşitliği, (1.26)'daki gibi matris formunda yazılabilir.

$$K^2 \alpha = N \lambda K \alpha \quad (1.26)$$

(1.26)'daki, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N$ pozitif değerler, K 'nın özdeğerleridir ve özvektörlerin bir sabit ile çarpılması yönde bir değişiklik yapmaz. Buradan (1.26) denklemi, (1.27)'deki gibi yeniden düzenlenebilir.

$$K \alpha = \lambda \alpha \quad (1.27)$$

(1.27)'de α , e^ϕ birim vektör olacak şekilde normalleştirilir ve izdüşürülmüş örnekler F uzayında ortalanarak işlem yapılır.

F 'deki vektörler, e^ϕ özvektörleri tarafından yayılarak oluşturulan alt uzaya izdüşürülür. x , F 'deki izdüşümü $\phi(x)$ olan test örneği olsun. $\phi(x)$ 'in e^ϕ özvektörlerine izdüşümü ϕ 'ye karşı düşen doğrusal olmayan temel bileşendir.

$$e^\phi \phi(x) = \sum_{i=1}^n \alpha_i (\phi(x_i) \phi(x)) = \sum_{i=1}^n \alpha_i k(x_i, x) \quad (1.28)$$

Yani, çekirdek fonksiyonu kullanarak, örnekleri F uzayına eşleme yapmadan, ilk q ($1 \leq q \leq n$) doğrusal olmayan temel bileşen çıkartılabilir.

Çekirdekli yöntemlerde diğer bir önemli husus, öznitelik uzayına eşleştirilen örnekler, o uzayda merkezlenmelidir. Yani, her örnek (1.29) denklemindeki gibi ortalanacaktır.

$$\phi(x_i) = \phi(x_i) - \frac{1}{N} \sum_k \phi(x_k) \quad (1.29)$$

Ortalanmış örneklerle çekirdek matrisi ($K_C(x_i, x_j)$) (1.29) denklemine göre hesaplayalım (1.30).

$$\begin{aligned}
K_C(x_i, x_j) &= \left(\phi(x_i) - \frac{1}{N} \sum_k \phi(x_k) \right) \left(\phi(x_j) - \frac{1}{N} \sum_k \phi(x_k) \right) \\
&= \phi(x_i) \phi(x_j)^T - \left[\frac{1}{N} \sum_k \phi_k \right] \phi(x_j)^T - \phi(x_i) \left[\frac{1}{N} \sum_k \phi_k \right] \\
&\quad + \left[\frac{1}{N} \sum_k \phi_k \right] \left[\frac{1}{N} \sum_k \phi_k^T \right]
\end{aligned} \tag{1.30}$$

$K(x_i, x_j) = \phi(x_i) \phi(x_j)^T$ olduğundan, (1.30) yeniden düzenlenirse (1.31) elde edilir. (1.31)'de, $K(x_i, x_j)$ yerine K_{ij} kullanılmıştır.

$$\begin{aligned}
K_{ij}^C &= K_{ij} - K_i 1_j^T - 1_i K_j^T - k 1_i 1_j^T, \\
K_i &= \frac{1}{N} \sum_k K(x_i, x_k) \quad \text{ve} \quad k = \frac{1}{N^2} \sum_{ij} K(x_i, x_j)
\end{aligned} \tag{1.31}$$

(1.31) ile öznitelik uzayında örnekler ortalananmış olur. t_i test örneği olmak üzere (1.30)'u test örnekleri için de yazalım.

$$K_C(t_i, x_j) = \left(\phi(t_i) - \frac{1}{N} \sum_k \phi(x_k) \right) \left(\phi(x_j) - \frac{1}{N} \sum_k \phi(x_k) \right) \tag{1.32}$$

(1.32)'yi, test örneğinin ortalananmış hali olarak (1.33) şeklinde yazabiliriz.

$$K_C(t_i, x_j) = K(t_i, x_j) - K(t_i) 1_j^T - 1_i K(x_j)^T - k 1_i 1_j^T, \tag{1.33}$$

ÇTBA'da, öznitelik sayısı giriş boyutunu geçebilir. Gözlem sayısının M , giriş boyutunun N olduğunu ve $M > N$ olduğunu varsayalım. TBA en fazla N adet "0" olmayan özdeğer bulur. Buna karşın ÇTBA M adet özdeğer bulabilir. Diğer taraftan, ÇTBA ile orijinal görüntünün yeniden üretilebileceği garantisi yoktur.

1.3.2.3. Çekirdekli Ayırıştırma Analizi

TBA gibi ÇTBA da giriş verilerinin toplam varyansını en aza indirmek için tasarlanmıştır ve ayırıştırma amacı için en uygun yöntem olduğu tam olarak söylenemez. ÇTBA'da olduğu gibi, DAA'yı da, çekirdek hilesiyle yüksek boyutlu uzayda uygulamak mümkündür. Bu yaklaşıma çekirdekli ayırıştırma analizi (ÇAA) denmektedir. ÇAA, ilk olarak Mika vd. tarafından [136] iki sınıf için tanımlanmış, sonra Baudat ve Anouar tarafından çok sınıflı problemler için genelleştirilmiştir [144].

R^n uzayından F uzayına doğrusal olmayan eşleme yapan fonksiyon Φ olarak verilmiş olsun.

$$\Phi : R^n \rightarrow F, \quad x \mapsto \phi(x) \quad (1.34)$$

(1.34)'te, R^n giriş uzayında verilmiş örüntüler, çok daha büyük boyutlu öznitelik uzayına eşlenmektedir. ÇAA'nın amacı, doğrusal uzayda olan giriş örüntülerini, öznitelik uzayında bir DAA problemi gibi çözmektir. Bu özellik uzayında Fisher kriterini maksimum yapmaya karşılık gelir (1.35).

$$J^\phi(\phi) = \frac{\phi^T S_b^\phi \phi}{\phi^T S_t^\phi \phi}, \quad \phi \neq 0, \quad (1.35)$$

Burada, S_b^ϕ ve S_t^ϕ , F öznitelik uzayında, sırasıyla sınıflar arası dağılım ve toplam dağılım matrisleridir. Dağılım matrisleri ilgili uzayda (1.36) ve (1.37) formülleri hesaplanır.

$$S_b^\phi = \frac{1}{M} \sum_{i=1}^C c_i (\mu_i^\phi - \mu^\phi)(\mu_i^\phi - \mu^\phi)^T \quad (1.36)$$

$$S_t^\phi = \frac{1}{M} \sum_{i=1}^N (\phi(x_i) - \mu^\phi)(\phi(x_i) - \mu^\phi)^T \quad (1.37)$$

Burada $x_1, x_2, x_3, \dots, x_M$ giriş uzayındaki M tane eğitim örneği; $M = \sum_{i=1}^C c_i$ olmak üzere c_i , i . sınıftaki örnek sayısı; μ_i^ϕ özellik uzayındaki i . eğitim sınıfın ortalama vektörü; μ^ϕ özellik uzayındaki tüm eğitim örneklerinin ortalama vektörüdür.

Bu noktadan sonra problem, $(S_t^\phi)^{-1} S_b^\phi$ matrisinin özdeğer ve özvektörlerinin bulunmasıyla çözülür. Yani ÇAA için, ÇTBA'daki işlem adımlarında TBA yerine DAA kullanılır.

1.4. Örüntü Sınıflandırma

Yürüyüşten kişi tanıma uygulamalarının son aşaması olarak, EYK [49, 58, 81, 82, 84, 92, 93, 98, 99, 101, 102, 104], DVM [78, 105], YSA [87] ve HMM [53, 61, 70, 83, 100, 106] gibi algoritmalarla sınıflandırma yapılmıştır. Sınıflandırma yaklaşımlarında, örnekler/sınıflar arasındaki uzaklıkların/ilişkilerin hesaplanması önemli bir yere sahiptir.

1.4.1. Uzaklık Ölçütleri

En basit anlamda sınıflandırma, iki sınıf arasındaki uzaklığa bakmaktır. Yani sınıflandırma iki sınıf arasındaki ilişkileri belirli kurallar çerçevesinde işlemekten ibarettir. Örüntü tanıma işlemlerinde ayırıştırma analizleri yapıldığında, kompleks sınıflandırıcılar genellikle fazla performans artışı sağlamaz. Bu nedenle, basit doğrusal uzaklık ölçütleri ile sınıflandırma, sistem performans açısından daha çok tercih edilir.

Kartezyen koordinat sisteminde 2 nokta arasındaki uzaklığı ölçmenin çeşitli yolları vardır. En geneli noktaların her iki eksenindeki değerlerinin farklarının karesi toplamalarının karekökü ile hesaplanan Pisagor bağıntısıdır. Bunun vektörler arasındakine Öklid uzaklık ölçütü denir (1.38).

$$d_{\text{öklid}} = \sqrt{\sum_{i=1}^N (f(i) - f_k(i))^2} \quad (1.38)$$

Şekil 1.10'da Minkowski uzaklık ölçütünün çeşitli p değerleri için birimdik alanda kapsadığı alan verilmektedir.

Bunların dışında Chebychev, Hamming, Mahalanobis uzaklıkları nadiren kullanılan uzaklık ölçütleridir. Problemin doğasına göre kullanılacak uzaklık ölçütü, sınıflandırıcının performansını artırır.

Örüntülerden elde edilen öznitelikler çok boyutlu uzayda bir noktayı temsil ederler. Fakat özniteliklerin kendileri vektörel formdadır ve aralarındaki açı uzaklık ölçütü olarak kullanılabilir. İki vektör arasındaki açının kosinüsü, eğer vektörler aynı ise “1” değerini alır. O halde iki vektör arasındaki açının kosinüsünün birden çıkarılmış hali, uzaklık ölçütü olarak kullanılabilir. (1.42)'de x ve y vektörleri arasındaki uzaklık, aralarındaki açının kosinüsüne dayalı olarak hesaplanmıştır.

$$d_{Kosinus} = 1 - \cos(\theta), \quad \cos(\theta) = \frac{xy}{\|x\|\|y\|} \quad (1.42)$$

1.4.2. En Yakın Komşuluk Sınıflandırıcıları

Adından da anlaşılacağı gibi sınıflandırılacak örneğin yakın olduğu komşu veya komşuluklara bakarak yapılan sınıflandırma yöntemidir. Çeşitli yaklaşımları olsa da en çok kullanılan EYK ve k -EYK sınıflandırıcılarıdır.

EYK sınıflandırıcıları, sınıflar arasındaki ilişkileri genellikle uzaklık ölçütleri ile belirler. Sınıflandırılacak test örneğini, sınıflardaki en yakın bir veya k tane en yakın örneklere veyahut sınıf merkezlerinden en yakınına göre değerlendirip etiketlendirir.



Şekil 1.11. (a) En yakın komşuluk, (b) k -en yakın komşuluk sınıflandırıcıları

1.4.2.1. Standart En Yakın Komşuluk

Bir örneğin, bilinen sınıflardaki örneklerle uzaklık ölçütlerine dayalı olarak karşılaştırılıp bir sınıfa dahil edilmesine EYK sınıflandırması denir.

Bir noktanın temsil ettiği örneklerden oluşan sınıf bilgileri A, B olsun. Şekil 1.11.(a)'daki gösterimde x örneğinin hangi sınıfa ait olduğu sorgulanmaktadır. Burada x örneği A sınıfının bir elemanına daha yakın olduğundan A sınıfına dâhil edilmiştir. Matematiksel olarak ifade edilirse (1.43) eşitliğinde, x'_n, x' in en yakın komşusudur.

$$\min d(x_i, x) = d(x'_n, x) \quad (1.43)$$

1.4.2.2. k-En Yakın Komşuluk

Temel olarak bir sınıflandırıcıdan, sınıf içerisindeki eleman sayısı ile doğru orantılı olarak daha iyi sınıflandırma yapması beklenir. Bu, EYK kuralında en yakın birkaç komşuluk ilişkisine bakılmasını gerektirir. Buna literatürde k -EYK kuralı denir ve k tane en yakın komşuluğa göre sınıflandırma yapılır.

k -EYK kuralına göre belirlenmiş k tane elemanın ait oldukları sınıflara bakılır ve k tane elemanın en fazla olduğu sınıf, sınıflandırıcı çıkışına verilir. Buradaki k sayısının seçimi deneysel olup; k büyük seçilirse hatalı sınıflandırma sayısı azalır, küçük seçilirse yakın komşuların etkileri artar.

Şekil 1.11.(b)'de $k=3$ alındığında k -EYK sınıflandırıcısı gösterilmektedir. EYK'da, A sınıfına dahil edilen x örneği, k -EYK'da, en yakın benzeşmelerdeki skor fazlalığından dolayı bu sefer B sınıfına dahil edilmiştir.

EYK ilişkileri, Voronoi çizelgeleri ile yakın ilişkilidir. Voronoi çizelgesinde noktalar arasına çekilen doğru parçalarının orta dikmeleri ile her noktaya ait alan belirlenir. Sınıflandırılacak örnek hangi alanda ise, alanın sahibi olduğu örneğe benzediği varsayımı ile ait olduğu alanın sınıfına atanır [145].

EYK kriterlerinden hangisi ile sınıflandırma yapılacağına karar vermek için sınıfları oluşturan örneklerin karakteristikleri iyi bilinmelidir. Örnek olarak yüz tanıma problemini ele alalım: Bir sınıfta sakallı, bıyıklı ve normal görüntülerden birer tane olsun ve x örneğinin ait olduğu sınıfta bıyıklı görüntü olmasın. Bu durumda x test örneğinin bıyıklı görüntülerin olduğu sınıflardan birine daha yakın olması muhtemeldir. Bu nokta da k -EYK

seçilmesi daha mantıklı olabilir ki; diğer yüz hatlarının baskınlığı bıyiksız ve sakallı görüntülerinin güç birliği ile öne çıksın. Diğer bir örneğimizde her sınıfta her tip görüntüden fazlaca olsun ve x örneğinin ait olduğu sınıfta yalnızca bir tane sakallı resmi olsun. Bu durumda x örneği sakallı ise k -EYK ile farklı sınıftan sakallı görüntüye benzerlik skoru, ait olduğu sınıfın skorunu geçebilir. Bu durumda EYK seçilmesi daha mantıklıdır.

1.4.3. Destek Vektör Makineleri

DVM, V.Vapnik tarafından önerilen, bir düzlemdeki iki grubun sınırlarını belirleyen çizginin, nasıl çizileceğini belirleyen bir istatistiksel bir yaklaşımdır [134]. Çizdiği sınır her iki grubun üyelerine de en uzak noktalardan geçer.

Şekil 1.12.(a)'da bir düzlemde temsil edilen “€” ve “■” grupları için DVM sınıf çizgisinin belirlenmesi gösterilmektedir. Düzlemdeki her bir nokta, eğitimdeki örneklerin özniteliklerinin boyutlarına tekabül eder ve aralarından çekilen çizgi ile sınıflandırma yapılmış olur. Gruplar arasındaki sınırın belirlenmesi için, gruplara en yakın noktalardan geçen paralel iki çizgi çizilir. Sonra bu çizgiler arasındaki mesafe azaltılarak DVM sınıf çizgisinin yeri belirlenir. Bu iki grup arasında oluşan aralığa marj (ofset) denir. Mevcut düzlemdeki noktaların tanımı (1.44)'teki gibi yapılsın.


$$D = \left\{ (x_i, c_i) \mid x_i \in R^p, c_i \in \{-1, 1\} \right\}_{i=1}^n \quad (1.44)$$

Burada x vektör uzayındaki bir noktayı ve c ait olduğu sınıfı temsil eder. Gösterimin bir aşırı düzlem (hyperplane) üzerinde olduğunu varsayarak her bir noktayı (1.45) şeklinde ifade edebiliriz.

$$wx - b = 0 \quad (1.45)$$


(1.45) denklemi, $ax+b$ gibi bir doğru denklemine benzer. Bu denklemde w aşırı düzleme dik olan normal vektör, x noktanın değişken parametresi ve b kayma değeridir.

Buradan iki grup arasında mesafenin marj değeri $b/\|w\|$ ile hesaplanır. Şekil 1.12.(a)'da, mesafeyi en yüksek değere çıkarmak amacıyla -1, 0 ve 1 değerlerine sahip doğruları üretmek gereklidir. Bunun için doğrular arasındaki mesafe 2 birim olarak alınmıştır. Yani tolerans değeri $2/\|w\|$ 'dir. Bu, Şekil 1.12.(a)'da doğruların kaydırılmasına denktir ve aynı zamanda problemin doğrusal ayrılabilirliğini gösterir. Diğer taraftan iki grup arasındaki aşırı düzlemin yönü tek değildir veya bir tane aşırı düzlem yoktur (Şekil 1.12.(b)). DVM bu aşırı düzlemler içerisinde en büyük marja sahip olanı alır.



Şekil 1.12. Öznitelik uzayında doğrusal DVM


Şekil 1.12.(a)'da doğrusal ayrılabilen 2 grup verilmiştir. Şekil 1.13.(a)'daki gösterimde doğrusal ayırma yapılamamaktadır. Ayrıştırırmayı yapabilmek için, Şekil 1.13.(b)'deki gibi bir eğri, sınır olarak çizilmelidir. Bu işlem çekirdek hilesiyle doğrusal olmayan uzayda yapılabilir.



Şekil 1.13. Doğrusal olmayan uzay, (a) Doğrusal DVM (b) Doğrusal olmayan DVM

Bilindiği gibi DVM iki sınıf arasındaki sınırı belirler. Yani DVM ile iki sınıf tolerans değerinde birbirinden ayrılmakta ve bu ayrım sonucunda elde edilen öznitelik vektörlerine göre aşırı düzlem üzerinde iki düzlem oluşturulmaktadır. İki'den fazla sınıf olması durumunda DVM çoklu sınıf problemi haline getirilebilir. DVM'nin çoklu sınıf problemlerini çözebilmesi için pek çok yaklaşım olsa da, yaygın olarak 3 tanesi kullanılmaktadır [139]:

- Çoklu sınıf probleminin ikili gruplara indirgenmesi (bire-karşı-bir) : Knerr vd. tarafından önerilmiştir. Bu yaklaşımda k adet sınıf için $k(k-1)/2$ tane sınıflandırıcı kurulur ve her bir sınıflandırıcı, sadece 2 gruptan gelen verilerle eğitilir. Böylece, eğitim için sadece iki sınıfa ait veriler kullanılarak eğitim süresi azaltılmış olur.
- Problemin tek gruptan bütün gruplara modellenmesi (bire-karşı-hepsi) : bu yaklaşımda k adet sınıf için k tane sınıflandırıcı kurulur ve i .sınıflandırıcı i .sınıfın verilerini kendi sınıfı, diğer tüm sınıf verilerini 2. sınıf olarak kabul eder. Bu işlem, k tane DVM için tekrar edilir. Bu yaklaşım, eğitim süresi bire-karşı-bir yaklaşımından çok daha uzun olduğu için daha az tercih edilir.
- Çoklu sınıf sıralama DVM'leri : bu yaklaşımda sınıflar üzerinde bir DVM sınıflandırıcısı, bütün sınıfların üyelerini içeren bir sınıflandırma yapmaya çalışır. Bu yaklaşım, sonuca varılamama gibi bir tehlike yanında oldukça uzun süren bir eğitim aşamasına sahip olduğundan pek tercih edilmez.



Şekil 1.14. Çoklu DVM, (a) bire-karşı-bir DVM, (b) bire-karşı-hepsi DVM

Şekil 1.14.(a)'da her iki sınıf arasında maksimum marjlı çizgiler çeken DVM verilmiştir. Yeni bir örnek geldiğinde her bir sınıflandırıcıya sorulur ve en çok hangi sınıflandırıcıdan cevap gelirse yeni örnek o sınıflandırıcıya konulur.

Şekil 1.14.(b)'de bire-karşı-hepsi yaklaşımı ile bir sınıfın diğer tüm sınıflar ile karşılaştırılması sonucu, maksimum marjlı çizgiler çekilmiştir. Her sınıf için tekrarlanan bu işlem sonucunda k tane doğru üretilmiştir. Sonra bu doğruların denklemlerinin birleştirilmesiyle bütün sınıfların ayrıştırılması sağlanabilir.


Sınıflandırıcılar içerisinde DVM gittikçe önem kazanmaktadır ve bunun sonucu olarak yazılım kütüphanelerinde yerini almış durumdadır [146]. Yapay zeka uygulamalarında oldukça popüler olan katmanlı sinir ağlarına göre DVM, yerel minimumlara takılmaması, aykırı değerlerden kolayca etkilenmemesi ve genelleştirilmesinin kolay olması gibi avantajlara sahiptir [147]. Bunun dışında, DVM'nin, parametre kestirimi için eğitim verilerini tekrar tekrar kullanması, eğitim sürecinde, YSA'ya göre daha çok işlem hacmi ve zaman gerektirebilir [147].

1.4.3. Sınıflar Arası Uzaklığa Dayalı EYK

Örüntü tanıma tekniklerinin test aşamasında genellikle tek bir örnek test edilir. Yürüyüşe dayalı kişi tanıma çalışmalarında kullanılan örnekler yürüyüş dizilerinden üretildiği için aynı anda birkaç test örneği elde edilebilir. Bu nedenle test esnasında test sınıf bilgisini de kullanmak mantıklı olur.

Test esnasında test örneklerinin sınıf bilgisini kullanmanın en basit yolu, sınıftaki her bir örneğin sınıflandırılması sonucunda sınıf elemanlarının en çok dâhil olduğu sınıfın seçilmesidir. Bu yöntem bütün sınıflandırıcılar için kullanılabilir.

Diğer bir yaklaşım, sınıflar arasındaki uzaklıkları hesaplarken sınıf bilgisini kullanmaktır. Bu tür yaklaşımlarda, referans ve test sınıflarının elemanları arasında uzaklıklar hesaplanır. Sonra bu uzaklıkların ortalaması veya medyanı alınarak iki sınıf arasındaki mesafe ölçüsü olarak belirlenir. Bu yaklaşımlar hatalı gözlemlerin etkisini azaltır. Boulgourious, sınıflar arasındaki uzaklığı kullanarak yürüyüş örüntülerini sınıflandırmıştır [91, 92]. Çalışmasında, Şekil 1.15'teki yaklaşım önerilmiştir.



Şekil 1.15'te, ilgili uzaklık ölçütüne dayalı olarak iki sınıf arasındaki uzaklık hesabı gösterilmektedir. Burada, c_j , sütunların minimumu; C , test sınıfına ait örnek sayısı; s_i , satırların minimumu; S , eğitim sınıfına ait örnek sayısıdır. d_{ij} , iki örnek arasındaki uzaklık olmak üzere c_j ve s_i sırasıyla (1.46) ve (1.47)'deki gibi hesaplanabilir.

$$c_j = \min\{d_{ij}\}, \quad j = 1, \dots, m \quad (1.46)$$

$$s_i = \min\{d_{ij}\}, \quad i = 1, \dots, n \quad (1.47)$$

c_j ve s_i 'ye bağılı olarak c ve s sınıfları arasındaki uzaklık (D_{sc}) (1.50) denklemi ile elde edilebilir.

$$D_s = \text{ortalama} / \text{medyan}(s_i) \quad (1.48)$$

$$D_c = \text{ortalama} / \text{medyan}(c_j) \quad (1.49)$$

$$D_{sc} = \frac{1}{2}(D_c + D_s) \quad (1.50)$$


Sınıfların benzerliği diye de adlandırılan bu yöntem yürüyüş dizilerinin tanınması için oldukça uygun düşmektedir. Böylece, siluetlerin hatalı (kapanma, emilme vb.) elde edilmesi ile oluşan bozuk yürüme örüntüleri, başka bir örüntü ile telafi edilebilir.

2. YAPILAN ÇALIŞMALAR

Günümüzde biyometrik özellikler sayesinde güvenilir, hızlı ve otomatik olarak kimlik tanıma yapabilen sistemler kullanılır hale gelmiştir. Suç mahallinde bırakılan örneklerin, biyometrik özellik veritabanları ile karşılaştırılarak olayların aydınlatılması, parmak izi kontrolleriyle sahte kimlik kartı kullanımının önüne geçilmesi, güvenlik kameralarıyla yakalanan yüz görüntülerinden kişilerin otomatik tanınması, biyometrik özelliklerin etkin bir şekilde kullanıldığı diğer alanlardır. Biyometrik özelliklerin daha ileri uygulaması, anti-terörizm gibi güvenlik güçlerine karşı gelişen insan tabanlı saldırıların önceden tahmin edilmesinde kullanılmalarıdır [14]. Bu amaçla 2000’li yıllarda HumanID programı kurularak pek çok üniversite ve enstitü teşvik edilmiştir [3].

Uzaktan otomatik kimlik tespiti, yüz ve yürüyüş şekli biyometrik özellikleri ile yapılabilir [14]. Yüksek çözünürlükteki kameralarla alınan yüz görüntüleriyle büyük veritabanlarından bile kimlik tespiti yapılabilir. Ancak yüzün gizlenme, değiştirilme ve karanlıkta görünmeme gibi dezavantajları vardır. Gelişim aşamasında olan yürüyüş şekli biyometrik özelliği kızılötesi ve termal kameralarla karanlıkta ve karmaşık ortamlarda ve düşük çözünürlükteki kameralarla çok uzaklardan ölçülebilir.

Yürüyüş biyometrik özelliği, diğer biyometrik özelliklerin aksine, belirli bir zaman içerisinde elde edilen görüntü dizilerinin işlenmesini gerektirir. Öncelikle görüntü dizilerinde nesneler algılanır ve algılanan nesnenin insan olup olmadığına karar verilir. Algılanan nesne insan ise, yürüyüş dizisinden yürüyüş biyometrik özellikleri ölçülür. Yürüyüş biyometrik özelliklerinin ölçümü, model-tabanlı yaklaşımlarda, model oturtma ve zamanla modeldeki dinamik değişimlerin analizi, modelden bağımsız yaklaşımlarda, siluet çıkarma ve yürüyüş örüntüsü üretme işlem adımları şeklindedir. Sonraki aşamada ölçülen biyometrik özelliklerden kişisel yürüyüş biyometrik imzaları veya örüntü tanımadaki adıyla öznitelikleri çıkarılır. Yürüyüşünden kişi tanımanın son aşaması, özniteliklerin sınıflandırılmasıdır. Bu aşamada önceden çıkarılan kişisel yürüyüş öznitelikleriyle, tanınması arzulanan kişinin yürüyüş öznitelikleri karşılaştırılır. Şekil 2.1’de yürüyüşten kişi tanıma uygulamasının aşamalarını gösteren bir model verilmiştir. Modelde, nesnelerin gözetleme sisteminden bölütlenmiş bir şekilde elde edildiği varsayılmıştır. Yürüyüş tanıma sistemi genel olarak örüntü tanıma problemi olarak ele alınsa da, modelin sol kısmından da görüldüğü gibi yürüyüş şeklinin temsil edilmesi aşaması vardır.



Şekil 2.1. Yürüyüş biyometrik özelliğine dayalı kişi tanıma sistemi

Bu bölümde, yürüyüş içeren siluet dizilerinden yürüyüş örüntüsü üretimi, biyometrik özellik çıkarımı ve sınıflandırılmasını içerir örüntü tanıma amaçlı yapılan çalışmalar ve tarafımızdan önerilen yaklaşımlar sunulmuştur.

Yürüyüş örüntüsü üretmek için siluet kutusu ile siluet sınırları arasındaki 4 farklı yönden uzaklıklardan yürüyüş periyodu boyunca oluşturulan şavak örüntü [112-114], siluet dizisinin TBA yapılarak elde edilen özvektörlerin toplamı, her bir siluet pikselinin yürüyüş periyodu boyunca hesaplanan 1-boyutlu DCT bileşenleri ve siluet dizisindeki çerçevelerin p adımlı farklarının enerjisi (pCFEI) yaklaşımları önerilmiştir. Yürüyüş örüntülerinin doğrudan ve 2B-DCT'si alınarak boyut indirgeme ve öznitelik çıkarma yaklaşımlarıyla performansları araştırılmıştır. Önerilen yürüyüş örüntüleri içerisinde en iyi performansı pCFEI vermiş ve yaygın kullanıma sahip YEİ ile karşılaştırılmıştır.

Bu bölümdeki diğer bir konu, örüntülerde boyut indirgenmesi ve beraberinde özellik çıkarma işlemidir. Literatürde yaygın olarak, TBA ve DAA yöntemleri yürüyüş örüntülerinden özellik çıkarma amacıyla kullanılmıştır. Bu çalışmada mevcut yaklaşımlardan farklı olarak direk doğrusal ayrıştırma analizi (D-DAA), 2-boyutlu temel bileşen analizi (2B-TBA) ve doğrusal olmayan özellik uzayında direk doğrusal ayrıştırma analizi (ÇDAA) yapılmıştır. 2B-TBA'nın sağdan ve soldan uygulandığında değişen performansından hareketle, örüntülerin görüntü boyutları (görüntü yüksekliği ve genişliği) değiştirilerek farklı dağılım matrislerindeki ayrıştırıcılık yeteneği incelenmiştir. Yürüyüş şekline göre kişi tanıma çalışmalarında ilk kez uygulanan özellik çıkarma yaklaşımlarının performansı, diğer TBA, ÇTBA ve TBA+LDA özellik çıkarma yöntemleri ile kıyaslanmıştır. Çekirdek hilesi ile doğrusal olmayan uzayda özellik çıkarma

yaklaşımlarında parametre kestirilmesi gerekmektedir. Deneylerimizde en iyi performansı veren Gauss çekirdeği sigma (σ) parametresinin kestirimini gram matrizen otomatik hesaplayan bir denklem, deneysel çalışmalar sonucu üretilmiştir. Bütün deneylerimizde, σ değeri bu denkleme göre hesaplanmıştır.

Örüntü tanımanın sonraki aşaması olan sınıflandırmada, mevcut sınıflandırıcılarda normalize edilmiş veriler kullanılmaktadır [146]. Çalışmada verilerin normalizasyonu özniteliklerin uzandığı boyutlara göre ayrı ayrı yapılmıştır. Yeni bir yaklaşım olan bu normalizasyon sınıflandırıcıların performansını artırmıştır.

Örüntü sınıflandırma çalışmalarında, hızlı ve kolay uygulanabilirliği açısından Öklid uzaklık ölçütleriyle beraber EYK sınıflandırıcıları başarılı bir şekilde kullanıldığı bilinmektedir. Bununla beraber AÖÜ ve vektörlerin arasındaki açının kosinüsüne dayalı uzaklık (KAU) daha iyi sonuçlar vermektedir. Bu uzaklık ölçütlerinden farklı olarak, eğitim örneklerinin özniteliklerinden hesaplanan ortalama öznitelik vektörüyle, eğitim ve test öznitelik vektörlerinin vektörel farkları hesaplanmış ve fark vektörleri arasındaki açının kosinüsü uzaklık (kKAU) ölçütü olarak önerilmiştir. Deneylerimizde kKAU, diğer uzaklık ölçütlerinden daha iyi sonuçlar vermiştir.

Örüntü sınıflandırma işleminde, sınıflara ait birden fazla örnek varsa, minimum uzaklık, merkezi uzaklık, k -EYK gibi sınıflandırma mekanizmaları kullanılır. Bu çalışmada, Bölüm 1.4.4'te verilen sınıflandırma mekanizması ile parametre ihtiyacı olmayan EYK kullanılmıştır. Kullanılan diğer bir sınıflandırıcı DVM için LibSVM kütüphanesinden faydalanılmıştır. LibSVM kütüphanesinde, eğitim sınıfları için denetim yapılmaktadır, ancak test örneklerinin sınıf bilgisi değerlendirilmemektedir [146]. Çalışmada LibSVM ile sınıflandırılan test sınıfındaki örneklerin, etiketlendiği sınıf bilgilerinin maksimum skorluna bakılarak, tam denetimli bir DVM oluşturulmuştur.

Bu tez çalışmasında yapılan deneylerde, LibSVM kütüphanesi hazır olarak kullanılmış olup diğer uygulamalar Borland C++ Builder editöründe C++ dilinde geliştirilmiştir.

2.1. Yürüyüş Veritabanlarının Düzenlenmesi

Ağ ortamından indirilen yürüyüş veritabanlarından, CMU MoBo ve CASIA-A veritabanları, RGB formatında renkli, USF, CASIA-B, CASIA-C, SOTON veritabanları, siluet olarak ikili formattadır. Renkli formattaki veritabanlarından siluetlerin üretilmesi için

BRR algoritması [30] uygulanmıştır. CMU MoBo veritabanı yürüme bandında oluşturulduğundan arka plan modeli için veritabanında verilen arka plan görüntüleri kullanılmıştır.

Üretilen ve indirilen veritabanlarında siluetler, kayıt kamerasının çözünürlüğündeki çerçeveler şeklinde olduğundan, nesne bölütleme ve kutulama işlemi yapılmıştır [29]. Sonra her bir siluet çerçevesi (siluet kutusu boyutlarında), ilgili veri tabanındaki en büyük siluet yüksekliğine göre, en/boy oranı değiştirilmeden yeniden boyutlandırılıp, olabilecek en büyük genişlikteki görüntülerin ortasında saklanmıştır. Tablo 2.1’de veritabanları için belirlediğimiz siluet görüntü boyutları verilmiştir.

Tablo 2.1. Yürüyüş veritabanlarının siluet görüntü boyutları


Veritabanı	İmge Genişliği	İmge Yüksekliği
CMU MoBo	224	304
CASIA-A	88	160
SOTON	328	392
USF V1	92	128
USF V2	92	128
CASIA-B	88	160
CASIA-C	88	160

Siluet görüntüsü olarak indirilen veritabanlarının bazılarında kopukluklar, arkaplan bilgilerinin ön plan bilgilerine karışması gibi bozukluklar olduğundan, oluşturulan siluet çerçevelerinde en/boy oranının 0.8’den büyük ve 0.3’ten küçük olanları incelenmiş ve gerektiğinde elle düzeltme yapılmıştır. Şekil 2.2’de bozuk çerçevelerden örnekler verilmiştir.

Şekil 2.2.(a)’da verilen USF veritabanı için bozuk siluetler özellikle zeminin çimen olduğu oturma alanlarında daha fazladır. Genellikle kafa ve bacak bölgelerinde kopukluklar ve ayak bölgelerinde gürültüler mevcuttur. En az bozuk siluet içeren SOTON veritabanında da genel olarak gölgeden dolayı ayak bölgesinde gürültüler vardır (Şekil 2.2.(b)). Kızılötesi kamera kullanılan CASIA-C veritabanındaki siluetlerin çoğunda boşluklar vardır. Şekil 2.2.(c)’de görüldüğü gibi bazı siluetler arka plandan bölütlenememiştir. Şekil 2.2.(d)’de

CASIA-B veritabanına ait bozuk silüetler verilmiştir. Özellikle profil dışındaki açılarda görüntülerinde bozuk silüetlere rastlanmaktadır.

Yürüyüş periyodu, CMU MoBo, SOTON, USF V1 ve CASIA-A veritabanları için elle belirlenmiştir. USF V2 veritabanında, her bir kayıt (bir kişinin farklı oturumlardaki kayıtları için farklı) için yürüyüş periyotları verilmiştir. CASIA-B ve CASIA-C veritabanlarında yapılan testlerde, otomatik hesaplanan yürüyüş periyodu kullanılmıştır.



Şekil 2.2. Veritabanlarındaki bazı bozuk silüetler, (a) USF, (b) SOTON, (c) CASIA-C (kızılötesi kamera), (d) CASIA-B

CMU, SOTON ve CASIA-A veritabanları literatürde kullanıldığı şekilde sunulmaktadır. ZeminAyakkabıYön (ZAY) dizinleriyle sunulan USF veritabanları USF-NIST formatına göre yeniden düzenlenmiştir. USF-NIST formatı, veritabanından, oturmadaki kişilerin bulunduğu dizinlerin hangi sete ait olduğu, kişilerin yaş, boy, kilo özellikleri ile beraber saklanan “CSV” formatında dosya olarak edinilmiştir. CASIA-B veritabanı aynı anda 11 farklı kamera ile oluşturulmuştur ve indirilen siluet dizinlerinde en az siluet sayısı, yani üretilebilecek en az örnek sayısı profilden kayıt edilen setlerdedir. Diğer açılardaki setlerde, belirlenmiş yürüyüş kayıt alanının dışından, bozuk siluetler içeren çerçeveler mevcuttur. Siluet çerçevelerinde, kayıt alanının belirleyici işaretleri algılanamadığından, tüm setlerde siluet dizilerinin ortasından 90°’lik açılı setlerdeki çerçeve sayısı kadar çerçeve seçilmiş ve test formatı [81]’e göre düzenlenmiştir. CASIA-C veritabanında normal yürüyüş oturumlarının ilk ikisi eğitim, diğer ikisi test seti olarak belirlenmiştir. Bunun dışında CASIA-C veritabanında hızlı, yavaş ve çanta taşınarak yapılan yürüyüşler test için kullanılmaktadır.

2.2. Yürüyüş Örüntüsü Üretme

Siluet tabanlı yöntemlerde, yürüyüş biyometrik özelliklerinin çıkarılması için yürüyüş dizilerinden yürüyüş şeklini temsil eden örüntüler üretilir. Yürüyüş şeklinin temsil edilebilmesi için, bir yürüyüş periyodundaki çerçeve sayısı kadar ardışık siluet çerçevesi yeterlidir ve bunlar, kişisel yürüyüş imzasının üretilmesi amacıyla yürüyüş örüntüsünün üretilmesinde kullanılırlar. Yürüyüş esnasında, yürüyüş periyotunun belirlenmesi için bir adımdakinden daha fazla siluet üretilir. Bunun sonucu olarak, anlık durumlarda birden fazla yürüyüş imzası üretilerek tanıma performansı artırılabilir.

2.2.1. Yürüyüş Periyodu Hesabı

Yürüyüş ritminin periyodunu hesaplamak için ardışık siluet üzerindeki değişken değerlerin veya bu değerlerin ortak olarak etkilediği nokta veya özelliklerin yürüme esnasında oluşturduğu işaretleri kullanılır. İnsan vücudunda yürüyüş ritminin en iyi izlenebildiği noktalar, bacak ve bel bölgeleridir [7, 8, 13]. Bu bölgelerden noktalar seçmek, yerel görüntü işlemlerle işlem yükü getirir. Mevcut çalışmalarda, siluet görüntüsündeki ön

plan bilgilerinin toplamı, siluet merkezi ve siluet kutusunun genişliği veya siluet kutusunun boyutlarının oranı gibi global özelliklerden yürüyüş periyodu tahmin edilmiştir [118]. Bu çalışmada da yürüyüş periyodu siluet kutusunun en/boy oranındaki değişime göre hesaplanmıştır. Siluet kutusunun genişliği daha az işlem yükü getirmesine rağmen, siluetlerin yeniden boyutlandırılmasından önce siluet kutusu genişliğine göre yürüyüş periyodunun tahmini hatalı olur. Siluetlerin yeniden boyutlandırılması ile siluet kutusunun en/boy oranının hesaplanmasının getireceği hesapsal işlem yükü kıyaslandığında, yürüyüş periyodunun siluet kutusunun en/boy oranına göre tahmin edilmesi daha az maliyetlidir.

Bu tezde, yürüyüş dizisindeki siluet kutularının en/boy oranına göre yürüyüş frekansı işareti üretilip (2.1) denklemi ile normalize edilmiştir. Sonra öz-ilintisi (2.2) hesaplanıp hızlı Fourier dönüşümü (2.3) ile genlik spektrumu bulunmuştur. Genlik spektrumunda (2.4) denklemiyle yürüyüş periyodu tahmin edilmiştir [118].

$$s(t) = \frac{s(t) - \mu_s}{\sigma^2} \quad (2.1)$$

$$R_{ss}(j) = \sum_n s_n \bar{s}_{n-j} \quad (2.2)$$

$$S_k = \sum_{n=0}^{N-1} R_n e^{-j 2 \pi k \frac{n}{N}} \quad k = 0, \dots, N-1 \quad (2.3)$$


$$P = \frac{2(N-1)}{\arg \max (S)} \quad (2.4)$$

Denklemlerdeki $s(t)$ işareti siluet çerçevesinin en/boy oranının zamanla değişimi, μ_s ve σ^2 , sırasıyla $s(t)$ işaretinin ortalaması ve standart sapması, p tahmin edilen yürüyüş periyotudur.

2.2.2. Yürüyüş Enerji İmgesi

YEİ yürüyüş örüntüsü, bir periyotluk yürüyüş dizisindeki aynı yüksekliğe sahip ardışık ortalanmış siluet görüntüleri toplamının, farklı büyüklükteki yürüyüş periyotları

için yürüyüş periyoduna bölünmesiyle elde edilir [59]. Şekil 2.3'te, YEİ'nin üretilişi verilmiştir. S , ikili siluet görüntüsü ve p yürüyüş periyodudur.



Şekil 2.3. YEİ'nin üretilişi

2.2.3. Önerilen p Çerçeve Farkı Enerji İmgesi


YEİ yürüyüş örüntüsü ardışık siluet çerçevelerinin toplanmasına dayalı olduğu için siluette değişmeyen bölgeleri de barındırmaktadır. Siluetteki değişmeyen bölgeler fiziksel yapı bilgisini (iri yapılı, zayıf, çocuk) sakladığından özellikle az salınışlı yürüyüşlerde tanıma, yürüyüşteki dinamik bilgiden daha çok fiziksel özelliklerden gerçekleştirilebilir. Bu nedenle bu tez çalışmasında, yürüyüşteki anlık değişimleri daha çok barındıran, p adımlı çerçeve farklarının enerji imgesi (pCFEİ), yürüyüş örüntüsü olarak önerilmektedir. Şekil 2.4'te, pCFEİ'nin üretilişi için ikili siluet görüntülerini giriş alan bir yapı verilmiştir.

pCFE imgesindeki p parametresi yürüyüşün hız değişimlerinde veya saniyede alınan görüntü sayısının değişmesi durumlarında, değişmeyen yürüyüş örüntüsünü üretebilmek için gereklidir. p parametresi, saniyede alınan çerçeve sayısı (f) ve yürüyüş periyotuna (P) bağlı olarak denklem (2.5)'ten hesaplanmış ve pCFEİ, (2.6) denklemi ile üretilmiştir.

$$p = \frac{P}{f \times k}, \quad 1 \leq p < \frac{P}{4} \quad (2.5)$$

$$pCFEI = \frac{1}{P} \sum_{k=1}^P |S_k - S_{k'}|, \quad k' = (k + p) \bmod P \quad (2.6)$$

Burada, k deneysel sabittir.




Şekil 2.4. pCFEI'nin üretilişi

Yürüyüş, periyodik bir hareket olduğundan, pCFEI'nin üretilmesinde, yürüyüş periyodunu aşan p adım sonraki çerçeveler yerine $\bmod P$ 'ye göre, başlangıç yürüyüş dizisi çerçeveleri kullanılabilir (2.6). Gerçek zamanlı sistemlerde yürüyüş sürekli bir hareket olduğundan $k' = k + p$ şeklinde uygulanması daha uygundur. Testlerde kullanılan veritabanlarından daha fazla örnek üretebilmek için pCFEI denklem (2.6)'teki gibi üretilmiştir. Mevcut veritabanlarında, p tamsayı parametresinin, "1" veya daha büyük ve $P/4$ 'ten küçük olması deneysel olarak belirlenmiştir.

2.2.4. Siluete 4-Yönden Bakıştaki Uzaklıklara Dayalı Yürüyüş Örüntüsü

pCFEİ yaklaşımından önceki yürüyüş örüntüsü üretme çalışmamızda, bir periyotluk yürüyüş dizisindeki siluetlere 4 farklı yönden bakılarak, siluet kutusu ile siluet sınırları arasındaki uzaklıkların, yürüyüş periyodu kadar genişlikteki imgenin sütunlarına yerleştirilmesiyle oluşturulan 4 farklı yürüyüş örüntüsü (sol, sağ, alt, üst) üretme yaklaşımı önerilmiştir [113, 114, 117].



Şekil 2.5. Siluet sınırları ile siluet etrafına konuşlandırılan dikdörtgen sınırları arasındaki uzaklığa dayalı uzaysal-zamansal hareket temsilleri

Şekil 2.5'te, F_L , F_R , F_T , F_B fonksiyonları sırasıyla sol, sağ, üst ve alt yönden bakışlarda yürüyüş örüntülerini üretir. Fonksiyonlardaki gösterimlerde; x,y siluet kutusunun kartezyen koordinatlarına göre piksel konumunu, t bir yürüyüş periyotluk siluet dizisindeki zamanı gösterir. $F_L(y,t) = \sum_x bs(x,y,t)$ sol yürüyüş, t anındaki bs ikili siluet kutusunda $x=0$ başlangıcından artırılarak rastladığı ilk siluet sınır pikseline kadar alınan yol mesafesi (piksel birimli), t anındaki y değerini gösterir. Diğer yönlerdeki yürüyüş örüntüsü üretme fonksiyonları da benzer şekildedir.

Siluetlere farklı yönlerden bakarak üretilen bu yürüyüş örüntüleri birbirinden bağımsızdır. Bu, siluet sınırlarına dayalı üretilen diğer yaklaşımlara göre gürültü açısından avantaj sağlar. Bu yürüyüş örüntüleriyle, disiplinler arası çalışmalarımızda, deneklerin ilaç almışlık durumunun analizi başarılı bir şekilde yapılmıştır [148-150].

2.2.5. Temel Bileşenlerle Yürüyüş Örüntüsü Üretme

TBA’nde özvektörler veri dağılımının yöneylerini temsil etmektedir. Bir yürüyüş periyodu içerisindeki siluetler gözlem olarak düşünülürse, siluet dizisinin yöneyleriyle yürüyüş temsil edilebilir. Bunun için bir yürüyüş periyodundaki siluetlerin TBA yapılıır. Sonra, özdeğer ve özvektörlerine dayalı olarak yürüyüş temsil edilebilir.


p yürüyüş periyotlu bir siluet dizisinde siluetler S_i şeklinde verilsin. Bir yürüyüş periyodundaki vektöre çevrilmiş siluetlerin kovaryans matrisinin özdeğer (λ_i) ve özvektörleri (Λ_i) hesaplanır ve özdeğerlere göre sıralanır. Sonra öznitelik çıkarmada olduğu gibi özdeğer toplamalarının belirli bir yüzdesini sağlayan özdeğer sayısı kadar özvektör (m) örüntü üretimi için kullanılır. Çalışmada TBA’ya dayalı iki farklı örüntü üretilmiştir. Birincisinde m tane özvektör, onlara karşılık gelen özdeğerlerle çarpılarak toplanmıştır (2.7). Diğerinde m tane özvektörün ortalaması alınmıştır (2.8). TBA’ya dayalı olarak örüntü üretme yaklaşımı ilk kez bu tezde önerilmektedir.

$$YO_{TBA1} = \frac{1}{p} \sum_{i=1}^m \lambda_i \Lambda_i \quad (2.7)$$

$$YO_{TBA2} = \frac{1}{p} \sum_{i=1}^m \Lambda_i \quad (2.8)$$

Şekil 2.6’da, USF V1 veritabanında, TBA ile üretilen farklı kişilere ait yürüyüş örüntüleri verilmiştir. Şeklin üst kısmındaki örüntüler (2.7) ve alt kısmındakiler (2.8)’e göre üretilmiştir. Şeklin sol yarısındaki örüntüler birinci şahsa, sağ yarısındakiler diğer şahsa ait yürüyüş örüntüleridir ve farklı kişilerin her bir örüntü üretme yaklaşımında 3’er örüntüsü gösterilmiştir.

TBA ile üretilen yürüyüş örüntüleri YEİ ve PCFEİ ile benzer tanıma performansı sağlamaktadır. Ancak tüm bir periyotluk yürüyüşler için, ayrı ayrı TBA yapılmasını gerektiren maliyetli bir yaklaşımdır.



Şekil 2.6. TBA ile üretilmiş USF V1 eğitim setinden örnek görüntüler


2.2.6. DCT ile Yürüyüş Örüntüsü Üretme

DCT görüntü sıkıştırma da sıkça kullanılan ortogonal bir dönüşümdür. 1-boyutlu DCT dönüşümün ilk değerine DC, diğerlerine AC bileşen denir. Tarafımızdan önerilen DCT ile yürüyüş örüntüsü üretme yaklaşımında DC bileşen, YEİ'ye oldukça benzemektedir.

Önerilen DCT ile yürüyüş örüntüsü üretme yaklaşımında, siluet çerçevesindeki piksel sayısı kadar 1-boyutlu DCT yapılır. Bir yürüyüş periyodu boyunca bir pikselin aldığı değerlerin DCT'si hesaplanır. Bütün pikseller için yapılan bu işlem sonucunda, elde edilen DC ve AC bileşenlerden ayrı ayrı yürüyüş örüntüleri üretilmiştir. Şekil 2.7'de görüldüğü gibi 4 farklı yürüyüş örüntüsü üretilmiştir. Birincisi piksel DCT'lerinin DC bileşenleri, ikincisi ilk AC bileşenleri, üçüncüsü ikinci AC bileşenleri bir araya getirilerek oluşturulmuştur. ACTOP örüntüsü AC1 ve AC2 de kullanılmamış AC bileşenlerin ilk yarısının toplanmasıyla elde edilmiştir.

Şekil 2.7'de aynı kişinin aynı yürüyüş örüntüsü için 2'şer örneği görülmektedir. Şekilde sütunlarda 4 farklı yürüyüş örüntüsü üretme yaklaşımlarının örnek görüntüleri ayrı ayrı verilmiştir. Şeklin üst kısmında USF V1 veritabanı eğitim setinden 2463, alt kısmında aynı eğitim setinden 3633 numaralı kişinin yürüyüş örüntüleri vardır.

DCT ile yürüyüş örüntüsü üretme yaklaşımımız, her piksel için 1-boyutlu DCT dönüşüm gerektirdiğinden maliyetlidir.



řekil 2.7. DCT Bileřenleri ile yürüyüş üretme, (a) DC bileřen, (b) AC bileřenlerin birincisi, (c) AC bileřenlerin ikincisi, (d) AC bileřenlerin, AC bileřen sayısının yarısına kadar toplamı

2.3. Örüntülerden Özellik Çıkarımı

Verileri en küçük boyutta ayırıcı özellikleri ile temsil etme işlemine özellik çıkarımı denir. Eğitim kümesinde, her örneğe ait olan ortak özellikler ve tekrarlı bilgilerin olmasına karşılık çeşitli analiz yöntemleri ile eğitim verisinin rank sayısı hesaplanır. Hesaplanan rank sayısı, verinin tekrarsız temsil edilebileceği boyut sayısını ifade eder. Analiz sonucunda üretilebilen boyutlar birbirine dik yöneylerdir ve yöneylere izdüşürülen veriler küçük boyutlarda tekrarsız temsil edilebilir. Bu işleme özuzaya eşleştirme, eşleştirmeyi sağlayan analiz sonucu özvektörlerden üretilmiş yöneyler topluluğuna, eşleme veya

dönüşüm matrisi denir. Örüntü tanıma çalışmalarında, eğitim kümesinden elde edilen eşleme matrisi, eğitim ve test örneklerinin özuzaydaki temsillerini veya kısaca özniteliklerini bulmak için kullanılır.

Bir veri kümesinin temel bileşenlerini bulmak, o verinin daha küçük boyutlarda temsil edilebilmesini yani dolaylı olarak sıkıştırılmasını sağlar. Örüntü tanıma problemlerinde bu işlem öznitelik çıkarımı için kullanılmaktadır. Diğer taraftan, örüntü tanıma deneylerinde bir sınıfa ait birbirine az benzeyen birden fazla örnek olabilir ve danışmansız TBA yöntemi, sınıfları tam olarak temsil edemeyebilir. Bu nedenle danışmanlı yaklaşımlarla öznitelik uzayını belirlemek, öznitelik çıkarımı için daha uygundur [136]. Doğrusal uzayda yapılan bu işlem doğrusal ayrıştırma analizi (DAA) diye geçer [136]. Bu noktada TBA için tekrarlı bilgileri eleyen boyut indirgeme, DAA içinse veriyi küçük boyutlarda temsil eden ayrıştırma aracı olarak düşünmek daha doğrudur. Nitekim DAA örnek sayısının az, boyut sayısının büyük olduğu durumlarda her zaman doğrudan hesaplanamaz. Bu probleme örüntü tanımada az örnek sayısı (sample small size (SSS), AÖS) problemi denir [137, 138]. AÖS problemini çözmek için DAA, TBA uzayında, TBA+DAA şeklinde uygulanabilir. Daha geliştirilmiş yöntemlerde AÖS problemi doğrudan DAA, boş uzay analizi gibi yaklaşımlarla çözülmüştür [137, 138].

Deneylerde eğitim kümesindeki toplam örnek sayısı genellikle boyut sayısından daha küçüktür. Eğitim verisi matrisinin rankı ise $r < \min(\text{örnek sayısı}, \text{boyut sayısı})$ 'dır. Doğrusal Cebirde $\overline{XX}^T$ ile $\overline{X}^T \overline{X}$ 'nin ranklarının ve özdeğerlerinin aynı olduğu konusunda yaygın bir teorem vardır. Buna ek olarak $\overline{XX}^T$ 'nin özvektörleri, $\overline{X}$ matrisi ile çarpılan ve normalize edilen $\overline{X}^T \overline{X}$ özvektörleri ile aynıdır. Bu teorem ayrıştırma analizleri için kullanılmaktadır [138].

Çalışmalarımızda, ayrıştırma analizlerinde yürüyüş örüntüleri doğrudan ve 2-boyutlu DCT'si alındıktan sonra kullanılmıştır. Elde edilen deneysel sonuçlar, yürüyüş örüntülerinin 2B-DCT'sini almanın performansı artırmadığını göstermiştir.

2.3.1. Doğrusal Ayrıştırma Analizleri

Verilerin, bulunduğu uzayda ayrıştırmak için analiz edilmesine doğrusal uzayda ayrıştırma analizi denir. Genel Bilgiler Bölümünde açıklanan TBA, DAA birer doğrusal

ayırıştırma analizidirler. Burada AÖS problemini çözen TBA+DAA ve D-DAA yaklaşımları incelenmiştir.

2.3.1.1. Direk Doğrusal Ayırıştırma Analizi

D-DAA ayırıştırma analizi, DAA'nın özel hali olup sınıflar arasındaki varyansların boş uzayını kaldırarak AÖS problemini çözer [137]. Bu analizde, sınıflar arası varyansların (S_b) sınıf içi varyanslara (S_w) oranını maksimize eden A eşleme matrisi, $A = A_{DAA} A_{TBA}$ şeklinde hesaplanmıştır.

$$AS_w A^T = I, \quad AS_b A^T = A \quad (2.9)$$

Öyle bir A matrisi bulunsun ki; (2.9)'daki eşitlikler sağlanabilsin. Geleneksel olarak bu işlem S_w 'nin boş uzayının atılması ile yapılır. Ancak D-DAA yaklaşımında önce S_b 'nin boş uzayı kaldırılır. Böylece S_w 'nin ayırıcı özellikler barındırdığı iddia edilen boş uzayı saklanmış olur [137].

Sınıf sayısının C , örnek sayısının n , i .sınıftaki örnek sayısının n_i ve örneklerin boyut sayısının l olduğu durumda, D-DAA'nın işlem adımları aşağıdaki gibi verilebilir [137]:

1. Adım: S_b 'nin köşegenleştirilmesi

$$S_b = \sum_{i=1}^C n_i (\mu_i - \mu)(\mu_i - \mu)^T = \Phi_b \Phi_b^T, \quad (l \times l) \quad (2.10)$$

$$\Phi_b = [\sqrt{n_1}(\mu_1 - \mu), \sqrt{n_2}(\mu_2 - \mu), \dots] \quad , \quad (l \times C) \quad (2.11)$$

Kısım 2.3'teki teorem uygulanırsa, köşegenleştirme için $\Phi_b^T \Phi_b$ 'nin özdeğer ve özvektörleri bulunur. $m < C$ olmak üzere sıfırdan büyük özdeğer sayısı olsun. Z özdeğerlerle normalleştirilmiş $\Phi_b^T \Phi_b$ 'nin özvektörlerinin ilk m sütunu olarak alınır. Burada S_b ve Φ_b sırasıyla (2.10) ve (2.11) denklemleri ile hesaplanır.

2. Adım : S_w nin yeni uzayda köşegenleştirilmesi: Bu adımda $Z^T S_w Z$ 'nin öz-analizi yapılır.

$$S_w = \sum_i (x_i - \mu_{ki})(x_i - \mu_{ki})^T = \Phi_w \Phi_w^T \quad (2.12)$$

$$\Phi_w = [(x_1 - \mu_{k1}), (x_2 - \mu_{k2}), \dots] \quad , \quad (l \times n) \quad (2.13)$$

$$Z^T S_w Z = Z^T \Phi_w \Phi_w^T Z = (\Phi_w^T Z)^T \Phi_w^T Z \quad (2.14)$$

$$U^T Z^T S_w Z U = D_w \quad (2.15)$$

(2.15)'e göre bulunan özdeğerler (D_w) sıfır içerebilir. Özellikle sıfır içeren değerler saklanıp büyük özdeğerlere karşılık gelen özvektörlerden eleme yapılarak amaç fonksiyonunun maksimizasyonu sağlanır.

w eleme yapıldıktan sonra kalan özdeğer sayısı olsun.

$$A = A_{DAA} A_{TBA} = U^T Z^T \quad (2.16)$$

$$\dot{x} \leftarrow D_w^{-\frac{1}{2}} A x \quad (2.17)$$

3. Adım: Öznitelik uzayına eşleme matrisi (2.16)'daki gibi hesaplanır. Bir örneğe ait öznitelik hesaplanırken (2.17) izdüşümü yapılmaktadır. Bu durumda eşleme matrisini (2.18)'deki gibi yeniden düzenleyip yeni eşleme matrisi ile doğrudan izdüşüm alınabilir.

$$A' = D_w^{-\frac{1}{2}} A_{DAA} A_{TBA} = D_w^{-\frac{1}{2}} U^T Z^T \quad (2.18)$$

Burada elde edilen $(l \times w)$ boyutlarındaki eşleme matrisi ile öznitelik uzayına izdüşürülen öznitelik vektörünün uzunluğu w olur.

2.3.1.2. TBA+DAA

D-DAA özellik çıkarma yöntemindeki tanımlamalar geçerli olmak üzere, TBA uzayında DAA analizi ile dönüşüm matrisi W_{opt} (2.21) denklemi ile verilmiştir [138].

$$W_{TBA} = \arg \max_w |W^T S_t W|, \quad S_t = S_w + S_b \quad (2.19)$$

$$W_{DAA} = \arg \max_w \frac{|W^T W_{TBA}^T S_b W_{TBA} W|}{|W^T W_{TBA}^T S_w W_{TBA} W|} \quad (2.20)$$

$$W_{opt} = W_{TBA} W_{DAA} \quad (2.21)$$

S_w 'nin tersinin olmadığı durumlarda verinin temel bileşenleriyle oluşturulan düşük boyutlu uzayda tersi alınabilir. Bu nedenle verilerin W_{TBA} ile TBA uzayına eşlemesi yapılmıştır. Böylece amaç fonksiyonunun çözümü gerçekleştirilebilir. TBA+DAA yöntemi ile elde edilen eşleme matrisindeki özvektör sayısı (boyut sayısı) sınıf sayısından büyük olabilir.

2.3.1.3. 2-Boyutlu Temel Bileşen Analizi

2B-TBA, TBA'nin örneklerin 2-boyutlu halde iken uygulanmasıdır. $A_1, A_2, \dots, A_M$, eğitimde kullanılmak üzere M adet örnek olsun. Eğitim örneklerinden dönüşüm matrisini (X) hesaplamak ve TBA uzayına her bir örneği $Y = AX$ dönüşümü ile taşımak özniteliklerin çıkartılmasına denktir [151,152].

Formül (2.22)'te 2B-TBA için toplam dağılım matrisi (G_t) hesaplanmıştır. Sonraki aşamada TBA da olduğu gibi G_t 'nin öz-uzayı bulunmuştur (2.23). G_t 'nin sıfırdan büyük özdeğerlerine karşılık gelen d tane özvektör standart TBA'da olduğu gibi, özuzaya eşleme matrisinin (A) oluşturulmasında kullanılmıştır. 2B-TBA uzayında izdüşüm, yine 2-boyutlu olarak yapılır. Her bir örnek için öznitelikler (X), 2-boyutlu örnek olmak üzere (2.24)'teki gibi hesaplanır. (2.24)'te çıkarılan öznitelikler de 2-boyutludur.

$$G_t = \frac{1}{M} \sum_{j=1}^M (A_j - \bar{A})^T (A_j - \bar{A}) \quad (2.22)$$

$$J(X) = X^T G_t X \quad (2.23)$$

$$Y = AX \quad (2.24)$$

Bu tez çalışmasında örneklerin boyutlarında değişiklikler yapılarak 2B-TBA'nın ayırıştırma performansı incelenmiştir. Bunun için her bir görüntünün alt kısmı, üst kısmın sağına veya sağ kısım görüntünün alt kısmına eklenmiştir. Böylece aynı veri ile çeşitli boyutlarda görüntüler üretilmiştir. Bu çalışma [152]'da sağdan ve soldan yapılan 2B-TBA sonuçlarının farklı olmasından hareketle yapılmıştır.

2.3.2. Doğrusal Olmayan Ayırıştırma Analizleri

Doğrusal olmayan verilerin doğrusal uzayda ayrıştırılması başarısız olduğundan, dolaylı yoldan doğrusal olmayan uzayda ayırıştırma işlemi Genel Bilgiler bölümünde değinildiği gibi çekirdek hilesi yöntemi ile gerçekleştirilmiştir. Bu çalışmada doğrusal olmayan uzaya eşleme için polinom ve Gauss çekirdek fonksiyonları kullanılmıştır. Gauss çekirdek fonksiyonun σ parametresinin otomatik belirlenmesi için deneysel olarak bir denklem belirlenmiştir.

2.3.2.1. Gauss Çekirdek Parametresinin Kestirimi

Gauss çekirdeğinin σ parametresini otomatik belirlemek için eğitim örneklerinden oluşturulan çekirdek matrisinden (gram matris) faydalanılmıştır. Gauss fonksiyonu kullanıldığında gram matris $[0,1]$ aralığında değerler alır ve dağılım σ parametresine göre kümelenir veya saçılır. Deneylerde σ parametresi otomatik değiştirilerek gram matrisin ortalaması hesaplanmıştır ve elde edilen başarı sonuçları ortalamaya göre

değerlendirilmiştir. Deneysel çalışmalar sonucunda, gram matrisin ortalama değerinin $\frac{1}{4}$ olduğu durumlarda en başarılı sonuçlar elde edilmiştir. Bundan hareketle (2.25) denklemi σ parametresinin otomatik hesaplanması için üretilmiştir. Çalışmada tüm çekirdekli öznelik çıkarıcılarda σ parametresinin kestiriminde (2.25) denklemi kullanılmıştır.

$$\sigma = \frac{1}{n} \sqrt{\sum_i^n \sum_j^n \|x_i - x_j\|^2} \quad (2.25)$$

Literatürde çekirdek parametrelerinin otomatik seçimi için kesin bir mekanizma yoktur. Genellikle eğitim kümesinden çapraz-değerlendirme ile parametre kestirimi yapılmaktadır [132, 145, 153]. Deneysel çalışmalarımızda, önerilen σ parametresi kestirme yöntemi çoğunlukla en iyi sonucu vermiştir.

2.3.2.2. Çekirdekli Direk Ayırıştırma Analizi

DAA'nin doğrusal olmayan uzayda yapılmasına ÇAA denilmektedir. Nitekim çekirdekli ayırıştırma analizinde de DAA'da olduğu gibi Φ_w matris tersinin alınamama problemi sıkça görülmektedir. Bu problemin çözümü DAA'dakine benzer şekilde yapılabilir. Yani çekirdekli direk ayırıştırma analizi (ÇDAA), AÖS problemi oluşmadan doğrusal olmayan uzayda, doğrusal ayırıştırma analizi yapmaya olanak tanır. Ayırıştırma analizi için maksimize edilecek amaç fonksiyonu (2.36)'teki gibi verilsin. Bu durumda ÇDAA'nın işlem adımları şöyle verilebilir [155]:

$$\Psi = \arg \max_{\Psi} \frac{|\Psi^T S_b \Psi|}{|\Psi^T S_w \Psi|} \quad (2.26)$$

1) Özellik uzayında S_b 'nin özlük analizi:

F uzayında S_b (2.27) şeklinde verilsin.

$$S_b = \sum_{i=1}^c \left(\sqrt{\frac{C_i}{L}} (\bar{\phi}_i - \bar{\phi}) \right) \left(\sqrt{\frac{C_i}{L}} (\bar{\phi}_i - \bar{\phi}) \right)^T = \sum_{i=1}^c \tilde{\phi}_i \tilde{\phi}_i^T = \Phi_b \Phi_b^T \quad (2.27)$$

Burada $\tilde{\phi}_i = \sqrt{\frac{C_i}{L}}(\bar{\phi}_i - \bar{\phi})$ ve $\phi_b = [\tilde{\phi}_1 \dots \tilde{\phi}_c]^T$ 'dir. Özellik uzayında boyut sayısı çok büyük hatta sonsuz olabileceğinden özdeğer hesabı ($C \times C$) boyutlu $\Phi_b \Phi_b^T$ matrisinden dolayı olarak yapılabilir [138, 155]. C sınıf sayısı olmak üzere oluşabilecek sıfırdan büyük özdeğer sayısı (m) en fazla $C-1$ 'dir.

$\Phi_b \Phi_b^T$ 'in hesaplanması F uzayında iç çarpımın yapılmasını gerektirir. Bu işlem Mercer şartlarını sağlayan çekirdek fonksiyonları ile yapılır. Z_l ve Z_h gibi iki keyfi sınıf için bir ($C_l \times C_h$) boyutlarında iç çarpım matrisi K_{lh} (2.28) denklemindeki gibi tanımlanabilir.

$$K_{lh} = k_{ij} \quad , \quad i = 1, \dots, C_l \quad , \quad j = 1, \dots, C_h \quad \text{ve} \quad k_{ij} = k(z_{li}, z_{hj}) = \phi_{li} \phi_{hj} \quad (2.28)$$

Tüm $\{Z_i\}_{i=1}^C$ sınıfları için, L örnek sayısı olmak üzere ($L \times L$) boyutlarındaki çekirdek (K) matris (2.29)'deki denklemden tanımlanmıştır.

$$K = (K_{lh}) \quad , \quad l, h = 1, \dots, C \quad (2.29)$$

Son olarak $\Phi_b \Phi_b^T$ (2.30) 'daki gibi ifade edilebilir.

$$\Phi_b \Phi_b^T = \tilde{\phi}_i^T \tilde{\phi}_j = \frac{\sqrt{C_i C_j}}{N} (\bar{\phi}_i^T \bar{\phi}_j - \bar{\phi}_i^T \bar{\phi} - \bar{\phi}^T \bar{\phi}_j + \bar{\phi}^T \bar{\phi}) \quad (2.30)$$

(2.30) denkleminin matrislerin çarpımı şeklinde (2.31) denkleminle ifade edilebilir.

$$\Phi_b \Phi_b^T = \frac{1}{L} B \left(A_{LC}^T K A_{LC} - \frac{1}{L} (A_{LC}^T K 1_{LC}) - \frac{1}{L} (1_{LC}^T K A_{LC}) + \frac{1}{L^2} (1_{LC}^T K 1_{LC}) \right) B \quad (2.31)$$

Burada; $B = \text{diag}[\sqrt{C_1}, \sqrt{C_2}, \dots, \sqrt{C_c}]$, 1_{LC} bütün terimleri bir olan $L \times C$ boyutlarında matris, $A = \text{diag}[a_{c1}, a_{c2}, \dots, a_{cc}]$, $L \times C$ boyutlarında blok köşegenel matris, a_{ci} bütün terimleri $\frac{1}{C_i}$ olan $C_i \times 1$ boyutunda vektördür.

$\Phi_b \Phi_b^T$ 'nin özdeğer ve özvektör analizi yapılarak, λ_i özdeğerleri ve e_i ($i = 1 \dots C$) özvektörleri hesaplanır. $(\Phi_b \Phi_b^T)(\Phi_b e_i) = \lambda_i (\Phi_b e_i)$ olduğundan S_b 'nin özvektörleri

$v_i = \Phi_b e_i$ şeklinde elde edilir. S_b 'nin boş uzayını kaldırmak için sıfırdan büyük özdeğerlere karşılık gelen özvektörler kullanılır. Sıfırdan büyük özvektör sayısı en fazla $m(\leq C-1)$ tanedir ve S_b 'nin özdeğerleri (2.32) denklemiyle bulunur.

$$V^T S_b V = \Lambda_b = \text{diag}[\lambda_1^2, \lambda_2^2, \dots, \lambda_m^2] \quad (2.32)$$

Burada; $V = [v_1, v_2, \dots, v_m] = \Phi_b E_m$ sıfırdan büyük özdeğerlere karşılık gelen özvektörlerdir.

2) Özellik uzayında S_w 'nin özlük analizi:

$U = V \Lambda_b^{-1/2}$ olsun. S_b ve S_w 'yi U 'nun içerdiği alt uzaya izdüşürürsek $U^T S_b U = I$ olur ve $U^T S_w U$ (2.43) denklemindeki gibi hesaplanır.

$$U^T S_w U = (E_m \Lambda_b^{-1/2})^T (\Phi_b^T S_w \Phi_b) (E_m \Lambda_b^{-1/2}) \quad (2.33)$$

K çekirdek matrisi kullanılarak $(\Phi_b^T S_w \Phi_b)$ ifadesi (2.34) denklemiyle verilmiştir.

$$\Phi_b^T S_w \Phi_b = \begin{bmatrix} \tilde{\phi}_1 & \dots & \tilde{\phi}_c \end{bmatrix} S_w \begin{bmatrix} \tilde{\phi}_1 & \dots & \tilde{\phi}_c \end{bmatrix} = \tilde{\phi}_i^T S_w \tilde{\phi}_j, \quad i, j = 1, \dots, C \quad (2.34)$$

(2.35) eşitliğinde, (2.34) denkleminin açık hali verilmiştir ve (2.35) denklemi (2.38) denklemiyle matrislerin çarpımı şeklinde ifade edilebilir.

$$\begin{aligned} \tilde{\phi}_i^T S_w \tilde{\phi}_j &= \frac{1}{L} \tilde{\phi}_i^T \left(\sum_{l=1}^C \sum_{k=1}^C (\phi_{lk} - \bar{\phi}_l)(\phi_{lk} - \bar{\phi}_l)^T \right) \tilde{\phi}_j \\ &= \frac{1}{L} \tilde{\phi}_i^T \left(\sum_{l=1}^C \sum_{k=1}^C \phi_{lk} \phi_{lk}^T - \sum_{l=1}^C \bar{\phi}_l \left(\sum_{k=1}^{C_l} \phi_{lk}^T \right) - \sum_{l=1}^C \left(\sum_{k=1}^{C_l} \phi_{lk}^T \right) \bar{\phi}_l^T \right. \\ &\quad \left. + \sum_{l=1}^C C_l \bar{\phi}_l \bar{\phi}_l^T \right) \tilde{\phi}_j \\ &= \frac{1}{L} \left(\sum_{l=1}^C \sum_{k=1}^C \tilde{\phi}_i^T \phi_{lk} \phi_{lk}^T \tilde{\phi}_j - \sum_{l=1}^C C_l \tilde{\phi}_i^T \bar{\phi}_l \bar{\phi}_l^T \tilde{\phi}_j \right) \end{aligned} \quad (2.35)$$

(J1)
(J2)

$$J1 = \frac{1}{L} B \left(A_{LC}^T K K A_{LC} - \frac{1}{L} (A_{LC}^T K K 1_{LC}) - \frac{1}{L} (1_{LC}^T K K A_{LC}) + \frac{1}{L^2} (1_{LC}^T K K 1_{LC}) \right) B \quad (2.36)$$

$$J2 = \frac{1}{L} B \left(A_{LC}^T K W K A_{LC} - \frac{1}{L} (A_{LC}^T K W K 1_{LC}) - \frac{1}{L} (1_{LC}^T K W K A_{LC}) + \frac{1}{L^2} (1_{LC}^T K W K 1_{LC}) \right) B \quad (2.37)$$

Burada $W = \text{diag}[w_1, w_2, \dots, w_c]$ $L \times L$ boyutlarında blok köşegenel matris ve w_i , bütün terimleri $\frac{1}{C_i}$ olan $C_i \times C_i$ boyutlarında matristir.

$$\Phi_b^T S_w \Phi_b = \left(\tilde{\phi}_i^T S_w \tilde{\phi}_j \right)_{i,j=1,\dots,C} = \frac{1}{L} (J1 - J2) \quad (2.38)$$

$m \times m$ 'lik $U^T S_w U$ matrisi köşegenleştirilip artan sıralanmış özdeğerlerine (λ'_i) karşılık gelen özvektörler (p_i) bulunur. Büyük özdeğerlere karşılık gelen M adet $P = [p_1, p_2, \dots, p_m]$ özvektörlerini seçelim. Buradan (2.39) denklemi tanımlanabilir.

$$Q = UP \quad (2.39)$$

Q matrisi ile S_w 'nin özdeğerleri (2.40)'tan bulunur.

$$Q^T S_w Q = \Lambda_w = \text{diag}[\lambda'_1, \lambda'_2, \dots, \lambda'_M] \quad (2.40)$$

Son olarak (2.26) denklemini maksimize eden F özellik uzayında düşük boyutlu alt uzaya eşleme matrisi (2.41)'denklemini ile hesaplanabilir.

$$\Gamma = Q \Lambda_w^{-1/2} \quad (2.41)$$

3) Özellik Çıkarımı:

Herhangi bir giriş örüntüsünün (z), seçilmiş özvektörlerle öznilelik uzayına izdüşürülmesi ile özellik çıkarımı ve boyut azaltımı (2.42) şeklinde yapılabilir.

$$y = \Gamma^T \phi(z) = (E_m \Lambda_b^{-1/2} P \Lambda_w^{-1/2})^T (\Phi_b^T \phi(z)) \quad (2.42)$$

Burada $(\Phi_b^T \phi(z)) = [\tilde{\phi}_1, \tilde{\phi}_2, \dots, \tilde{\phi}_c] \phi(z)$ olduğundan;

$$\tilde{\phi}_i^T \phi(z) = \left(\sqrt{\frac{C_i}{L}} (\bar{\phi}_i - \bar{\phi}) \right)^T \phi(z) = \sqrt{\frac{C_i}{L}} \left(\frac{1}{C_i} \sum_{m=1}^{C_i} \phi_{im}^T \phi(z) - \frac{1}{L} \sum_{p=1}^C \sum_{q=1}^{C_p} \phi_{pq}^T \phi(z) \right) \quad (2.43)$$

$$\Phi_b^T \phi(z) = \frac{1}{\sqrt{L}} B \left(A_{LC}^T \gamma(\phi(z)) - \frac{1}{L} 1_{LC}^T \gamma(\phi(z)) \right) \quad (2.44)$$

(2.44)'teki $\gamma(\phi(z)) = [\phi_{11}^T \phi(z) \ \phi_{12}^T \phi(z) \ \dots \ \phi_{cc}^T \phi(z)]^T$ $L \times 1$ 'lik vektördür. (2.42) ve

(2.44) birleştirilirse (2.45) denklemi elde edilir.

$$y = \Theta \gamma(\phi(z)) \quad (2.45)$$

$$\Theta = \frac{1}{\sqrt{L}} \left(E_m \Lambda_b^{-1/2} P \Lambda_w^{-1/2} \right)^T \left(B(A_{LC}^T - \frac{1}{L} 1_{LC}^T) \right) \quad (2.46)$$

(2.46) denklemi z 'nin düşük boyutlu uzaya izdüşümünü (y) doğrudan hesaplamak için kullanılabilir.

Giriş olarak her eğitim örneği (z), L -boyutlu bir vektör olarak alınıp, daha düşük boyutta y olarak çıkışa veren ÇDAA yaklaşımı işlem adımlarını özet olarak verirsek [155]:

1. Çekirdek matrisi K 'yi hesapla (eşitlik 2.29),
2. Eşitlik (2.30)'a göre $\Phi_b^T \Phi_b$ 'yi hesaplayıp E_m ve Λ_b 'yi bul,
3. Eşitlik (2.33)'den $U^T S_w U$ 'yu hesaplayıp, P ve Λ_w 'yi bul,
4. Θ 'yi hesapla ve dönüşüm matrisini bul (2.36),
6. z için en uygun öznitelik temsili $y = \Theta \gamma(\phi(z))$ 'dir.

2.4. Örüntü Sınıflandırma

Örüntü tanıma problemlerinde EYK sınıflandırıcısı kolay uygulanabilirliği ve hızlı olması açısından yaygın bir şekilde kullanılmaktadır. Bunun yanında son zamanlarda

DVM yaklaşımı sınıflandırma işlemlerinde oldukça popüler olmuştur. Çalışmada her iki yöntemde uygulanmış ve performans karşılaştırmaları yapılmıştır.

Doğrusal DVM yaklaşımı, doğrusal olmayanlara göre genellikle daha kötü sınıflandırma yapmaktadır. Doğrusal DVM'nin de başarılı olabilmesi için çekirdek parametrelerinin iyi ayarlanması gerekir. Deneylerde parametre seçimi yavaş ama performansı daha iyi olan yöntem ızgara-tarama yöntemi ile yapılmıştır. Bu DVM'nin öğrenme aşamasında oldukça zaman almasına sebep olmaktadır.

DVM öğrenme aşamasında eğitim verisindeki sınıf bilgilerini kullanmaktadır. Bu özellik Bölüm 1'de açıklandığı gibi EYK sınıflandırıcılarına da test verilerinin sınıf bilgileri de dahil olmak üzere dolaylı yoldan kazandırılmaktadır. Bu şekilde EYK kriterine göre sınıflandırmadaki başarı artışı, DVM ile sınıflandırmadaki yakalamış ve zaman zaman daha iyi sonuçlar vermiştir. Bundan hareketle DVM sınıflandırıcısında da test sınıf bilgisinin kullanılabilmesi düşünülmüştür. Çalışmamızda, DVM için test sınıf bilgisini kullanmak amacıyla, test sınıfındaki örneklerin sınıflandırılma karnesi tutulmuştur. Sınıflandırma karnesine göre en çok ait olunan sınıf, test sınıfının yeni etiketi olarak belirlenmiştir. Böylece DVM ile sınıflar arasındaki benzerlik incelemesi sağlanmıştır. Bu sınıflandırıcı tezde kDVM olarak geçmektedir.

2.4.1. EYK için Uzaklık Ölçütü

EYK kriterinde örnekler/sınıflar arasındaki uzaklığı ölçmek için işlem yükü açısından yaygın olarak öklid uzaklık ölçütü kullanılır. Çalışmada benzer şekilde iki vektör arasındaki açı uzaklık ölçütü olarak kullanılmıştır. Daha sonra vektörel açıya dayalı uzaklık ölçütü geliştirilerek kKAU uzaklık ölçütü önerilmiştir (2.47).

Önerilen yöntemde eğitim örneklerinden elde edilen özniteliklerinin ortalamasının çıkarıldığı eğitim ve test öznitelikleri arasındaki açı, uzaklık ölçütü olarak alınmıştır. Her öznitelikten, öznitelikler ortalaması çıkarıldığından bu yönteme, kaydırılmış kosinüs açı uzaklığı (kKAU) adı verilmiştir. kKAU (2.47)'deki gibi hesaplanır.

$$kKAU = 1 - \frac{(\vec{e} - \vec{\mu})(\vec{t} - \vec{\mu})}{\|\vec{e} - \vec{\mu}\| \|\vec{t} - \vec{\mu}\|}, \quad \vec{\mu} = \frac{1}{N} \sum_{k=1}^N \vec{e}_k \quad (2.47)$$

kKAU $[0,1]$ arasında değer alır. (2.47)'de, N , eğitim kümesindeki örnek sayısıdır. Vektörlerin boyut sayısı özniteliklerle eşdeğerdir. $\vec{e}$ ve $\vec{t}$ vektörleri, sırasıyla eğitim ve test örneklerinin öznitelikleridir.

2.4.2. Sınıflandırıcıya Giren Verilerin Normalize Edilmesi

LibSVM kütüphanesinde verilerin sınıflandırılmadan önce $[0,1]$ veya $[-1,1]$ aralığına getirilmesi özellikle belirtilmiştir [146]. Eğitim ve test verilerinin tutarlı olması için genel olarak bütün sınıflandırıcılarda normalizasyon gerçekleştirilmektedir.

Verilerin normalizasyonu, genellikle uzayın normalizasyonu ile gerçekleştirilir. Veri havuzundaki minimum ve maksimum değer seçilerek bütün veriler (2.48)'deki gibi normalize edilebilir.

$$V' = (V'_{tavan} - V'_{taban}) \left(\frac{V - \min V}{\max V - \min V} \right) + V'_{taban} \quad (2.48)$$

Burada V' normalize edilmiş veriyi, V'_{tavan} ve V'_{taban} sırasıyla normalize edilmiş verinin maksimum ve minimum değerleri, V , $\min V$ ve $\max V$ sırasıyla veri, verinin minimum ve maksimum değerleridir. Denklem (2.48) göre yapılan normalizasyonda verinin dağılımında hiçbir değişiklik olmaz.

Bu tez çalışmasında verilerin öznitelik boyutlarına göre normalizasyonu gerçekleştirilmiştir. Bunun için eğitim verisindeki öznitelik vektörlerinin maksimum ve minimum değerleri her bir boyut için bulunmuştur. Sonra her bir boyut bu değerlere göre istenen aralıkta normalize edilmiştir. Bu işlem denklem (2.49)'daki gibi gerçekleştirilebilir.

$$V'_i = (V'_{tavan} - V'_{taban}) \left(\frac{V_i - \min V_i}{\max V_i - \min V_i} \right) + V'_{taban} \quad (2.49)$$

Burada V'_i normalize edilmiş veriyi, V'_{tavan} ve V'_{taban} sırasıyla normalize edilmiş verinin maksimum ve minimum değerleri, V_i , $\min V_i$ ve $\max V_i$ sırasıyla veri, verinin minimum ve maksimum değerleridir.

3. BULGULAR VE İRDELEME

Bu bölümde, yürüyüşten kişi tanıma çalışmalarında literatürde kabul görmüş veritabanları üzerinde, önerilen yöntem ve yaklaşımlar için yapılan deneylerin sonuçları irdelenmektedir. Yöntemlerin daha önce yapılmış çalışmalarla karşılaştırmalarında, yayınlanmış sonuçların yanı sıra, performansları kabul görmüş bir kısım yürüyüş örüntüsü üretme ve özellik çıkarma yaklaşımlarının uygulamaları geliştirilerek sonuçlar değerlendirilmiştir.

Yürüyüş şekline dayalı kişi tanıma çalışmaları 3 temel aşamadan oluşur: 1) yürüyüş örüntüsü üretme, 2) özellik çıkarma ve 3) sınıflandırma. Birinci aşamada, örüntüler siluet dizilerinden üretildiğinden, siluetlerin belirlenmesine ve gürültü eliminasyonuna bağlı olarak farklı örüntüler oluşturulabilir. Bu nedenle önerilen örüntü üretme yaklaşımıyla (pCFEİ) beraber, performansının iyi olduğu bilinen YEİ örüntüleri de üretilmiştir. Yaklaşımlarımızı değerlendirmek için, yürüyüş örüntüleri (YEİ, pCFEİ), TBA ve ÇTBA yaklaşımlarıyla irdelenmiştir. İkinci aşamada, yürüyüş şekline dayalı örüntülerde denenmemiş özellik çıkarma yaklaşımları YEİ üzerinden değerlendirilmiştir. Çalışmalarımızda son aşama için kKAU uzaklık ölçütü yaklaşımı önerilmektedir. Bu yaklaşımın performansı YEİ ve pCFEİ örüntülerinden ölçülmüştür.


İlerleyen bölümlerde öncelikle, test sonuçlarının daha iyi irdelenmesi için, deneylerde kullanılan veritabanlarının karakteristikleri hakkında özet bilgi verilmiştir. Ardından özniteliklerin normalize edilmesinde, tarafımızdan önerilen öznitelik boyutlarına göre normalizasyon yaklaşımı değerlendirilmiştir. Sonra, EYK sınıflandırıcılarında kullanılan uzaklık ölçütlerinin, yürüme örüntülerindeki başarıları, önerilen kKAU ölçütüyle beraber değerlendirilerek, performansı daha iyi olanlar seçilmiş ve sonraki deneylerin sonuç gösterimlerinde kullanılmıştır. Sonraki kısımda yürüyüşten kişi tanıma amaçlı kullanılan özellik çıkarma yöntemlerinin avantaj ve dezavantajları, çeşitli yürüyüşler içeren veritabanları üzerinde yapılan deneylerle incelenmiştir. Bu aşamada, yürüyüş örüntülerinin DCT dönüşümü yapılarak frekans domeninde özellik çıkarma ve 2B-TBA'da görüntü boyutlarındaki değişimlerin etkisi araştırılmıştır. Daha sonra, YEİ ve pCFEİ örüntü üretme teknikleri ve bu alanda yayınlanmış çalışmaların sonuçları karşılaştırılmıştır.

3.1. Yürüyüş Veritabanları

2000’li yıllarda, 20-30 kişinin laboratuvar ortamındaki yürüme kayıtlarından oluşan veritabanları, daha sonraları, doğal durumları içeren ortamlarda, 150 kişiye varan mevcutlara ulaşmıştır. Günümüzde kullanılan yürüyüş veritabanlarında, farklı yönlerde, farklı kalınlıktaki elbiselerle, çanta gibi eşya taşıyan kişilerin farklı zamanda gerçekleştirdikleri yürüyüş kayıtları vardır. Deneylerde dört birim tarafından üretilmiş, çeşitli özellikler içeren veritabanları kullanılmıştır. Burada deney sonuçlarının tartışılabilmesi için veritabanlarının genel özellikleri verilmiştir. Yürüyüş veritabanları hakkında daha ayrıntılı bilgilere ekler kısmından erişilebilir.

3.1.1. CMU MoBo Yürüyüş Veritabanı

CMU MoBo yürüyüş veritabanı 25 kişinin kapalı ortamda, yürüme bandında yapmış olduğu hızlı, yavaş ve topla beraber normal yürümelerinden oluşur. Yürüme bandı etrafına altı tane sabit kamera yerleştirilmiştir. Deneylerde beş kameradan alınan hızlı ve yavaş yürüme görüntüleri kullanılmıştır.



Şekil 3.1. CMU yürüyüş veritabanında kullanılan yönler ve etiketlemeleri

Çalışmalarımızda, her bir kamera Şekil 3.1’teki V1, V2,...,V6 etiketlemeleriyle temsil edilmektedir. Deney isimleri; kameranın bakış yönü, eğitimdeki yürüme şekli, testteki

yürüme şekli biçiminde verilmiştir. Örneğin V1-HY deneyinde, V1 kameranın bakış yönünü, H eğitimin hızlı ve Y testin yavaş yürüyüşlerde yapıldığını ifade eder.

CMU veritabanında, her kişinin ilgili deney setinde en az 8 periyotluk yürüyüş imge dizisi vardır. Aksi belirtilmedikçe eğitim ve testte kullanılan bir bireye ait örnek sayısı sekizdir.

CMU veritabanı hız değişikliği olan yürüyüşlerde, kişi tanıma testleri için uygundur. Ancak yürüme bandı kullanıldığından yürüyüş serbestliği kısıtlanmıştır ve kişi sayısı azdır. Yine de, yaklaşımların ön değerlendirilmesinde kullanılmaktadır.

3.1.2. SOTON Yürüyüş Veritabanı

Çalışmalarımızda kullandığımız SOTON yürüyüş veritabanı, 116 kişinin dışarıda sağa ve sola doğru yapmış olduğu normal yürüyüşlerden oluşur. Her iki yön içinde kişilerin ortalama 8'er periyotluk yürüyüş silüetleri vardır. Yayınlanmış çalışmalarda, eğitim ve testler, aynı yöndeki yürüyüşlerde farklı sayılardaki örneklerle yapılmıştır. L1-L7, L2-L6, .., L7-L1 isimli deney setleri, “eğitimin yapıldığı yürüyüş yönü (L/R) ve eğitimde kullanılan örnek sayısı-testin yapıldığı yürüyüş yönü (L/R) ve testte kullanılan örnek sayısı” şeklinde ifade edilmiştir. Burada, L sola ve R sağa doğru yürüyüşü temsil etmektedir. SOTON yürüyüş veritabanı, eğitim ve testin aynı şartlarda olduğu durumların değerlendirilmesi için oldukça uygundur.

3.1.3. USF Yürüyüş Veritabanları

USF'nin, USF V1 ve USF V2 diye tanımlanan iki farklı yürüyüş veritabanı mevcuttur. Her iki versiyonda da ayakkabı, elbise değişikliği, eşya taşıma gibi farklı özellikte yürüyüşler vardır. Yürüyüşler beton ve çimen zeminlerde, elips şeklindeki bir yörüngede yapılmıştır. Kayıtlar elips yörüngesinin sağ ve sol kısmına sabit konuşturulmuş kameralarla oluşturulmuştur. USF V2'de ayrıca farklı zamanlarda yürüyüş kayıtları mevcuttur. Her bir oturumda kişilere ait 5 periyotluk yürüyüş dizisi mevcuttur. USF-NIST formatıyla belirlenmiş deney setlerine ait özellikler Tablo 3.1'de verilmiştir.

Tablo 3.1. USF Veritabanlarının USF-NIST formatı

Setler	Kişi Sayısı		Test setlerinin eğitim setinden farklı özellikleri
	USF V1	USF V2	
Eğitim seti (GAR)	71	122	Sağ yöndeki kameradan, çimde A-çeşit ayakkabı ile yapılan yürüyüş görüntüleri
Test set-A (GAL)	71	122	Yön
Test set-B (GBR)	41	54	Ayakkabı
Test set-C (GBL)	41	54	Yön, ayakkabı
Test set-D (CAR)	70	121	Zemin
Test set-E (CBR)	44	60	Zemin, ayakkabı
Test set-F (CAL)	70	121	Zemin, yön
Test set-G (CBL)	44	60	Zemin, yön, ayakkabı
Test set-H (GARB)	-	120	Çanta
Test set-I (GBRB)	-	60	Çanta, ayakkabı
Test set-J (GALB)	-	120	Çanta, yön
Test set-K (GRT2)	-	33	Zaman, ayakkabı, elbise
Test set-L (CRT2)	-	33	Zemin, zaman, ayakkabı, elbise

Tablo 3.1’de, USF veritabanı, V1 ve V2 versiyonlarına ait deney setlerinin özellikleri beraber verilmiştir. Veritabanlarındaki eğitim setleri V1 için 71 ve V2 için 122 kişiden oluşur. Eğitim seti olarak, çimde A-çeşit ayakkabı ile yapılan yürüyüşlerin sağdaki kamera kayıtları kullanılmıştır. USF V1, A-G, USF V2, A-L arasındaki test setlerinden oluşur. Tabloda görüldüğü gibi, setlerdeki kişi sayıları her iki versiyon için farklıdır. Özellikler sütununda, test setlerinin, eğitim setinden farklı özellikleri verilmiştir. Örneğin test G-seti için zemin, yön ve ayakkabı özellikleri belirtilmiştir. Eğitim seti, çimde, A-tipi ayakkabı ile sağdaki kamerayla oluşturulduğundan özellikler sütunundan, G-setinin beton zeminde, B-tipi ayakkabı ve sol kamerayla oluşturulduğu anlaşılır. Kullanılan bütün yürüyüş veritabanlarında olduğu gibi USF veritabanlarında da, test setlerinde bulunan her bireyin, eğitim setinde de kayıtları vardır. USF veritabanları, kişi sayısının fazla olması ve farklı yürüyüş özellikleri içermesi açısından en önemli yürüyüş veritabanlarından biridir.

3.1.4. CASIA Yürüyüş Veritabanları

CASIA'nın, CASIA-A (NLPR), CASIA-B ve CASIA-C olmak üzere üç farklı yürüyüş veritabanı vardır:

CASIA-A (NLPR) yürüyüş veritabanı : 20 kişinin açık ortamda sabit bir kamera önünde yapmış olduğu tek oturumluk kayıtlardan oluşur. Her kişinin, profilden, kameraya dik ve 45°'lik açılarla yürüyüşleri vardır. Kişiler, ileri-geri-ileri-geri şeklinde gittikleri kamera yönünde, her biri 2 periyotluk yürüme örüntüsünü oluşturabilecek normal yürüyüş yapmıştır. Deney setlerinde, profil V00, 45° 'lik açı yönü V45 ve kameraya doğru yürüyüş V90 olarak tanımlanmıştır. Her bir setteki ilk iki yürüyüş eğitim, geriye kalan 2 yürüyüş test verisi olarak kullanılmıştır.

CASIA-B yürüyüş veritabanı : 124 kişinin kapalı ortamda işaretlenmiş bir yol üzerindeki yürüyüş kayıtlarından oluşur. Yürüyüş alanı, 18°'lik açılarla yerleştirilmiş 11 tane kamera ile izlenmiştir. Tüm kişiler 6 kere normal, 2 kere çanta taşıyarak ve 2 kere mont gibi daha kalın bir giysi giyerek, en az iki yürüyüş örüntüsü oluşturacak kadar normal hızda yürüyüş yapmıştır. Belirlenmiş deney setleri:

- ilk 4 normal yürüyüş : eğitim seti (8 örnek içerir)
- son 2 normal yürüyüş : NM-set, (her kişi için 4 örnek içerir)
- 2 çanta taşıırken yürüyüş : BG-set, (her kişi için 4 örnek içerir)
- 2 elbise değiştirilerek yürüyüş : CL-set, (her kişi için 4 örnek içerir)

şeklinde yayınlanmış çalışmalarda belirlenmiştir [21].

CASIA-B veritabanının üretildiği alanda, kayıt alanının belirlenmesi için zemine ve duvara alan renginden farklı renkte işaretler konmuştur. Bu işaretler arasındaki mesafe en az 2 adımda kat edilmektedir. Ancak silüet olarak elde edilen görüntülerde, bu işaretler belirgin değildir ve kişilerin kayıt alanına giriş öncesi ve çıkış sonrası, 90°'den başlayarak diğer açılara doğru artan sayıda silüet imgesi vardır. Kayıt alanına girmeden ve çıktıktan sonra oluşan imgelerde, kişiler, ilgili açıdan daha farklı açılarda yürüyüş yapmıştır ve bu alanlardan üretilen silüetler, bozukluklar (kopmuş parçalar ve arka plandan gelen gürültüler) içerir. Açının geçerliliğini korumak ve bozuk silüetleri ayırmak için, setteki imge dizisinin ortasındaki silüetlerden 2 yürüyüş örüntüsü temsil edecek kadar silüet imgesi deney setine dahil edilmiştir. Deneylerimizde, 5 kişinin yürüyüş kayıtlarının tamamını elde edemediğimizden, 124 kişilik CASIA-B veritabanından 119 kişinin kayıtları

kullanılmıştır. CASIA-B yürüyüş veritabanı, 124 kişinin 11 farklı açıdan alınmış normal, eşya taşıma ve kalın elbise giyinerek oluşturduğu önemli bir yürüyüş veritabanıdır.

CASIA-C yürüyüş veritabanı : 153 kişinin, karanlıkta bir yönde yaptığı normal, hızlı, yavaş ve eşya taşımaları (çanta) yürüyüşlerinin kızılötesi kamera ile toplanan görüntülerinden oluşur. Her kişinin, 4 adet normal, 2 adet çantalı, 2 adet hızlı ve 2 adet yavaş yürüyüş kaydı vardır. Her bir yürüyüş en az 2-tam adımlık bilgi içerir. Eğitim ve test setleri şu şekilde verilmiştir:

- Eğitim seti : ilk 2 normal yürüme (4 örnek)
- NM test seti : sonraki 2 normal yürüme (4 örnek)
- BG test seti : çanta taşırken yapılan 2 adet yürüme (4 örnek)
- FQ test seti : hızlı yürürken alınan 2 adet yürüme (4 örnek)
- FS test seti : yavaş yürürken alınan 2 adet yürüme (4 örnek)

CASIA-C veritabanı karanlıkta, yürüyüş biyometrik özelliğinden kişi tanıma çalışmaları için 153 kişinin kayıtlarından oluşan önemli bir veritabanıdır.

3.2. Özniteliklerin Sınıflandırılması

Deneylerimizde, yürüyüş örüntülerinden çıkarılan özniteliklerin sınıflandırılması EYK ve DVM ile yapılmıştır. Kullandığımız EYK standart olup örnekler ve sınıflar arası uzaklıkların hesabına dayanır. Örnekler arası uzaklıkta, test örnekleriyle eğitim örnekleri arasında en çok benzeyenler eşleştirilir (denetimsiz sınıflandırma). Sınıflar arası uzaklıkta eğitim ve test sınıflarındaki bütün örneklerin benzeşim değerlerinden uzaklık hesabı yapılır (Bölüm 1.4.4).

Örnekler arasındaki uzaklık ÖÜ, AÖÜ, KAU ve tarafımızca önerilen kKAU uzaklık ölçütleriyle hesaplanmıştır. Bölüm 1.4.4'te anlatıldığı gibi sınıflar arasındaki uzaklıkların hesabında, örnekler arasındaki uzaklıkların ortalaması kullanılıyorsa, uzaklık ölçütlerine, “mn” ve medyanı kullanılıyorsa “md” şeklinde ön ekler yapılmıştır. Böylece EYK için denetimli ve denetimsiz toplam $I2=(4+4(mn)+4(md))$ uzaklık ölçütü yani 12 sınıflandırıcı üretilmiştir. Ayrıca DVM ve DVM de test sınıf bilgisini de kullanan, önerdiğimiz kDVM sınıflandırıcıyla, sınıflandırıcı sayımız 14'e yükselmiştir.


DVM sınıflandırıcısı için LibSVM kütüphanesini kullandığımızı daha önce belirtmiştik. LibSVM sınıflandırılacak verileri normalize edilmiş halde kabul etmektedir. Bazı durumlarda, kullanılan yazılım ve donanımlarda hesapsal sınır taşmaları oluşur ve

veriler deforme olur. Pratik uygulamalarda karşılaşılan bu durum, normalizasyon ile düzeltilir. Çalışmalarımızda ilk olarak standart normalizasyon uygulanmıştır. Daha sonra normalizasyon ile sınıflandırıcı başarısının artırılması düşünülmüş ve özniteliklerin boyutlarına göre normalizasyon denenmiştir. Yapılan deneyler sonucunda, normalizasyon işlemiyle performans artışı sağlanabileceği görülmüştür.

Bu kısımda normalizasyonla gelen performans artışının gözlemlendiği deney sonuçlarından örnekler verilmiştir. Daha sonra sınıflandırıcılar değerlendirilip, başarı performansı iyi olan 2 denetimli ve 2 denetimsiz sınıflandırıcı, öznitelik çıkarma ve örüntü üretme yaklaşımlarının sonuç sunumlarında kullanılmak üzere seçilmiştir.

3.2.1. Özniteliklerin Normalizasyonu

Öznitelik normalizasyonun sınıflandırıcılardaki etkisini incelemek amacıyla YEİ örüntüleri, TBA ve ÇTBA özellik çıkarım yaklaşımları kullanılarak, Şekil 3.2-3.5'te sonuçları verilen deneyler yapılmıştır.




Şekil 3.2. Özniteliklerin normalize edilmesi: CMU, V1-HY setinde YEİ örüntülerinden TBA ile çıkarılan özniteliklerin normalizasyonu

Şekil 3.2-3.5'te UN; uzaysal normalizasyonu, BN; boyutlara göre normalizasyonu, NY ise normalizasyon yapılmadığı durumları gösterir. Deney sunumlarında verilen başarı

oranı denetimli ve denetimsiz sınıflandırıcılarda farklı iki şekilde hesaplanır. Denetimsiz sınıflandırıcılarda, örnekler kıyaslandığı için başarı oranı, testte doğru tanınan örnek sayısının, testteki tüm örnek sayısına oranı şeklinde hesaplanmıştır. Denetimli sınıflandırıcılarda ise test sınıflarında doğru tanınan sınıfların, test edilen sınıf sayısına oranı, başarı oranını vermektedir.

Şekil 3.2-3.5'te sonuçları verilen deneylerde farklı veritabanları ve özellik çıkarıcılar kullanılmıştır. Böylece farklı veriler ve özellik çıkarıcılarla normalizasyon performansı incelenmiştir. Tüm şekillerin başlıklarında, kullanılan veritabanı ve özellik çıkarıcıların isimleri belirtilmiştir.


Şekil 3.2'de sonuçları verilen deneyde, CMU veritabanının V1 yönündeki kamera kayıtları kullanılmıştır. Deneyde, eğitim hızlı yürüyüşte ve test yavaş yürüyüşte yapılmıştır. TBA ile çıkarılan özniteliklerin sınıflandırılmasında, BN yaklaşımıyla tüm sınıflandırıcılarda %20 civarında performans artışı sağlanmıştır.




Şekil 3.3. Özniteliklerin normalize edilmesi: CASIA-B, Set-NM setinde YEİ örüntülerinden ÇTBA ile çıkarılan özniteliklerin normalizasyonu

Şekil 3.3'te, CASIA-B NM-seti, Şekil 3.4'te USF V1 A-seti ve Şekil 3.5'te USF V2 A-seti üzerinde sırasıyla ÇTBA, TBA ve ÇTBA özellik çıkarma yaklaşımlarıyla yapılan deneylerin sonuçları verilmiştir. Farklı yürüyüş şekilleri ve özellik çıkarma yaklaşımlarının kullanıldığı bu deneylerde, yine BN yaklaşımının performans artışı sağladığı gözlemlenmiştir. Şekillerden de görüldüğü gibi, mdÖÜ ve mnÖÜ sınıflar arası uzaklık

ölçütleri kullanıldığında BN yaklaşımının performans artışı daha az olmaktadır. Bunun sebebi Öklid uzaklığının doğrudan öznitelikler arasında hesaplanmasından kaynaklanabilir. AÖÜ, öznitelikleri normalize ettikten sonra, KAU ve kKAU ise özniteliklerin doğrultusuna göre uzaklığı hesapladığından, herhangi bir normalizasyon işlemi yapılmayan ÖÜ'na göre gürültünden daha az etkilenirler.



Şekil 3.4. Özniteliklerin normalize edilmesi: USF V1, Set-A setinde YEİ örüntülerinden TBA ile çıkarılan özniteliklerin normalizasyonu




Şekil 3.5. Özniteliklerin normalize edilmesi: USF V2, Set-A setinde YEİ örüntülerinden ÇTBA ile çıkarılan özniteliklerin normalizasyonu

Yürüyüş örüntülerinden kişi tanıma çalışmalarımızda öznelitliklerin boyuta göre ayrı ayrı normalize edilmesi yaklaşımında genel olarak performans artışı gözlemlenmiştir. Bu noktadan sonra verilen bütün deney sonuçlarında öznelitlik normalizasyonu, boyutlara göre yapılmıştır.

3.2.2. Uzaklık Ölçütlerinin ve Sınıflandırıcıların Karşılaştırılması


Sınıflandırıcılarda kullanılan ÖU, AÖU, KAU uzaklık ölçütlerinin, yayınlanmış çalışmalarda başarılı sonuçlar verdiği bilinmektedir. Bu uzaklık ölçütlerine ilave olarak, Bölüm 2.4.1’de kKAU uzaklık ölçütü tarafımızdan önerilmiştir. Şekil 3.6-3.11’de sonuçları verilmiş deneylerde, denetimli ve denetimsiz sınıflandırıcılar incelenmektedir. Toplam 14 sınıflandırıcının, farklı yürüyüş özelliklerine sahip veritabanlarında, YEİ ve pCFEİ örüntülerinden TBA, ÇTBA, D-DAA ve ÇDAA yaklaşımlarıyla çıkarılan özellikleri sınıflandırma performanslarına bakılıp, iyi olan 4 tanesi seçilmiştir. Bu tezde, deneylerin sunumlarında seçilen sınıflandırıcıların sonuçları üzerinden değerlendirme yapılacaktır.




Şekil 3.6. Uzaklık ölçütlerinin karşılaştırılması: SOTON veritabanında, TBA ile çıkarılan öznelitliklerin EYK yaklaşımıyla sınıflandırılması

Şekil 3.6’da, denetimsiz (sınıf bilgisinin kullanılmadığı) uzaklık ölçütleri (ÖU, AÖU, KAU, kKAU), SOTON veritabanında YEİ örüntülerinden TBA yaklaşımıyla çıkarılan öznelitliklerin EYK ile sınıflandırılmasında kullanılmıştır. Sola yürüyüşlerin, ilk 2 örneği eğitim-sonrakiler test; ilk 3 örnek eğitim sonraki 5 örnek test; ilk 5 örnek eğitim sonraki 3

örnek test ve kümenin yarısı eğitim diğer yarısı test verisi olarak deneyler yapılmıştır. Oldukça düzgün silüetlere sahip SOTON veritabanında yapılan deneylerde, denetimsiz uzaklık ölçütlerinden kKAU ile en iyi sınıflandırma yapılmıştır.




Şekil 3.7. Uzaklık ölçütlerinin karşılaştırılması: USF V2 veritabanında, ÇTBA ile öznitelik çıkartılarak EYK yaklaşımıyla sınıflandırılması



Şekil 3.8. Uzaklık ölçütlerinin karşılaştırılması: USF V2 veritabanında, ÇDAA ile öznitelik çıkartılarak EYK yaklaşımıyla sınıflandırılması


Şekil 3.7’de USF V2 veritabanı üzerinde YEİ örüntüsü oluşturulup ÇTBA ile çıkarılan özniteliklerin denetimsiz uzaklık ölçütlerinin kullanıldığı EYK ile sınıflandırılma sonuçları verilmiştir. Bozuk silüetleri çok olan USF’de yapılan 12 testlik deneyde, en iyi performanslı denetimsiz sınıflandırmalar, yine kKAU ile sağlanmıştır. Şekil 3.8, yürüyüş

örüntüsünün pCFEİ ve özellik çıkarımının ÇDAA ile aynı veritabanında yapılan deneyin sonuçlarını göstermektedir. Sonuçlarda yine, genel olarak kKAU ile daha iyi performans elde edilmiştir.




Şekil 3.9. Sınıflandırıcıların karşılaştırılması: USF V1 veritabanında YEİ örüntülerinden, ÇTBA ile çıkarılan özneliliklerin sınıflandırılması

Şekil 3.9 ve 3.10’da denetimli sınıflandırıcıların karşılaştırılma deneylerinin sonuçları verilmiştir. Deneylerde sırasıyla USF V1 veritabanı YEİ ve ÇTBA ile, CASIA-B veritabanı pCFEİ ve ÇDAA ile kullanılmıştır. Deneylerde DVM’nin parametre kestirimi ızgara-tarama yaklaşımı ile yapılmıştır. Izgara-tarama, parametrelerin belli aralıklarda küçük adımlarla değiştirilmesi şeklinde gerçekleştirilmiştir. Izgara-tarama ile kestirilen parametreler tarafımızca önerilen kDVM yaklaşımı için de kullanılmıştır. Her iki deneyde de elde edilen sonuçlardan, sınıflandırmada iyi performans verdiği bilinen DVM yaklaşımının, yürüyüş tanımda, EYK sınıflandırıcıları karşısında, beklenen performansı vermediği gözlemlenmiştir. Standart Öklid dışındaki diğer sınıflandırıcılar, birbirine yakın, en iyi performanslı sonuçları vermiştir. DVM’nin kötü performansı, ayrıştırmanın iyiliğinden kaynaklanabilir.



Şekil 3.10. Sınıflandırıcıların karşılaştırılması: CASIA-B veritabanı, 90°'lik (profil) kamera yönünde pCFEİ örüntülerinden ÇDAA ile çıkarılan özneliklerin sınıflandırılması



Şekil 3.11. Sınıflandırıcıların karşılaştırılması: USF V2 veritabanında her sınıftan bir pCFEİ örüntü örneği alınarak, ÇTBA ile çıkarılan özneliklerin sınıflandırılması

DVM'nin, eğitim kümesindeki sınıf bilgisini kullanan denetimli bir sınıflandırıcı olduğu bilinmektedir. DVM'yi denetimsiz yapmak için eğitim kümesinde her sınıftan birer

örnek alınarak, Şekil 3.11’de sonuçları verilen deney yapılmıştır. Deneyde USF V2 veritabanında pCFEİ üzerinden ÇTBA ile özellikler çıkarılmış ve denetimsiz sınıflandırıcılarla tanıma yapılmıştır. Denetimsiz DVM’nin de beklenen performansı göstermediği görülmüştür. Deneyde en iyi performans kKAU tarafından kaydedilmiştir.

Şekil 3.6-3.11’deki sonuçların toplu değerlendirilmesinde, DVM’nin parametre kestirimi, uzun eğitim süresine sahip olması yanında yürüyüş örüntüleri için beklenen performansı gösteremediği görülmektedir. Diğer taraftan hızlı ve basit olması yanında kKAU sınıflandırıcısı oldukça iyi performanslar göstermiştir. Bu nedenle, yürüyüş şekli biyometrik özelliği için yürüyüş örüntülerinden çıkarılan özniteliklerin sınıflandırılmasında, EYK sınıflandırıcılarının (kKAU uzaklık ölçütü ile) kullanılması bizim açımızdan daha uygun görülmektedir.

Bu tezde, yürüyüş şeklinden kişi tanıma ve örüntü tanıma çalışmalarına yapılan diğer katkıların deney sonuçlarının sunumunda, performans açısından iyi olan AÖÜ ve kKAU ve bunların denetimli yaklaşımlarından mnAÖÜ ve mnkKAU uzaklık ölçütleri kullanılmıştır. Böylece kKAU’nun katkısı diğer deneylerde de irdelenirken, sınıflandırıcı sayısının az olmasıyla, deney sonuçları, daha kolay anlaşılabilir hale gelmiştir.

3.3. Özellik Çıkarma Yaklaşımları


Siluet tabanlı yürüyüş örüntüsünden kişi tanıma çalışmalarında, örüntülerdeki tekrarlılıktan ve örüntü boyutunun büyüklüğünden dolayı, ayrıştırıcı özelliklerin belirlenmesinde, öznitelik çıkarma yaklaşımları önemli bir yer tutmaktadır. İyi bir öznitelik çıkarıcıda aranan ilk performans, ayrıştırıcı alt uzayların belirlenmesidir. Önemli diğer bir kriter de bu uzayda temsil edilen örüntü boyutunun büyüklüğüdür. Çıkarılan özniteliklerin küçük boyutlu olması, işlem yükünü hafifletirken saklama ünitelerinin performansını da artırır.

Öznitelik çıkarıcıların değerlendirilmesinde öncelikle, özniteliklerin boyutlarındaki değişimlere göre performans değerlendirmesi yapılmıştır. Daha sonra farklı yürüyüş veritabanlarında, öznitelik çıkarıcıların genel performansı ölçülmüştür.

3.3.1. Öznitelik Boyutlarının Sınıflandırmaya Etkisi

Şekil 3.12-15'te sonuçları verilen deneylerde, öznitelik çıkarma yöntemleri, kullanılan özniteliğin boyut sayısına göre incelenmiştir. Yürüyüş örüntülerinin TBA, ÇTBA, D-DAA ve ÇDAA ile elde edilen alt uzaylardaki temsillerinin kKAU uzaklık ölçütü ile EYK sınıflandırılması yapılmıştır.


Şekil 3.12'de, SOTON veritabanı L4-L4 setindeki YEİ, Şekil 3.13'te CASIA-B veritabanı set-NM setindeki pCFEİ, Şekil 3.14'te CMU veritabanı V1-HY setindeki YEİ ve Şekil 3.15'te USF V2 veritabanı set-H setindeki pCFEİ yürüyüş örüntülerinin, kullanılan öznitelik boyutuna göre tanıma başarısı verilmiştir. Grafiklerde yatay eksen, alt uzayı oluşturan özvektör sayısını göstermektedir.




Şekil 3.12. Özellik çıkarma yöntemleri: SOTON veritabanında, YEİ örüntülerinin kKAU+EYK ile sınıflandırması

Özellik çıkarma yöntemlerinin birbirine göre üstünlükleri, verinin dağılımına göre değişkenlik gösterir. Eğitim kümesinde sınıfa ait örnekler arasındaki değişkenlik az ise ve test örnekleri de aynı özellikleri taşıyorsa doğrusal yöntemlerden TBA daha iyi sonuçlar verebilmektedir (Şekil 3.12). Sınıf içinde yeterince (en az 2) örnek sayısı varsa ve örnekler arasında değişkenlik mevcutsa o zaman doğrusal yöntemlerden D-DAA ile öznitelikler daha iyi belirlenebilir (Şekil 3.13, 3.14). Yüz tanıma problemlerinde renk, ifade değişimi gibi durumlarda doğrusal olmayan bileşen analizi iyi sonuçlar vermektedir [155]. Şekil


3.15'te sonuçları sunulan deneyde, hız değişimleri durumunda doğrusal olmayan özellik çıkarma yöntemlerinin daha başarılı olduğu gözlemlenmiştir. Doğrusal olmayan yöntemlerden ÇDAA, eğitim setindeki örnek sayısının fazla (8 örnek) olmasından dolayı daha baskın sonuçlar vermiştir. Şekil 3.16 deneyi için de aynı şeyler söz konusu olsa da, buradaki ifade değişimi daha farklıdır. Verilen deneyde, farklı ayakkabı giyip çanta taşıyan ve farklı yönden görüntüsü alınmış kişilerin, 5 örneğinden tanınmasına çalışılmıştır. Yine en iyi sonucu ÇDAA vermesine rağmen, bunu diğer özellik yöntemlerine nazaran daha fazla sayıda boyuta sahip özneteliklerle gerçekleştirebilir. Bunun sebebi, uygulanan ÇDAA yönteminde değeri küçük olan özdeğerlere karşılık gelen özvektörlerin normalize edilmesi olabilir [155]. Ayrıca ÇDAA ve D-DAA gibi sınıf bilgisini içeren yöntemlerde, sınıf sayısından bir eksik özvektörün seçilmesi, sınıf içi ve sınıflar arasındaki değişim analizinin geçerli olması için öngörülmektedir [136, 137, 138, 152].



Şekil 3.13. Özellik çıkarma yöntemleri: CASIA-B veritabanında, pCFEİ örüntülerinin kKAU+EYK sınıflandırması



Şekil 3.14. Özellik çıkarma yöntemleri: CMU veritabanında, YEİ örüntülerinin kKAU+EYK sınıflandırması




Şekil 3.15. Özellik çıkarma yöntemleri: USF V2 veritabanında, pCFEİ örüntülerinin kKAU+EYK sınıflandırması

Şekil 3.12-15'te, kullanılan özniteliklerin boyut sayısının önemli bir parametre olduğu görülmüştür. Sınıf bilgisini kullanan yöntemler, en fazla sınıf sayısının bir eksiği kadar sütuna sahip eşleme (dönüşüm) matrisi oluştururlar. Sınıf bilgisine bakmayan yöntemlerde, pozitif özdeğer sayısının veya özdeğer toplamalarının belirli bir yüzdesini sağlayan özdeğer sayısı kadar özvektör, eşleme (dönüşüm) matrisini oluştururken kullanılır.

3.3.2. Öznitelik Çıkarma Yaklaşımlarının Değerlendirilmesi


Bu bölümdeki deneylerde, denetimsiz özellik çıkarıcılarda kullanılan özvektör sayısı (öznitelik boyut sayısı), özdeğerler toplamının %98'ni sağlayan özdeğer sayısı kadardır. Denetimli özellik çıkarıcılarda ise boyut sayısı sınıf sayısının bir eksiği kadardır. Bu şartlar altında TBA, ÇTBA, D-DAA, TBA+DDA, ÇDAA ve 2TBA ile elde edilen öznitelikler, EYK ile sınıflandırılmıştır. Deneylerde farklı veritabanlarından YEİ veya pCFEİ yaklaşımlarıyla üretilen öznitelikler arasındaki uzaklıklar, farklı uzaklık ölçütleriyle hesaplanmıştır. Burada, farklı özellikteki yürüyüşlerde ve farklı yürüyüş örüntü üretme yaklaşımlarında, öznitelik çıkarıcıların performanslarının ölçülmesi amaçlanmıştır.



Şekil 3.16. Öznitelik çıkarma yaklaşımlarının değerlendirilmesi: USF V2 veritabanı YEİ örüntülerinde AÖÜ+EYK sınıflandırması

Şekil 3.16-19’da, yürüyüş örüntülerinden TBA, ÇTBA, D-DAA, TBA+DAA, ÇDAA ve 2B-TBA öznelik çıkarma yaklaşımlarıyla belirlenen özneliklerin tanınma başarıları verilmektedir. Şekil 3.16’da, USF V2 ve Şekil 3.17’de CASIA-B veritabanındaki YEİ örüntüleri, AÖU uzaklık ölçütünün kullanıldığı EYK yaklaşımıyla sınıflandırılmıştır. pCFEİ yürüyüş örüntülerinin kullanıldığı Şekil 3.18 ve Şekil 3.19’da sonuçları verilen deneylerde mnkKAU uzaklık ölçütüyle özellik çıkarma yaklaşımları irdelenmiştir. Şekil 3.16-19’daki deneylerde kullanılan veritabanları, doğallığı temsil edebilen yürüyüşleri içermektedir. Onlarda yapılan deneylerle, örüntü tanıma işlemlerinde çok önemli bir aşama olan özellik çıkarma yaklaşımlarından yürüyüş şekli için en uygun olanının belirlenmesine çalışılmıştır. Elde edilen sonuçlarda genel olarak ÇDAA yaklaşımı, performans ve tanıma başarısı açısından tercih edilmektedir. ÇDAA’nın tercih edilmesindeki diğer bir sebep, sınıf içindeki örnek sayısı fazla olduğunda, DAA ve farklı versiyonlarının daha performanslı olduğunun bilinmesidir [130, 136].


Şekil 3.16’da her sınıfta en fazla 5 örnek, Şekil 3.17’de eğitim sınıflarında 8, test sınıflarında 4 örnek vardır. Her iki şekilde de, çekirdek tabanlı yöntemlerin diğerlerine nazaran daha iyi sonuç verdiği görülmektedir. Yürüyüş veritabanlarında yaptığımız soldan ve sağdan 2B-TBA’nın her ikisinde de, genel olarak TBA’ya göre performans artışı sağlamadığı gözlemlenmiştir.




Şekil 3.17. Öznelik çıkarma yaklaşımlarının değerlendirilmesi: CASIA-B veritabanı YEİ örüntülerinde AÖU+EYK sınıflandırması

D-DAA ve TBA+DAA yöntemleri, AÖS problemini çözen benzer yaklaşımlar olduğundan sonuçları birbirine yakındır. Fakat TBA+DAA’da kullanılan özvektör sayısı

sınıf sayısından fazla olabilirken, D-DAA’da maksimum sınıf sayısının bir eksiği kadar olabilir. Ayrıca TBA+DAA’da , TBA uygulanarak sınıf içi dağılımda kaldırılan alt uzayın (boş uzay) ayrıştırıcı bilgi barındırdığı, bu nedenle D-DAA’nın daha iyi olduğu savunulmaktadır [137].



Şekil 3.18. Öznitelik çıkarma yaklaşımlarının değerlendirilmesi: USF V1 veritabanı pCFEİ örüntülerinde mnkKAU+EYK sınıflandırması




Şekil 3.19. Öznitelik çıkarma yaklaşımlarının değerlendirilmesi: CASIA-B veritabanı pCFEİ örüntülerinde mnkKAU+EYK sınıflandırması


Şekil 3.19, CASIA-B yürüyüş veritabanının 90°'lik açıda (profil) alınan görüntülerinde yapılan deney sonuçlarını gösterir. Sınıflandırmada, sınıf bilgisi kullanıldığından, aynı şartlarda yapılan normal yürüyüşlerde özellik çıkarma yöntemleri yüksek başarı göstermektedir. Diğer çanta taşıma ve elbise değişikliği durumlarında Şekil 3.17'deki ÇDAA'nın üstünlüğü yerini TBA ve ÇTBA'ya bırakmıştır. Bu ilişki Şekil 3.16 ve Şekil 3.18'de de görülmektedir.

3.3.3. 2B-TBA Özellik Çıkarıcısının İncelenmesi

Şekil 3.20'de USF veritabanından üretilen YEİ örüntülerinin görüntü boyutlarında değişiklikler yapılarak 2B-TBA ile öznitelikleri çıkarılmış ve kKAU ile performansı incelenmiştir. Özniteliklerin aynı şekilde belirlendiği Şekil 3.21'de de, mNAÖÜ ile sınıflandırma yapılmıştır. Her iki deneyde de makul değerlerde değişen görüntü boyutları için başarı performansları çok az değişmiştir.



Şekil 3.20. USF V2 veritabanında 2B-TBA'nın, görüntü boyutlarındaki değişimlerdeki performansı




Şekil 3.21. CASIA-B veritabanı profilden (90°'lik açıda), 2B-TBA'nın görüntü boyutlarındaki değişimlerdeki performansı

3.4. Yürüyüş Örüntüsü Üretme Yaklaşımları

Yürüyüş şeklinden kişi tanıma çalışmalarında en önemli aşamalardan bir diğeri yürüyüş örüntülerinin üretilmesidir. Çalışmalarımızda farklı yürüyüş örüntüsü üretme yaklaşımları önerilmiş ve pCFEİ ile önemli bir katkı sağlanmıştır. İlerleyen bölümlerde önerilen yürüyüş örüntüleriyle yapılan deney sonuçları verildikten sonra pCFEİ ve YEİ örüntülerinin performansları değerlendirilmiştir.

3.4.1. Önerilen Yürüyüş Örüntülerinin Performansları

Şekil 3.22'de, Bölüm 2.2'de önerilen örüntü üretme yaklaşımlarının değerlendirilmesi amacıyla, çeşitli şartlarda yürüyüşlere sahip test setleri olan USF V1 yürüyüş veritabanında elde edilen tanıma başarıları verilmiştir. Deneylerde CDAA özellik çıkarma ve mnKAU uzaklık ölçütü kullanılmıştır.



Şekil 3.22. Örüntü üretme yaklaşımlarının değerlendirilmesi: USF V2 veritabanı üzerinde ÇDAA+mnkKAU+EYK ile başarımlar değerlendirilmesi


Şekil 3.22’de, zemin değişikliği olmayan test setlerinde (A,B,C) pCFEİ yaklaşımı en iyi performansı vermiştir. Zemin değişikliği olan testlerde (D,E,F,G) ise YEİ ve DC yaklaşımları daha iyi sonuçlar vermiştir. Yürüyüş örüntüleri birbirine çok benzeyen YEİ ve DC yürüyüş silüetlerinin ortalamasına dayalı yaklaşımlardır. Genel olarak bakıldığında AC bileşenler en az performansı gösterirken TBA yaklaşımları, tüm yaklaşımların ortalama performansına eşdeğer sonuçlar üretmiştir. Bu deney sonucunda işlem ve başarı performansı açısından pCFEİ’nin en iyi katkısı sağladığı gözlemlenmiştir. pCFEİ gürültüden daha çok etkilendiğinden, zemin değişikliği olan testlerde performans düşüklüğü oluşmuştur.

3.4.2. DCT ile Sıkıştırılmış Örüntülerin Performansı


Şekil 3.23 ve 3.24’te sonuçları verilen deneylerde, yürüyüş örüntülerinin 2B-DCT’si yapıldığında başarı performansı incelenmiştir. 2B-DCT görüntülerinin DC bileşeni sıfırlandıktan sonra tamamı (DCT100), sol üst köşedeki çeyrek kısmı (DCT50) ve sol üst köşedeki 1/16’lık bölümü (DCT25) yeni yürüyüş örüntüsü olarak belirlenmiştir. Oluşan bu yeni örüntüler ve DCT yapılmadığı orijinal halleri (Direk) için ayrı ayrı deneyler

yapılmıştır. Deney sonuçlarında yürüyüş görüntülerinin 1/16'sının tanıma için yeterli olduğu görülmüştür ancak genel olarak DCT'nin tanıma başarısında bir performans artışı olmamıştır.

Şekil 3.23'te CASIA-B'deki pCFEİ örüntülerinde, DCT etkisinin incelendiği deney sonuçları verilmiştir. AÖU sınıflandırmasında az da olsa Direk yaklaşımın daha iyi olduğu gözlenmiştir.



Şekil 3.23. Örüntülerin DCT'si: CASIA-B veritabanı 90°'lik açıda (profil), pCFEİ yürüyüş örüntüleri DCT'sinin sınıflandırılması



Şekil 3.24. Örüntülerin DCT'si: USF V2 veritabanında, YEİ yürüyüş örüntüleri DCT'sinin sınıflandırılması

DCT'nin etkisinin incelendiği bir başka deneyde USF V2 veritabanı, YEİ, TBA ve mnkKAU yaklaşımları kullanılmıştır. Deneyin Şekil 3.24'teki sonuçlarında, genel olarak performanslar birbirine yakındır. 12 testten oluşan deneyin zemin değişikliği yapılan test setlerinde (D, E, F, G, H) DCT25, diğerlerine göre daha iyi sonuçlar vermiştir. Buna, zeminden gelen gürültülerin yüksek frekanslar atılarak kaldırılmasının neden olduğu düşünülmektedir. Çanta taşınan (H, I, J) setlerde de benzer değerlendirme kısmen yapılabilir. Bu deneyin sonuçlarına bakıldığında, Direk yöntemin genel olarak daha performanslı olduğu söylenebilir. Ayrıca DCT'nin hesapsal maliyeti de, DCT yaklaşımının genel performansını düşürmektedir.


3.4.3. pCFEİ'de p Parametresinin Etkisi

pCFEİ'ndeki p parametresi ile anlık değişimleri algılama yanında, hız değişimlerinde de benzer yürüyüş örüntüsünü üretebilme hedeflenmiştir. Örneğin, eğer bir kişi yavaş yürüyorsa p parametresi kullanılmayıp ardışık çerçevelerin farkları alınınca, elde edilen önplan bilgileri az olur (sıfırdan farklı değerdeki piksel sayısı). Söz konusu durum, p parametresinin çok küçük değerleri için de geçerlidir. Hızlı yürüyüşlerde, p 'nin büyük seçildiğinde ise, fark imgesinde fazla sayıda ön plan bilgisi oluşur. Bundan dolayı, p parametresi saniyede alınan çerçeve sayısına ve yürüyüş periyoduna bağlı olarak kestirilmiştir. p parametresi kullanılma sebeplerinden diğeri de, hız değişimlerinde farkları alınan çerçevelerdeki siluet pozisyonlarının aynı olmasını sağlamaktır. fps (saniyede alınan çerçeve sayısı) ve yürüyüş periyoduna (P) bağlı olan $p = P \times k / fps$ hesabıyla teorik olarak bu işlem doğrudur. Ancak p parametresi dijitallikten dolayı tamsayı olmalıdır.

Hız değişiminde yürüyüş örüntüsünü YEİ üzerinden de değerlendirebiliriz. Kişi hızlı yürüdüğünde bir periyottaki çerçeve sayısı az olur yani yürüyüş örüntüsündeki dinamik bölgelerin temsili az sayıda örnekle sağlanmaya çalışılır. Başka bir deyişle yavaş yürüyüşlerden üretilen örüntülerde, dinamik bölgelerdeki pikseller arası geçişler, hızlı yürüyüştekinden daha yumuşaktır. YEİ'de bu problem, yakalanamayan çerçevelerin interpolasyon yöntemiyle hesaplanmasıyla çözülebilir. pCFEİ'de de aynı yöntem uygulanırsa hızlı/yavaş yürüyüşler için aynı yürüyüş örüntüsü üretilebilir. Diğer taraftan, pCFEİ için önerilen p parametresiyle interpolasyon yapmadan aynı yürüyüş örüntüsünü üretmek teorik olarak mümkündür.

Elimizdeki veritabanları, saniyede 25-30 çerçeve ile kaydedilmiştir ve bir kişinin ortalama tam bir adımı da 30-50 görüntü çerçevesinde gerçekleşmektedir. Örneğin yavaş yürüyüşü 45 çerçevede gerçekleştiren bir kişinin, hızlı yürüyüşü 30 çerçevede yaptığını ve hızlı yürüyüş için p 'yi 2 olarak hesapladığımızı varsayalım. Bu durumda yavaş yürüyüş için p parametresi 3 olur. Sonuç tamsayı çıktığından hızın değişiminin etkisi ortadan kalkar. Fakat, kişilerin yürüyüş periyodu çok daha farklı çerçeve sayılarında gerçekleşir. Yani p parametresi için hesaplanan oran genellikle tamsayı çıkmaz. Bu durumda yuvarlama yapılarak p parametresi hesaplanır. Deneylerimizde kullanılan veritabanlarında saniyede alınan çerçeve miktarının az olması nedeniyle p parametresinin etkisi pratikte net olarak görülememiştir.


p parametresinin etkisini incelemek için, hızlı ve yavaş yürüyüşlerden oluşan CMU veritabanı üzerinde deneyler yapılmıştır. CMU'da bütün kayıtlarda fps aynı olduğundan, p parametresini hesaplamak için yürüyüş periyodu (P) sabite (4,6,...,24) bölünerek hesaplanmıştır.



Şekil 3.25. CMU veritabanı V1-HY setinde farklı p parametreleri için başarımların değerlendirilmesi

Şekil 3.25'te, CMU'nun aynı kamera yönlerinde, eğitimin hızlı ve testin yavaş yürüyüşlerde yapıldığı deneyin sonuçları verilmiştir. Şekil 3.26'daki sonuçları verilen CASIA-C ile yapılan deneyde ise, veritabanındaki dizilerin fps 'si, yapay olarak

artırılmıştır. Şekil 3.25'teki seri adları mevcut fps'nin bölündüğü değeri, Şekil 3.26'dakiler ise farkları alınan çerçeveler arasındaki çerçeve uzaklığını ifade etmektedir. Çerçeve uzaklığı olarak iki nokta arasındaki çerçeve sayısı alınmıştır.



Şekil 3.26. CASIA-C veritabanında, fps 'si dijital olarak artırılmış yürüyüş dizilerinde, p parametreleri için başarımlar değerlendirilmesi


Şekil 3.25 ve Şekil 3.26'da, pCFEI'nin, p parametresinin küçük ve büyük değerlerinde daha iyi performans elde edildiği görülmektedir. p parametresinin büyük olduğu durumlarda, referans görüntüdeki silüet pozisyonu ile p adım sonraki silüet pozisyonu birbirine yakındır. Yani referans görüntüdeki pozisyon, adımın başlangıcı konumunda ise, p sonraki pozisyonda da adım başlangıcı olabilir. Yani büyük olan p adımı, silüet pozisyonu açısından küçük olabilmektedir.

3.4.4. YEİ ve pCFEI'nin Performans Değerlendirmesi


YEİ son zamanlarda pek çok araştırmacının kullandığı en popüler yürüyüş örüntüsü üretme yaklaşımıdır. Çalışmalarımızda YEİ yürüyüş örüntüleri üretilerek, daha önce yürüyüş şeklinden kişi tanıma çalışmalarında uygulanmayan özellik çıkarma yaklaşımlarıyla test edilmiştir. Bunun yanında tarafımızca önerilen yürüyüş örüntü üretme yaklaşımlarında en iyi performansı pCFEI ile yakalanmış ve YEİ'den üstün olan yanları gözlemlenmiştir.

YEİ örüntü üretme yaklaşımında, kişilerin örüntü merkezlerinde değişmeyen fiziksel yapı bilgisini barındıran bölgeler oluşur. Kalın elbise giyme veya eşya taşıma durumlarında fiziksel yapı değişir. Fiziksel yapıdaki bu değişimlerin tanıma performansında etkili olduğu gözlemlenmiştir. Yürüyüşteki anlık değişimleri yakalamayı hedefleyen pCFEİ yaklaşımında ise, kalın elbise giyen veya eşya taşıyan kişilerin tanınmasında YEİ'ye göre daha az negatif etki görülmüştür. Diğer taraftan YEİ, kapanma, kopma, gölge gürültüsü gibi bozukluklarda fiziksel yapıya bağımlılığından dolayı daha iyi performans göstermektedir. Deneylerimizde, bu şartları ayrı ayrı ve aynı anda içeren yürüyüş veritabanları kullanılarak performans karşılaştırması yapılmıştır. Bunun için TBA, ÇTBA, D-DAA ve ÇDAA özellik çıkarıcıları, EYK sınıflandırıcıları ile beraber kullanılmıştır. Yüksek performans elde edilen bazı deneylerde, denetimsiz sınıflandırıcıların sonuçları verilerek daha görsel karşılaştırma yapılmasına çalışılmıştır.

Şekil 3.27'de, CMU veritabanında yapılan hız deneylerinin (eğitim ve test farklı hızdaki yürüyüşlerde) sonuçları verilmiştir. Eğitim hızlı yürüyüşlerde yapıldığında, YEİ'nin genel olarak daha performanslı olduğu gözlemlenmiştir. Bu gözlem çapraz konuşlandırılmış kamera görüntülerinde (V4, V5) daha belirgindir. Bu performansın, YEİ'nin fiziksel yapı bilgisinden kaynaklandığı düşünülmüştür. pCFEİ'nin, kötü sonuçlar vermesinin nedeni olarak ta, p adımıındaki siluet pozisyonunun (SP), referans görüntüsündekine uzak olmasından (p , SP için büyük) kaynaklandığı düşünülmüştür. Eğitim yavaş yürüyüşlerde yapıldığında, pCFEİ ile daha iyi performanslar elde edilmiştir. Bunun, p 'nin küçük (p , SP için küçük) olmasından kaynaklandığı yargısına varılmıştır.




Şekil 3.27. YEİ ve pCFEİ'nin karşılaştırılması: CMU veritabanında ÇDAA+kKAU yaklaşımıyla sınıflandırma



Şekil 3.28. YEI ve pCFEI'nin karşılaştırılması: CASIA-C veritabanında ÇTBA+mnkKAU yaklaşımıyla sınıflandırma


Kızılötesi kamera ile oluşturulmuş CASIA-C veritabanında, normal yürüyüşlerin ilk dördü eğitimde, sonraki normal 2 yürüyüş (NM), çantalı 2 yürüyüş (BG), hızlı 2 yürüyüş (FQ) ve yavaş 2 yürüyüş (FS) testte kullanılarak yapılan deneyin sonuçları Şekil 3.28'de verilmiştir. CASIA-C veritabanındaki silüetlerin önplan bilgilerinde çizgisel ve dairesel kayıplar ve otomatik eşikleme kaynaklı gürültüler vardır (Şekil 2.2.(c)). Bu nedenle, çanta taşıma durumunda iyi performans sergileyen pCFEI yaklaşımı, hızlı ve yavaş yürüyüş testlerinde beklenen başarıyı gösterememiştir. Profilden alınan kayıtlarla oluşturulan CASIA-C üzerinde YEI, çantanın fiziksel yapıya katkısından olumsuz olarak etkilenirken, hızlı ve yavaş yürüyüş testlerinde fiziksel yapı bilgisi ve gürültüye karşı gücü sayesinde performans artışı sağlamıştır.

Şekil 3.29'da sonuçları verilen deneyde kullanılan CASIA-B veritabanı normal kamerayla oluşturulmuştur ve silüetlerde çatlaklar yoktur. Profildeki normal yürüyüşlerin ilk dördünde eğitim yapılan deneyin, normal yürüyüş (NM, 2 kez yürüyüş), çantalı yürüyüş (BG, 2 kez yürüyüş) ve kalın elbiseli yürüyüş (CL, 2 kez yürüyüş) testlerinde, pCFEI yaklaşımının YEI'den oldukça iyi performans sergilediği gözlemlenmiştir. Çanta ve eşya taşımanın, profilden bakışlarda YEI'deki fiziksel yapıya kattığı fazlalıklardan dolayı, pCFEI'ye göre daha düşük performans elde edilmiştir.



Şekil 3.29. YEİ ve pCFEİ'nin karşılaştırılması: CASIA-B veritabanında ÇDAA+kKAU yaklaşımıyla sınıflandırma


Şekil 3.30 ve 3.31'de farklı şartlardaki yürüyüşlere sahip USF veritabanlarıyla yapılan deneylerin sonuçları verilmiştir. Her iki versiyonda da, zemin değişikliği olmayan yürüyüşlerin (A, B, C, H, I, J) tanınmasında, pCFEİ'nin iyi performansı gözlemlenmiştir. Zemin değişikliği olan (D, E, F, G, L) testlerinde, YEİ'nin performansı pCFEİ'den daha iyi olmuştur. USF veritabanlarıyla yapılan deneylere bakıldığında, özellikle USF V1'de, bozuk silüetlerden dolayı başarı performansı oldukça düşüktür. Diğer taraftan zemin, elbise, eşya taşıma ve yön gibi yürüyüş şartları tanımayı olumsuz etkilemektedir.



Şekil 3.30. YEİ ve pCFEİ'nin karşılaştırılması: USF V1 veritabanında ÇDAA+mnkKAU yaklaşımıyla sınıflandırma

Şekil 3.31'de çanta taşınan yürüyüşlerde (H, I, J), pCFEİ'nin oldukça iyi performansı görülmektedir. pCFEİ'nin elbise değişimlerinde de YEİ'ye göre daha performanslı olduğunu söylemiştik. Bu iddiamız test set-K (elbise, zaman) ile doğrulanmıştır ancak test

set-L (elbise, zemin, zaman)'deki zemin değişimi pCFEİ'nin kalın elbise giyilmesine rağmen performansını düşürmüştür. Nitekim USF veritabanlarında, A, B, C, H, I, J setlerinde %50 üzerinde tanıma başarısı kaydedilirken diğer test setlerinde performans çok düşüktür ve genelde değerlendirmeye alınmamışlardır.




Şekil 3.31. Yürüyüş örüntülerinin karşılaştırılması: USF V2 veritabanında ÇTBA+mnkKAU yaklaşımıyla sınıflandırma

Farklı yürüyüşleri olan diğer bir veritabanı CASIA-B'de, 11 farklı açıdan alınmış 10 oturumluk yürüyüş kayıtları vardır. 10 oturumun ilk 6 tanesi normal yürüyüştür. Sonraki 2 yürüyüş çantalı (BG) ve son iki yürüyüş kalın elbiselidir (CL). Normal yürüyüşlerin son iki oturumu normal yürüyüş testi (NM) için ayrılmıştır. Deneylerimizde kullanılan kayıtlardaki kişi sayısı 119'dur. CASIA-B veritabanında, eğitim ve testleri aynı yöndeki kameradan alınan görüntülerde yaptığımız NM deneylerinde, %99 üzerinde başarı elde edilmiştir. Bu performans, yöntem seçiminde belirleyici olmadığından grafik olarak verilmemiştir.

Şekil 3.32'de eğitim ve testin aynı açıda yapıldığı, CASIA-B veritabanındaki çantalı yürüme koşullu set-BG testinin sonuçları verilmiştir. Şekilde YEİ ve pCFEİ ile ÇTBA ve ÇDAA yaklaşımları da incelenebilir. Şekil 3.32'de, profil görüntülerinde (90°) pCFEİ'nin her iki özellik çıkarıcıyla da, en iyi başarıyı sağladığı görülmektedir. Çapraz açılarda, genel olarak bütün yaklaşımların tanıma başarısı daha düşüktür. Önden ve arkadan görünüşlerde (0° ve 180°) YEİ performansı en iyi seviyesine gelirken pCFEİ'ye yaklaşır. Önden/arkadan görünüşlerde, çantalar genellikle sırt bölgesinde kapanırlar. Diğer açılarda ise çantalar,

fiziksel yapıyı bozan fazlalıklar oluşturur. Bu durumda YEİ'nin performansı düşmektedir. pCFEİ'nin dinamik bilgi hesabı, özellikle profil yönünde YEİ'ye göre %30 civarında başarı artışı sağlamıştır.




Şekil 3.32. Yürüyüş örüntülerinin ve özellik çıkarıcıların karşılaştırılması: CASIA-B veritabanı set-BG'de, pCFEİ ve YEİ'nin ÇTBA ve ÇDAA yaklaşımlarıyla başarı performansları

Şekil 3.33'te, CASIA-B veritabanının kalın elbise giyilmiş yürüyüşlerle yapılan deneylerin sonuçları verilmiştir. Kalın elbise giyildiği durumda pCFEİ doğrusal olmayan uzaydaki öznitelik çıkarıcılarla en iyi performansları vermektedir. YEİ'nin performansı, profile oldukça düşük olup önden/arkadan alınan görüntülere doğru pCFEİ'ye yaklaşmaktadır. Önden/arkadan alınan görüntülerde yürüyüş dinamiklik bilgisi, profile göre daha az bileşende ortaya çıkmaktadır. Bu nedenle profile, iyi olan pCFEİ'nin performansı, diğer açılara kaydıkça azalmaktadır.

Şekil 3.32 ve 3.33'te, ÇTBA her iki yürüyüş örüntüsü için de daha iyi sonuçlar vermiştir. Daha önce diğer veritabanlarında da yaptığımız deneylerde, ÇDAA'nın ÇTBA'dan daha performanslı olduğunu savunmuştuk.

Bölüm 3.3.2'de, USF gibi karmaşık ortam şartlarında yapılan deneylerde genel olarak ÇDAA en iyi sonuçları vermiştir. Buradan ÇDAA'nın karmaşık ortamlarda daha iyi ayırtırma yapabildiğini çıkarabiliriz. Ayrıca DAA yaklaşımlarının sınıftaki örnek sayısının fazla olduğu durumlarda denetimsiz özellik çıkarıcılara göre daha iyi performans sergilediği, yüz tanıma problemlerinde gösterilmiştir [155]. Elde ettiğimiz sonuçlar ve

literatür değerlendirmelerimizde, ÇDAA'nın genel olarak daha iyi performanslı olduğu düşünülmektedir.




Şekil 3.33. Yürüyüş örüntülerinin ve özellik çıkarıcıların karşılaştırılması: CASIA-B veritabanı set-CL'de, pCFEİ ve YEİ'nin ÇTBA ve ÇDAA yaklaşımlarıyla başarımları

Şekil 3.34-3.36'daki sonuçları elde ettiğimiz deneylerde, CASIA-B üzerinde, eğitimin yapıldığı açıların komşu açılarında testler yapılmıştır. Örneğin şekillerde, 144+ diye geçen yatay eksenindeki testin, eğitimi 144°, testi ise 144°'nin büyük komşu açısı 162°'de yapılmıştır. Benzer şekilde 144- için, 144°'de eğitilen örnekler, 126°'de test edilmiştir. Burada dikkat edilmesi gereken nokta 0° ile 180°'lik açıların birer komşusunun olmamasıdır. Şekillerde 0- için 180° ve 180+ için 0° komşu olarak verilmiştir.

Şekil 3.34-3.36'da sırasıyla CASIA-B üzerinde normal (NM), çanta taşıma (BG) ve kalın elbise giyme (CL) testlerinin sonuçları verilmiştir. Her üç testte de profile yakın açılarda performanslar daha iyidir. Eğitimin ve testin aynı açılarda yapıldığı deneylerdeki gibi, çapraz açılardaki testlerde de pCFEİ, YEİ'den daha iyi tanıma başarısı sağlamıştır. Önden/arkadan alınan görüntülerin çapraz testlerinde, YEİ genelde pCFEİ'den daha iyi performans sağlamıştır. Bu sonuç, profile yakın yürüyüşlerde görüntülenebilen uzuv değişimleri ile dik yürüyüşlerdeki karşılaştırılmasıyla açıklanabilir. Kamerası dik yürüyüş görüntülerinde, beden daha düz olmakta ve yürüyüş örüntülerinde daha az değişim meydana gelmektedir. Gürültüsüz yürüyüşler için az bilgi daha iyi tanıma sağlayabilir ama


doğal ortamlarda gürültü her zaman vardır. Diğer taraftan YEİ'nin önden/arkadan bakışlarından üretilen yürüyüş örüntülerindeki önplan bilgilerinde, statik bilgi dinamik bilgidir ve özellikle çanta bu bilgiyi daha az etkileyen pozisyonda bulunur, yani çoğu kişinin taşıdığı çanta bedenle kamera arkasında veya bedenin arkasında kalır. Bu durum, pCFEİ'ye göre YEİ'de performans artışı sağlamıştır.



Şekil 3.34. Yürüyüş örüntülerinin karşılaştırılması: CASIA-B Set-NM'de komşu açı test sonuçları

Şekil 3.34'te çapraz açılardaki normal yürüyüş testlerinin sonuçları verilmiştir. Profilde %95'lere varan performans kameraya dik yöndeki yürüyüşlerde %50'lerin altına inmektedir. Dik yöndeki açılardaki yürüyüş örüntüleriyle, komşu açılardaki yürüyüşlerin örüntüleri arasındaki ön plan farkları, profildekilerden daha fazladır. Şöyle ki; kolları sarkık önden görülen bir kişinin etrafında dönülünce, görülen kol bilgisi kaybolur ve 2 tane görünen bacaklar profile doğru tekleşir. Profildeki tek bacak, en ince halini alır. Bedenin şekil değişimi de benzer şekilde gerçekleşir. Profildeki performans artışının diğer bir sebebi, dinamik bilginin fazla olmasıdır. Azalan statik bilginin telafisi, dinamik bilgiyle yapılmış olur.

Normal yürüyüş deneylerinde, YEİ genel olarak pCFEİ'den daha iyi performans sergilemiştir. Bunun sebebi olarak fiziksel yapıyı barındıran statik bilgilerin doğruluğu düşünülmektedir. CASIA-B'nin normal yürüyüşleri, eğitim setinden farklı oturumlarda, aynı koşul ve şartlarda, eğitim kayıtlarının akabinde yapılmıştır.




Şekil 3.35. Yürüyüş örüntülerinin karşılaştırılması: CASIA-B Set-BG’de komşu açı test sonuçları

Şekil 3.35’teki sonuçlarda, çanta taşıma komşu açılarda test edilmiştir. Profile yakın açılarda pCFEİ, YEİ’ne göre oldukça iyi performans sergilerken, çanta bilgisinin çoğu zaman kaybolduğu dik yürüyüşlerde, YEİ daha iyi sonuçlar vermektedir. Kameraya dik yürüyüşlerde, pCFEİ’nin dinamik bilgiyi yakalaması zorlaşır ve tanıma başarısı düşer.

Şekil 3.36’da kalın elbise giyilerek yapılan yürüyüşlerin çapraz deneylerinin sonuçları verilmiştir. Elde edilen sonuçlar çanta taşınarak yapılan yürüyüş deneylerindekiyle benzerdir. Özellikle profile yakın açılarda, pCFEİ ve YEİ arasındaki performans farkı oldukça yüksektir. Kalın elbise giymeyi, aylar sonra kişinin fiziksel yapısındaki kilo alma/verme gibi değişimi olarak ta algılayabiliriz. Bundan hareketle, zaman koşulunda da pCFEİ’nin YEİ’den daha iyi olduğunu söylemek mümkündür.

Şekil 3.35 ve 3.36’da, YEİ ve pCFEİ yürüyüş örüntülerinin tanınması için yapılan deneylerde, YEİ’nin daha çok statik bilgileri, pCFEİ’nin ise daha çok dinamik bilgileri kullandığı sonucuna varılabilir. Profil açılarında elbise ve çanta fiziksel yapıya daha çok dahil olmaktadır. YEİ statik yapı bilgisini kullandığından, normal yürüyüşlerde eğitim yapıldığında daha çok hatalı tanıma yapabilir. Örneğin kalın elbise giyen kişi, iri yapılı birine benzetilebilir. Önden/arkadan alınan görüntülerde ise pCFEİ’nin dinamik bilgi edinimi ve YEİ için fiziksel yapıdaki değişim daha az olmaktadır. Bunun sonucu olarak statik bilgiyi kullanan YEİ daha iyi, dinamik bilgiyi kullanan pCFEİ daha kötü performans sergilemiştir.



Şekil 3.36. Yürüyüş örüntülerinin karşılaştırılması: CASIA-B Set-CL’de komşu açı test sonuçları

Bu tez çalışmasında, değişik yürüyüş örüntüsü üretme yaklaşımları sunulmuş ve önerilen yaklaşımlar içerisinde pCFEİ genel olarak en iyi performansı vermiştir. Deneylerde kullanılan ÇDAA yaklaşımı, USF veritabanlarında en iyi performansı gösterirken CASIA veritabanlarında ÇTBA’ne yakın sonuçlar üretmiştir. Çekirdek hilesi kullanılarak gerçekleştirilen doğrusal olmayan yaklaşımlarda, ifade değişimleri (yön, çanta, kalın elbise, ayakkabı) daha iyi algılanmıştır. Kullanılan veritabanlarında, sınıf içindeki örnek sayısı en fazla 8’dir. DAA yaklaşımlarının, sınıftaki örnek sayısının fazla olduğu durumlarda, denetimsiz özellik çıkarıcılara göre daha iyi performans sergilediği diğer örüntü tanıma problemlerinde de savunulmuştur. Bu nedenle ve deneylerimizde de elde ettiğimiz sonuçlar doğrultusunda, çalışmamızda pCFEİ ve ÇDAA yaklaşımlarının kKAU uzaklık ölçütüyle kullanılması uygun görülmektedir.

3.5. Önerilen Yaklaşımların Literatür Karşılaştırmaları

Bu bölümde sunulan sonuçlarda, ürettiğimiz YEİ ve önerdiğimiz pCFEİ yürüyüş örüntü üretme yöntemlerinin sonuçları beraber verilmiştir. Özellik çıkarma için kullanılan ÇDAA yaklaşımı yürüyüş örüntülerinde daha önceki çalışmalarda kullanılmamıştır. Literatürle karşılaştırma sonuçlarında kullanılan sınıflandırıcı, aksi belirtilmedikçe mnkKAU’dur.

3.5.1. CMU Veritabanı Literatür Sonuçları

Tablo 3.2’de, araştırmacıların CMU veritabanı ile ürettiği sonuçlar bizim sonuçlarımızla beraber verilmiştir. Deneylerimizde eğitim ve testler aynı setlerde yapıldığında, %100 tanıma başarısı elde edildiğinden ayrıca tabloda verilmemiştir. Tablo 3.2’deki sonuçlar, eğitim ve testin farklı hızlarda yapıldığı deneylerde elde edilmiştir. Tabloda, profilden (V1) ve önden (V3) alınan kayıtlardaki deneylerde, en iyi performansı bizim yaklaşımlarımız vermiştir. Literatürde, diğer yönlerdeki deneylerin rakamsal sonuçlarına rastlanmamıştır.

Tablo 3.2. CMU veritabanında elde edilen sonuçların literatürle karşılaştırılması

	V1-HY	V1-YH	V3-HY	V3-YH
[68] (Sarkar vd., 2005)	-	88	-	-
[39] (Lee vd., 2002)	-	64	-	-
[9] (Nixon vd., 2004)	-	72	-	-
[74] (Wang L. vd., 2003)	-	76	-	-
[80] (Huang vd., 2008)	-	64	-	-
[101] (Kale vd., 2003)	75	-	-	-
[103] (Wang W. vd., 2007)	64	80	-	-
[94] (Lee vd., 2007)	80	82	-	-
[98] (Chai vd., 2006)	76	68	-	-
[32] (Kale vd., 2004)	58	32	-	-
[18] (Wang W., 2007)	84	80	-	-
[156] (BenAbdelkader vd., 2004)	32	54	33	43
[54] (Collins vd., 2002)	-	76	-	100
[78] (Ekinçi vd., 2010)	86.5	80	88.5	90
YEİ	84	92	100	100
pCFEİ	84	100	100	100

3.5.2. SOTON Veritabanı Literatür Sonuçları

Tablo 3.3’te, SOTON veritabanında yaptığımız ve literatürden bulduğumuz deneylerin sonuçları verilmiştir. Deneyler L-setinde yapılmış olup, L2-L6 deneyindeki test etiketi, sola doğru yürüyüşlerde ilk 2 örneğin eğitim ve sonraki 6 örneğin test olarak kullanıldığını ifade etmektedir.

Tablo 3.3. SOTON veritabanında elde edilen sonuçların literatürle karşılaştırılması

	L2-L6	L3-L5	L4-L4	L6-L2
[43] (Wang vd., 2004)	-	-	-	84
[52] (Boyd, 2004)	-	-	-	85.8
[90] (Ioannidis vd., 2007)	-	-	-	96.43
[89] (Lam vd., 2007)	-	-	79.8	-
[95] (Xu vd., 2006)	-	-	86.41	-
[78] (Ekinci vd., 2010)	91.88	95.65	98.26	-
YEİ	99.1	100	100	100
pCFEİ	99.1	100	100	100

Gürültüsüz, bozuk olmayan siluetlerin bulunduğu SOTON veritabanının Tablo 3.3'teki deneysel sonuçlarında, önerdiğimiz yaklaşımlarla en iyi performansların elde edildiği görülmektedir. Her sınıfta 8'er örnek olmak üzere 115 sınıfın %99'un üzerindeki başarı performansı, tek oturum ve aynı yürüyüşler yapıldığı için yüksektir.

Tablo 3.3'te eğitim için her sınıftan 3'er örnek alındığında sınıflandırma başarısı %100 olmaktadır. Bu durum eğitimdeki örnek sayısı artırdıkça değişmemiştir (tamamı doğru sınıflandırılmış).

3.5.3. CASIA-A Veritabanı Literatür Sonuçları

CASIA-A yürüyüş veritabanıyla, aynı yönde normal yürüyüşler için deneyler yapılmıştır. İlk zamanlarda oluşturulan CASIA-A veritabanında sınıf sayısı 20'dir. Tablo 3.4'te, CASIA-A yürüyüş veritabanı için, mevcut çalışmalarla, deney sonuçlarımız verilmiştir. Literatürde daha çok profil kayıtları (V00) üzerinden deneyler yapılmıştır. Diğer oturumlar V45 çapraz ve V90 dik yöndeki yürüyüşlerden oluşur.

20 kişilik veritabanında yaptığımız deneylerde, %100 başarı performansına ulaşılmıştır. CASIA-A veritabanında diğerlerinden farklı, 45°'de dış ortamda oturum vardır. Buna rağmen az sayıda örneğe sahip 20 kişilik veritabanı olduğu için daha az rağbet görmeye başlamıştır.

Tablo 3.4. CASIA-A veritabanında elde edilen sonuçların literatürle karşılaştırılması

	V00	V45	V90
[49] (BenAbdelkader vd., 2001)	72.5	-	-
[54] (Collins vd., 2002)	71.25	-	-
[39] (Lee vd., 2002)	87.5	-	-
[108] (Phillips vd., 2002)	78.35	-	-
[74] (Wang L. Vd., 2003)	88.75	-	-
[106] (Cheng vd., 2008)	86	-	-
[87] (Lee H. Vd., 2008)	91.25	92.5	88.75
[126](Chen vd., 2007)	92.5	-	-
[43] (Wang vd., 2007)	82.5	-	-
[101] (Kale vd., 2003)	82.5	-	-
[78] (Ekinci vd., 2010)	92.5	-	-
YEİ	100	100	100
pCFEİ	100	100	100

3.5.4. USF V1 Veritabanı Literatür Sonuçları

Tablo 3.5. USF V1 veritabanında elde edilen sonuçların literatürle karşılaştırılması

	A	B	C	D	E	F	G
[108] (Phillips vd., 2002)	73	66	56	30	29	18	10
[68] (Sarkar vd., 2005)	87	81	54	39	33	29	26
[32] (Kale vd., 2004)	99	89	78	35	29	18	24
[90] (Ioannidis vd.,2007)	97	89	83	41	34	30	28
[71] (Tolliver vd., 2003)	85	81	60	23	17	25	21
[86] (Yang vd., 2008)	85	76	61	36	29	21	24
[92] (Boulgouris vd.,2006)	94	83	78	33	24	17	21
[75] (Wang L. Vd., 2003)	70.4	58.5	51.2	34.3	21.4	27.2	14.3
[57] (Han vd., 2006)	100	90	85	47	57	32	31
[91] (Boulgouris vd.,2007)	100	85	83	35	29	29	26
[89] (Lam vd., 2007)	79	61	37	24	20	20	9
[79] (Cuntoor vd., 2003)	52	40	20	18	20	15	15
[101] (Kale vd., 2003)	78	65	28	10	10	10	10
[104] (Lee L.,vd, 2003)	88	75	70	25	15	20	10
[78] (Ekinci vd., 2010)	79.2	67.1	53.6	31.6	27.4	18.1	24.4
YEİ	97.1	70.7	70.7	26.8	19	16.4	21.4
pCFEİ	92.9	73.1	73.1	23.8	19	16.4	14.2

Tablo 3.5'te, USF V1 yürüyüş veritabanında yapılmış çalışmaların sonuçları, bizim deneysel sonuçlarımızla beraber verilmiştir. Mevcut çalışmalarda, USF V1 veritabanının çok bozuk silüetlere sahip olduğu üzerinde durulmuş ve bazılarında elle düzeltmeler yapıldığı ifade edilmiştir [91]. Diğer bir noktada, eğitim setinde 71 olan kişi sayısı bazı çalışmalarda daha az gösterilmiştir [90,91]. Bu çalışmalarda, test setleri de USF-NIST formatından farklı sayıda olmuştur.

Tablo 3.5'te, başarının %50'yi geçtiği sonuçlarda, bizim sonuçlarımızdan iyi olanlar kalın olarak verilmiştir. Eğitim çimende yapıldığından, A, B, ve C oturumlarındaki tanıma performansı, betonda yapılan oturumlara göre daha iyidir. USF V1'in ardından, oturum ve kişi sayısı bakımından USF V2 veritabanı daha çok ilgi çekmektedir.

3.5.5. USF V2 Veritabanı Literatür Sonuçları

Tablo 3.6. USF V2 veritabanında elde edilen sonuçların literatürle karşılaştırılması

Testler	[68] (Sarkar vd., 2005)	[96] (Zongyi vd., 2006)	[32] (Kale vd., 2004)	[92] (Boulgouris vd., 2006)	[97] (Tao vd., 2007)	[56] (Han vd., 2004)	[95] (Xu vd., 2006)	[57] (Han vd., 2006)	[89] (Lam vd., 2007)	[86] (Yang vd., 2008)	[102] (Xu vd., 2007)	YEİ	pCFEİ
A	73	85	89	83	91	87	89	90	80	90	89	88.5	89.3
B	78	89	88	86	93	85	93	91	89	87	94	88.8	92.5
C	48	72	68	78	86	76	80	81	72	80	80	83.3	81.4
D	32	57	35	39	32	31	44	56	14	41	44	31.9	28.5
E	22	66	28	34	47	30	45	64	10	48	47	32.2	28.8
F	17	46	15	20	21	18	25	25	10	27	25	16.8	15.1
G	17	41	21	21	32	21	33	36	13	28	33	20.3	15.2
H	61	83	85	43	95	63	80	64	49	72	85	72.2	87.3
I	57	79	80	40	90	59	79	60	43	63	83	67.7	86.4
J	36	52	58	40	68	54	60	60	30	63	60	58.8	61.3
K	3	15	17	16	16	3	18	6	39	6	27	6	12.1
L	3	24	15	3	19	6	21	15	9	6	21	9	3

Tablo 3.6’da, USF V2 yürüyüş veritabanı ile yapılmış çalışmaların sonuçları ve deney sonuçlarımız verilmiştir. Hem eğitim hem de test setlerindeki kişi sayısı USF V1’e göre daha fazla olmasına rağmen silüetlerdeki bozuklukların USF V1’e göre az olmasından dolayı, test sonuçları daha iyi çıkmaktadır. Test set-B setinde, eğitim setinden farklı olarak yalnızca ayakkabı değiştirilmiştir. Eğitim çimindeki yürüyüşlerde yapıldığından, ayakkabının görünüm olarak fazla bir etkisinin olmadığı düşünülmektedir. Ancak ayakkabının rahatlık derecesi, yürüyüş kaslarını etkileyen bir faktör olabilir. Sonuç olarak bu düşünce USF V1’de doğrulanamamasına rağmen, USF V2’de en yüksek başarılı test setinin set-B olması ile desteklenmektedir. Tablo 3.6’daki kalın yazılar, tanıma başarısının %50’den iyi olduğu durumlarda, bizim elde ettiğimiz sonuçlardan iyi olan literatür sonuçlarının seçilirliği için kullanılmıştır.

Tablo 3.6’da, tüm zamanların en iyi performansı Tao vd. [97] çalışmasında sağlanmıştır. Onların çalışmasında zemin farklılığı olan oturumlarda başarı düşerken (C, D, F, G), çanta, ayakkabı ve yön başarıyı daha az etkilemektedir (H, I, J). Tarafımızca önerilen pCFEİ yaklaşımı, çanta taşıma (H, I, J) oturumlarında, YEİ’den daha iyi sonuçlar üretmektedir.

3.5.6. CASIA-C Veritabanı Literatür Sonuçları

Tablo 3.7. CASIA-C veritabanında elde edilen sonuçlar

	NM	FB	FQ	FS
[119] (Zhang vd., 2010)	88.9	79.74	90.2	89.22
[93] (Tan vd., 2007)	~98	~35	~87	~89
YEİ-TBA	100	84.9	91.5	90.1
pCFEİ-TBA	100	88.8	85.6	77.7
YEİ-ÇTBA	100	73.2	88.2	89.5
pCFEİ-ÇTBA	100	93.4	85.6	70.5
YEİ-D-DAA	100	80.3	93.4	94.1
pCFEİ-D-DAA	100	92.1	84.3	83
YEİ-ÇDAA	100	66.6	77.1	86.9
pCFEİ-ÇDAA	99.3	93.4	75.8	73.8

CASIA-C kızıl ötesi kamera ile alınan 153 kişilik bir veritabanıdır. Bu veritabanında, çanta ifadesinin ekli olması durumunda, en iyi sonuçlar çekirdek kullanan yöntemlerle

pCFEİ örüntülerinde elde edilmiştir. CASIA-C için indirilen siluetlerde, kesikli çizgiler ve siluetin algılanama gibi durumları söz konusudur. Yüz tanıma problemlerinde, yüzdeki ifade değişikliği çekirdek temelli yöntemlerle daha iyi belirlenebilmektedir [134]. CASIA-C'deki bozuk siluet bilgileri yüzdeki ifadelerle eşleştirilirse ÇDAA ile diğerlerine göre daha iyi sonuçların çıkması beklenen bir durumdur.

Tablo 3.7'de, 2 yayın ve bizim çalışmalarımızın sonuçları verilmektedir. Zhang vd. [118] çalışmasında hızlı ve yavaş yürümede, normal yürümeden daha iyi performanslar kaydedilmiştir. Diğer çalışmada, sonuçlar grafikten okunduğu için yaklaşık olarak ifade edilmiştir. Çanta taşıyan kişilerin daha iyi tanındığı pCFEİ yaklaşımı ÇDAA ile kullanıldığında, hızlı ve yavaş yürümelerde diğer özellik çıkarıcılara göre daha kötü performans sergilemiştir. Deneylerimizde CASIA-C veritabanında hız değişimlerindeki testlerde en iyi performans, D-DAA özellik çıkarıcısı ile elde edilmiştir.

3.5.7. CASIA-B Veritabanı Literatür ve Deneysel Sonuçları

124 kişiden oluşan CASIA-B veritabanının indirilen dosyalarının bir kısmı bozuk olduğundan, ancak 119 kişinin kaydı kullanılabilmektedir. Tablo 3.8'de, profilden (90°) alınan görüntülerle yapılmış çalışmaların sonuçları, deney sonuçlarımızla verilmektedir.

Tablodan görüldüğü gibi kalın elbise giyme ve çanta taşıma durumlarında, pCFEİ örüntüleri, YEİ'den daha iyi performans sağlamaktadır. [118]'de önerilen örüntü üretme yaklaşımı pCFEİ'ya benzerdir. [81, 87, 119]'deki çalışmalarda YEİ örüntüsünde ayak bölgesine maske uygulanarak çanta bilgisi kaldırılmıştır. Böylece ayak bölgesinin güçlü dinamikliği ve bedende oluşabilecek (eşya taşıma, kalın giyme) bozulmaların eliminasyonu ile performans artışı sağlanmıştır. Tablo 3.7'de olduğu gibi Tablo 3.8'de de, birkaç özellik çıkarıcının performansı aynı anda verilmiştir.

Tablo 3.9. CASIA-B veritabanı üzerinde üretilen YEİ yürüyüş örüntülerinin ÇDAA özellik çıkarma ve mnkKAU sınıflandırıcısı ile yapılmış deney sonuçlarını göstermektedir. Eğitimin yapıldığı A açısı için, komşu A- , A+ açılarında ve A açısında testler yapılmıştır. Tabloda, 018° satırındaki bütün deneylerde, eğitim 018° kamera yönünde yapılmıştır. 018°'deki eğitim için, A- kolonları testin 000°'da, A kolonları testin 018°'de ve A+ kolonları ise testin 036°'da yapıldığını göstermektedir. Aynı açılardaki eğitim-testlerde elde edilen başarılar, komşu açılardan %20 kadar daha iyidir.

Tablo 3.8. CASIA-B veritabanında elde edilen sonuçların literatürle karşılaştırılması

	NM	BG	CL
[119] (Zhang vd.,2010)	98.4	91.9	72.2
[120] (Bashir vd., 2010)	100	78.3	44
[88] (Bashir vd., 2008)	99.4	79.9	31.3
[83] (Chen vd., 2009)	91.1	-	-
[82] (Singh vd., 2006)	93.4	74.6	77.1
[84] (Lu vd., 2010)	100	-	-
[81] (Yu vd., 2006)	97.6	52	32.7
YEİ-TBA	100	72.2	63
pCFEİ-TBA	99.1	83.1	68.9
YEİ-ÇTBA	99.1	54.6	34.4
pCFEİ-ÇTBA	98.3	83.1	57.9
YEİ-D-DAA	100	68	35.2
pCFEİ-D-DAA	100	77.3	49.5
YEİ-ÇDAA	100	54.6	26.8
pCFEİ-ÇDAA	99.1	77.3	50.4

Tablo 3.9. CASIA-B veritabanında, YEİ+ÇDAA+mnkKAU aynı açı ve komşu açı test sonuçları

	NM			BG			CL		
ACI=A	A-	A	A+	A-	A	A+	A-	A	A+
000°	55	100	46.6	21	72.8	31.9	8.4	20.1	8.4
018°	82.3	100	85	41.5	73.1	46.2	14.2	33.6	24.3
036°	96.6	100	96.6	53.7	63	33.8	15.9	35.2	21
054°	97.5	100	80	47	55.9	30.2	21	38.6	26
072°	73.3	100	100	24.5	52.9	41.1	14.2	41.1	33.6
090°	99.1	100	93.3	52.1	63.8	44.5	25.2	35.2	19.3
108°	86.6	100	93.3	34.4	48.7	31.9	21.8	36.1	20.1
126°	93.3	99.1	95	26.8	51.2	42	24.3	34.4	27.7
144°	94.1	100	42.5	40.3	56.3	19.3	27.7	36.1	10.9
162°	14.1	100	83.3	9.2	62.1	42.8	5	32.7	15.1
180°	74.1	100	60.5	36.1	71.4	30.5	12.6	22.6	6.7

Tablo 3.10, 3.11 ve 3.12 CASIA-B veritabanı üzerinde tüm açılar için, pCFEI+ÇDAA+mnkKAU yöntemi kullanılarak Set-NM, Set-BG ve Set-CL test setleri ile elde edilen sonuçlar verilmektedir. Tablolardaki satırlar eğitimin, sütunlar testin yapıldığı açıdır.

Tablo 3.10. CASIA-B veritabanı Set-NM, ÇDAA+mnkKAU ile yapılmış çapraz test sonuçları

	000°	018°	036°	054°	072°	090°	108°	126°	144°	162°	180°
000°	100	18.3	9.1	2.5	0.8	0.8	0.8	1.6	5.8	13.3	33.3
018°	40.3	100	63.3	10.8	2.5	0.8	0.8	4.1	13.3	35	12.5
036°	20.1	70.8	100	81.6	15.8	7.5	9.1	19.1	23.3	13.3	9.1
054°	1.6	8.3	75	99.1	44.1	23.3	23.3	38.3	22.5	5.8	1.6
072°	2.5	3.3	6.6	40.8	99.1	94.1	65	23.3	7.5	1.6	1.6
090°	0.8	1.6	3.3	12.5	95	99.1	79.1	11.6	5	1.6	1.6
108°	0.8	2.5	3.3	16.6	55.8	83.3	98.3	64.1	9.1	2.5	0.8
126°	1.6	4.1	12.5	35	30.8	26.6	68.3	100	81.6	9.1	0
144°	4.2	3.3	20	28.3	8.3	5.8	21.6	90.8	100	10	2.5
162°	23.5	29.1	10.8	2.5	2.5	2.5	1.6	4.1	7.5	100	44.1
180°	32.7	7.5	5	0.8	0.8	0.8	0.8	0.8	5	40.8	100

Tablo 3.11. CASIA-B veritabanı Set-BG, ÇDAA+mnkKAU ile yapılmış çapraz test sonuçları

	000°	018°	036°	054°	072°	090°	108°	126°	144°	162°	180°
000°	78.8	10	9.2	1.6	1.6	2.5	0.8	0.8	3.3	10.9	25.2
018°	24.5	69.7	36.1	10.1	4.2	1.6	2.5	2.5	6.7	10.9	6.7
036°	13.5	33.6	67.2	34.7	5.8	5	7.5	10	11.7	6.7	4.2
054°	2.5	7.5	35.2	69.4	30.2	15.1	15.1	22.6	14.2	2.5	1.6
072°	2.5	1.6	5.8	14.4	68	48.7	26.8	12.6	3.3	1.6	1.6
090°	0.8	2.5	2.5	10.1	52.1	77.3	39.4	10.9	2.5	0.8	1.6
108°	0.8	1.6	3.3	8.4	26.8	54.6	68.9	25.2	3.3	0.8	0.8
126°	0.8	4.2	9.2	12.7	16.8	17.6	37.8	67.2	32.7	1.6	0.8
144°	1.6	3.3	10.9	11.8	3.3	5	8.4	47.8	64.7	4.2	2.5
162°	12.7	13.4	8.4	1.6	1.6	2.5	2.5	4.2	5	63.8	22.6
180°	27.1	9.2	1.6	0.8	0.8	0.8	0.8	1.6	2.5	23.5	72.2

Tablo 3.12. CASIA-B veritabanı Set-CL, ÇDAA+mnkAU ile yapılmış çapraz test sonuçları

	000°	018°	036°	054°	072°	090°	108°	126°	144°	162°	180°
000°	29.4	7.5	3.3	1.6	0.8	1.6	1.6	1.6	2.5	5.8	7.5
018°	7.5	31	25.2	7.5	1.6	0	1.6	2.5	5.8	10.9	1.6
036°	3.3	20.1	49.5	30.2	6.7	1.6	0.8	5.8	5	5	0.8
054°	1.6	4.2	18.4	58.8	19.3	10	6.7	9.2	5.8	0.8	0.8
072°	0.8	1.6	4.2	12.6	49.5	38.6	15.9	9.2	2.5	1.6	0.8
090°	1.6	2.5	1.6	9.2	35.2	50.4	19.3	5.8	1.6	1.6	1.6
108°	0.8	1.6	1.6	5.8	21	34.4	47.8	15.9	4.2	1.6	0.8
126°	0.8	1.6	4.2	10	11.7	9.2	23.5	45.3	21.8	2.5	0.8
144°	1.6	2.5	9.2	11.7	5.8	4.2	9.2	29.4	44.5	2.5	1.6
162°	5.8	8.4	5	2.5	0.8	0.8	1.6	1.6	2.5	28.5	9.2
180°	5	4.2	0.8	0.8	0.8	0.8	0.8	0.8	1.6	8.4	26

4. SONUÇLAR

Yürüyüşünden kişi tanıma çalışmaları, 2000’li yıllardan sonra biyometri alanında dikkat çeken araştırma konularından biri olmuştur. Özellikle, HumanID programı kurularak teşvik edilen üniversite ve enstitülerde farklı koşullarda yürüyüş veritabanları oluşturulmuştur. Bu tez çalışmasında da, yürüyüşten kişi tanıma amacıyla, yürüyüş örüntüsü üretme, özellik çıkarımı ve sınıflandırmayı içeren örüntü tanıma alanında bazı yaklaşımlar sunulmuştur. Önerilen yaklaşımlar, bu veritabanları üzerinde denenmiş ve en iyilerinin belirlenmesine çalışılmıştır. Yapılan araştırmalarda, yayınlanmış çalışmalarda, aynı anda 2’den fazla veritabanı ile test yapıldığına rastlanmamıştır.

Yürüyüş şeklinde kişi tanımanın önemli 3 aşaması vardır: 1) yürüyüş örüntüsü üretme, 2) özellik çıkarma ve 3) sınıflandırma. İlk zamanlar model tabanlı yaklaşımlarla ölçülen yürüyüş şekilleri, günümüzde daha çok silüetlere dayalı olarak modelden bağımsız yaklaşımlarla üretilen yürüyüş örüntüleriyle temsil edilmektedir. Özellikle YEİ yürüyüş örüntüsünün diğer yaklaşımlara karşı gösterdiği performans, araştırmacıları silüet tabanlı yürüyüş örüntüsü üretmeye ve YEİ’yi geliştirmeye yöneltmiştir. Çalışmalarımızda YEİ’ye alternatif olarak, yürüyüş dizisi çerçevelerinden hesaplanan özvektörlere, ayırık kosinüs dönüşümüne, silüet kutusu ile sınırları arasındaki mesafelere ve p aralıklı silüet çerçevelerinin fark toplamalarına dayalı yürüyüş örüntüsü üretme yaklaşımları geliştirilmiştir. Önerdiğimiz örüntü üretme yaklaşımları içerisinde en iyi performansı sağlayan pCFEI, yürüyüş dinamikliğini YEİ’ye göre daha çok ön plana çıkararak, eşya taşıma ve kalın elbise giyme koşullarında YEİ’den de yüksek performanslar sağlamaktadır.

Yürüyüş şekline dayalı kimliklendirmenin ikinci aşamasında, daha önce yürüyüş örüntülerinde uygulanmamış danışmanlı özellik çıkarıcılardan CDAA’nın daha iyi performans sağladığı gözlemlenmiştir. CDAA hız, elbise değişimi gibi doğal şartlarda DAA gibi yaklaşımlardan daha iyi ayrıştırma yapmaktadır. Çalışmalarımızda çekirdekli yöntemlerde, başarısından dolayı Gauss çekirdeği tercih edilmiş ve çekirdek fonksiyonu parametresinin otomatik kestirimi için deneysel olarak bir denklem üretilmiştir.

3. aşamada sınıflandırıcıya verilen özniteliklerin normalizasyonu farklı bir yaklaşımla gerçekleştirilmiştir. Özniteliklerin, boyutlara göre normalizasyonuyla alt uzayda özniteliklerin dağılımı yeniden düzenlenerek daha başarılı sınıflandırma sağlanmıştır.

Örüntü tanıma problemlerinde yapılmış çalışmalara bakıldığında; genellikle EYK sınıflandırıcıları, parametresiz ve kolay uygulanabilir olmaları açısından daha çok tercih edilmektedir. Probleme göre seçilen uzaklık ölçütleriyle EYK sınıflandırıcıları, karmaşık sınıflandırıcılara göre oldukça iyi performans sağlamaktadır. Çalışmamızda, çeşitli uzaklık ölçütleri denenmiş ve eğitim kümesindeki öznitelik vektörlerinin ortalamasının çıkarıldığı eğitim ve test öznitelik vektörlerinin arasındaki açığa dayalı hesaplanan yeni bir uzaklık ölçütü önerilmiştir. Uzaklık ölçütleri için yapılan bu katkıyla, yürüyüş örüntülerinde diğer uzaklık ölçütlerine göre performansı artırılmıştır. Bu noktada yürüyüş esnasında birkaç örnek alınabildiğinden, çevrimiçi uygulamalarda kullanılmak üzere, sınıflar arasındaki uzaklık hesabı önerilen yaklaşım için de gerçekleşmiştir.

Son zamanlarda ilgi çeken DVM sınıflandırıcısı, test sınıfından bir örneği eğitim sınıfları ile karşılaştırmaktadır. DVM ile sınıflandırma işleminin sınıflar arasında yapılması kullanılan LibSVM kütüphanesine uyarlanmıştır. Fakat her iki yaklaşımda da DVM, EYK'ya göre genel olarak performans getirisi oluşturmamıştır. DVM'nin parametre kestirimiyle uzun eğitim süreci dezavantajından dolayı EYK sınıflandırıcısı tercih edilmiştir.

Yürüyüş şekli biyometrik özelliğinin, gelecekte kimlik tespiti amacıyla çeşitli avantajlarından dolayı tercih edileceği öngörülmektedir. Bu bağlamda geliştirilen yaklaşımların gerçek hayatta uygulanabilirliği önem kazanmaktadır. Çalışmalarımızda, önerilen yaklaşımların uygulamaları C++ programlama dilinde geliştirilmiş olup, çevrimiçi platformlara uyarlanabilir modülerliğe sahiptirler.

5. ÖNERİLER

Düşük çözünürlükteki görüntülerle uzaktan kimlik tanıma çalışmalarında yürüyüş şekli davranışsal biyometrik özelliği, yakın gelecekte pek çok alanda kullanılacaktır. Bu yönde yapılan ön çalışmalar bir sonraki safhaya geçmek için yeterlidir. Bir sonraki safha, çevrimiçi sistemler oluşturup, daha büyük veritabanlarıyla gerçek zamanlı deneyler yapmaktır. Bunun için gözetleme sisteminin doğru ve tutarlı olması gereklidir.

Yürüyüş şeklinden kişi tanıma çalışmaları, son zamanlarda siluet tabanlı olarak daha iyi performans sağlamıştır. Kolay üretime sahip YEİ, bunun en bariz örneğidir. Önerilecek yeni yürüyüş örüntüsü yaklaşımları bu yönde, anlık değişimleri daha iyi temsil edecek şekilde olmalıdır.

Yürüyüş, bir süre içerisinde sürekli değişen karmaşık bir eylemdir. Yürüyüş ritminin yakalanması, dönme, el kol hareketleri gibi aktivitelerden ve ortamdaki kapanma gibi problemlerden dolayı zordur. Bu nedenle, farklı yön bakışlarında yürüyüş ritminin araştırılması performansı arttırabilir.

Sürekli gelişmekte olan örüntü tanıma yaklaşımları için özellik çıkarma yaklaşımlarından çekirdekli ve 2-boyutlular, günümüzde daha çok revaçtadır. Yeni sayılabilecek yürüyüş şekli biyometrik özelliği için, hala denenmemiş özellik çıkarma yöntemlerinin uygulanması, yürüyüş şeklinden kişi tanımaya daha efektif çözümler getirebilir. Diğer taraftan mevcut parametrelilik özellik çıkarma yaklaşımlarının çevrimiçi sistemlerde kullanılabilirliği otomatik parametre kestirimleriyle sağlanabilir.

Yürüyüş örüntülerinin sınıflandırılmasında genellikle EYK ve DVM tabanlı yaklaşımlar kullanılmıştır. Diğer sınıflandırma yaklaşımlarıyla performans artışı sağlanabilir.

Yürüyüş şekli, eşya taşıma, farklı kalınlıkta elbise giyme veya giyilen elbisenin rahatlığı gibi etkenlerin yanında kişinin ruhsal durumundan da etkilenebilir. Bu bağlamda yürüyüş esnasında ruhsal durumları da değerlendirmek ve etkilerini görmek gerekebilir.

Yürüyüş şekli, diğer biyometrik özelliklere alternatif olmasının yanında destekleyici olarak da kullanılabilir. Yüz tanıma veya cihazla teması gerektiren diğer biyometrik sistemler için, yaklaşan kişilerin yürüyüş şeklinden kimliklendirilmesiyle kişisel imza veritabanında karşılaştırılacak örnek sayısı azaltılabilir.

Sonu olarak, yryş Őeklinin biyometrik zellik olarak kullanılmasında kimlik doęrulamadan ziyade, serbest dolaşımdaki kişilerin kimlik tespiti amaçlanmaktadır. Bu gzetleme sistemlerinde, nesne algılayıp takip etme yanında, nesne analizi, hareketlerin yorumlanması, ruhsal durum deęerlendirmesi gibi iřlem ykleri de getirir. Ayrık alıřılan bu alanlardaki veriler birleřtirilebildięi takdirde, yryş Őekli biyometrik zellięine dayalı otomatik kimlik tespit etme sistemi gncel hayata geirilebilecektir.

6. KAYNAKLAR

1. Jain, A.K., Ross, A. ve Prabhakar, S., An Introduction to Biometric Recognition, IEEE Trans. on Circuits and Systems for Video Technologies, 14,1 (2004) 4-20.
2. Bromba, M., Biyometri ve Standartlar.
<http://www.bromba.com/faq/biofaq.htm#Biometrie> 15 Temmuz 2010.
3. <http://infowar.net/tia/www.darpa.mil/iao/HID.htm> Information Awareness Office, Human ID at a Distance (HumanID). 15 Temmuz 2010.
4. Åström, P., The Study of Ancient Fingerprints, Journal of Ancient Fingerprints.
http://www.ancientfingerprints.org/nr1_lo.pdf 15 Temmuz 2010.
5. Laufer, B., History of the Finger Print System.
<http://www.scafo.org/library/160201.html> 15 Temmuz 2010.
6. Murray, M.P., Drought, A.B. ve Kory, R.C., Walking Patterns of Normal Men, Journal of Bone and Joint Surgery (JBJS), 46,2 (1964) 335-360.
7. Johansson, G., Visual Motion Perception, Scientific American, 232,6 (1975) 75-88.
8. Cutting, J. ve Kozlowski, L., Recognizing Friends by Their Walk: Gait Perception Without Familiarity Cues, Bull. Psychon. Soc., 9,5 (1977) 353-356.
9. Niyogi, S. ve Adelson, E., Analyzing and Recognizing Walking Figures in XYT, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Haziran 1994, Seattle Wash, USA, 469-474.
10. Niyogi, S.A. ve Adelson, E.H., Analyzing Gait with Spatiotemporal Surface, In Proc. of IEEE Workshop on Motion of Non-rigid and Articulated Objects, Kasım 1994, Austin TX, USA, 64-69.
11. Murase, H. ve Sakai, R., Moving Object Recognition in Eigenspace Representation: Gait Analysis and Lip Reading, Pattern Recognition Letters, 17,2 (1996) 155-162.
12. Little, J. ve Boyd, J., Recognizing People by Their Gait: The Shape of Motion, Videre: Journal of Computer Vision Research, 1,2 (1998) 1-32.
13. Nixon, M.S., Automatic Gait Recognition for Human ID at a Distance, Southampton Database. <http://www.gait.ecs.soton.ac.uk/> 15 Temmuz 2010.
14. http://www.darpa.mil/news/2002/darpa_fact.html DARPA Programlarının Özeti. 15 Temmuz 2010.

15. <http://cpl.cc.gatech.edu/projects/hid/> Computational Perception Laboratory (Georgia Tech.), Human Identification at a Distance (HumanID). 15 Temmuz 2010.
16. Gross, R. ve Shi, J., The CMU Motion of Body (MOBO) Database, Tech. Rep. CMU-RI-Tr-01-18, Robotics Institute, Carneige Mellon University, 2001.
17. Kale, A., Human Identification at a Distance (HumanID), UMD Database. <http://www.umiacs.umd.edu/labs/pirl/hid/data.html> 15 Temmuz 2010
18. Veeraraghavan, A., Roy-Chowdhury, A.K. ve Chellappa, R., Matching Shape Sequences in Video with Applications in Human Movement Analysis, IEEE Trans. Pattern Anal. Mach. Intell., 27,12 (2005) 1896-1909.
19. Phillips, P.J., Sarkar, S., Robledo, I., Grother, P. ve Bowyer, K., The Gait Identification Challenge Problem: Data Sets and Baseline Algorithm, 16th International Conference on Pattern Recognition (ICPR'02), Ağustos 2002, Quebec City, Canada, 385-388.
20. Sarkar, S., Baseline Algorithm and Performance for Gait Based Human ID Challenge Problem. <http://marathon.csee.usf.edu/GaitBaseline/> 15 Temmuz 2010.
21. <http://www.cbsr.ia.ac.cn/english/Gait%20Databases.asp> CASIA Gait Database, Center for Biometrics and Security Research. 15 Temmuz 2010.
22. Orr, R.J. ve Abowd, G.D., The Smart Floor: A Mechanism for Natural User Identification and Tracking, In Proceedings of the Conference on Human Factors in Computing Systems, Nisan 2000, The Hague, The Netherlands, 275-276.
23. Suutala, J. ve Rning, J., Towards the Adaptive Identification of Walkers: Automated Feature Selection of Footsteps Using Distinction Sensitive LVQ, In Int. Workshop on Processing Sensory Information for Proactive Systems, Ocak 2004, Oulu, Finland, 61-67.
24. Middleton, L., Buss, A.A., Bazin, A. ve Nixon, M.S., A Floor Sensor System for Gait Recognition, In Fourth IEEE Workshop on Automatic Identification Advanced Technologies, Ekim 2005, Buffalo, New York, 171-176.
25. Morris, S.J., A Shoe-Integrated Sensor System for Wireless Gait Analysis and Realtime Therapeutic Feedback, PhD Thesis, Harvard - MIT Division of Health Sciences and Technology, USA, 2004.
26. Ailisto, H.J., Lindholm, M., Mäntyjärvi, J., Vildjiounaite, E. ve Mäkelä, S.T., Identifying People from Gait Pattern with Accelerometers, Journal Of Computers, 1,7 (2006) 51-59.
27. Gafurov, D., Helkala, K. ve Sondrol, T., Gait Recognition Using Acceleration from MEMS, In First IEEE International Conference on Availability, Reliability and Security, Nisan 2006, Vienna, Austria, 432-437.

28. Gafurov, D., Snekenes, E. ve Bours, P., Gait Authentication and Identification Using Wearable Accelerometer Sensor, In 5th IEEE Workshop on Automatic Identification Advanced Technologies, Haziran 2007, Alghero, Italy, 220-225.
29. Gedikli, E., Gerçek Zamanda Hareketli Nesnelerin İzlenmesi ve Aktivite Analizi, Yüksek Lisans Tezi, Fen Bilimleri Enst., K.T.Ü., Trabzon, 2004.
30. Ekinci, M. ve Gedikli, E., Background Estimation Based People Detection and Tracking for Video Surveillance, Lecture Notes in Computer Science, 2869 (2003) 421-429.
31. Ekinci, M. ve Gedikli, E., Silhouette Based Human Motion Detection and Analysis for Real-Time Automated Video Surveillance, Turkish Journal of Electrical Engineering and Computers, 3,2 (2005) 199-229.
32. Kale, A., Rajagopalan, A.N., Sundaresan, A., Cuntoor, N., Roy-Chowdhury, A., Kruger, V. ve Chellappa, R., Identification of Humans Using Gait, IEEE Transactions on Image Processing, 13,9 (2004) 1163-1173.
33. BenAbdelkader, C., Cutler, R. ve Davis, L., Stride and Cadence as a Biometric in Automatic Person Identification and Verification, In Proc. IEEE Face and Gesture Recognition, Mayıs 2002, Washington DC, USA, 372-377.
34. Bobick, A.F. ve Johnson, A.Y., Gait Recognition Using Static, Activity-Specific Parameters, IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'01), Aralık 2001, Kauai HI, USA, 423-430.
35. Cunado, D., Nixon, M.S. ve Carter, J.N., Automatic Extraction and Description of Human Gait Models for Recognition Purposes, Comput. Vis. Image Understand., 90,1 (2003) 1-41.
36. Cunado, D., Nixon, M.S. ve Carter, J.N., Using Gait as a Biometric, via Phase-Weighted Magnitude Spectra, Audio- and Video-Based Biometric Person Authentication, Lecture Notes in Computer Science, 1206 (1997) 93-102.
37. Kim, D., Lee, S. ve Paik, J., Active Shape Model-Based Gait Recognition Using Infrared Images, International Journal of Signal Processing, Image Processing and Pattern Recognition, 61 (2009) 275-281.
38. Dockstader, S.L., Berg, M.J. ve Tekalp, A.M., Stochastic Kinematic Modeling and Feature Extraction for Gait Analysis, IEEE Transactions on Image Processing, 12,8 (2003) 962-976.
39. Lee, L. ve Grimson, W.E.L., Gait Analysis for Recognition and Classification, Fifth IEEE International Conference on Automatic Face and Gesture Recognition, Mayıs 2002, Washington DC, USA, 155-162.

40. Tanawongsuwan, R. ve Bobick, A., Gait Recognition from Time-Normalized Joint-Angle Trajectories in the Walking Plane, in Proc. IEEE Computer Vision and Pattern Recognition (CVPR'01), Aralık 2001, Kauai, Hawaii, USA, 726-731.
41. Urtasun, R. ve Fua, P., 3D Tracking for Gait Characterization and Recognition, Sixth IEEE International Conference on Automatic Face and Gesture Recognition (FGR'04), Mayıs 2004, Seoul, Korea, 17-22.
42. Wagg, D.K. ve Nixon, M.S., On Automated Model-Based Extraction and Analysis of Gait, Sixth IEEE International Conference on Automatic Face and Gesture Recognition (FGR'04), Mayıs 2004, Seoul, Korea, 11-16.
43. Wang, L., Tan, T., Ning, H. ve Hu, W., Fusion of Static and Dynamic Body Biometrics for Gait Recognition, IEEE Trans. Circuits Syst. Video Technol., 14,2 (2004) 149-158.
44. Yam, C.Y., Nixon, M.S. ve Carter, J. N., Automated Person Recognition by Walking and Running via Model-Based Approaches, Pattern Rec., 37,5 (2004) 1057-1072.
45. Yoo, J.H. ve Nixon, M.S., Markerless Human Gait Analysis via Image Sequences, In Proceedings of International Society of Biomechanics XIXth Congress, Temmuz 2003, Dunedin, New Zeland, CD-ROM.
46. Zhang, J., Collins, R. ve Liu, Y., Representation and Matching of Articulated Shapes, IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'04), Haziran 2004, Washington DC, USA, 342-349.
47. Zhang, R., Vogler, C. ve Metaxas, D., Human Gait Recognition, Conference on Computer Vision and Pattern Recognition Workshop (CVPRW'04), Haziran 2004, Washington DC, USA, 18.
48. Huang X. ve Boulgouris, N.V., Model-Based Human Gait Recognition Using Fusion of Features, IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP'09), Nisan 2009, Taipei, Taiwan, 1469-1472.
49. BenAbdelkader, C., Cutler, R. ve Davis, L., Eigengait: Motion-Based Recognition of People Using Image Self-Similarity, Lecture Notes in Computer Science (LNCS), 2091 (2001) 284-294.
50. BenAbdelkader, C., Cutler, R. ve Davis, L., Motion-Based Recognition of People in EigenGait Space, Proceedings of the Fifth IEEE International Conference on Automatic Face and Gesture Recognition (FGR'02), Mayıs 2002, Washington DC, USA, 267-272.
51. Bhanu, B. ve Han, J., Human Recognition on Combining Kinematic and Stationary Features, Lecture Notes in Computer Science, 2688 (2003) 600-608.
52. Boyd, J. E., Synchronization of Oscillations for Machine Perception of Gaits, Comput. Vis. Image Understand., 96 (2004) 35-59.

53. Chen, C.H., Liang, J.M., Zhao, H., Hu, H. ve Tian J., Factorial HMM and Parallel HMM for Gait Recognition, IEEE Transactions on Systems Man and Cybernetics Part C-Applications and Reviews, 39,1 (2009) 114-123.
54. Collins, R., Gross, R. ve Shi, J., Silhouette-Based Human Identification from Body Shape and Gait, Proc. of the Fifth IEEE International Conference on Automatic Face and Gesture Recognition (FGR'02), Mayıs 2002, Washington DC, USA, 366-371.
55. Foster, J.P., Nixon, M.S. ve Prugel-Bennet, A., Automatic Gait Recognition Using Area-Based Metrics, Pattern Recognition Letters, 24,14 (2003) 2489-2497.
56. Han, J. ve Bhanu, B., Statistical Feature Fusion for Gait-Based Human Recognition, Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'04), Haziran 2004, Washington DC, USA, 842-847.
57. Han, J. ve Bhanu, B., Individual Recognition Using Gait Energy Image, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28,2 (2006) 316-322.
58. Hayfron-Acquah, J.B., Nixon, M.S. ve Carter, J.N., Automatic Gait Recognition by Symmetry Analysis, Pattern Recognition Letters, 24,13 (2003) 2175-2183.
59. Hayfron-Acquah, J.B., Nixon, M.S. ve Carter, J.N., Human Identification by Spatio-Temporal Symmetry, 16th International Conference on Pattern Recognition, Proceedings (ICPR'02), Ağustos 2002, Washington DC, USA, 632-635.
60. Huang, P., Harris, C. ve Nixon, M., Recognizing Humans by Gait via Parametric Canonical Space, Artificial Intelligence in Engineering, 13,4 (1999) 359-366.
61. Huang, P.S., Harris, C.J. ve Nixon, M.S., Canonical Space Representation for Recognizing Humans by Gait and Face, IEEE Southwest Symposium on Image Analysis and Interpretation, Nisan 1998, Tucson AZ, USA, 180-185.
62. Lee, C.S. ve Elgammal, A., Gait Style and Gait Content: Bilinear Models for Gait Recognition Using Gait Re-Sampling, in Proc. IEEE International Conference Face and Gesture Recognition (FGR'04), Mayıs 2004, Seoul, Korea, 147-152.
63. Li, X.L., Maybank, S.J., Yan, S.C., Tao, D.C. ve Xu, D.J., Gait Components and Their Application to Gender Recognition, IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, 38,2 (2008) 145-155.
64. Liu, J.Y. ve Zheng, N.N., Gait History Image: A Novel Temporal Template for Gait Recognition, Proceedings of the IEEE International Conference on Multimedia and Expo (ICME 2007), Temmuz 2007, Beijing, China, 663-666.
65. Liu, Y., Collins, R. ve Tsin, Y., Gait Sequence Analysis Using Frieze Patterns, Lecture Notes in Computer Science, 2351 (2002) 657-671.

66. Liu, Z. ve Sarkar, S., Simplest Representation Yet for Gait Recognition: Averaged Silhouette, In Proc. 17th International Conference on Pattern Recognition (ICPR'04), Ağustos 2004, Cambridge, United Kingdom, 211-214.
67. Nixon, M.S. ve Carter, J.N., Advances in Automatic Gait Recognition, Sixth IEEE International Conference on Automatic Face and Gesture Recognition (FGR'04), Mayıs 2004, Seoul, Korea, 139-144.
68. Sarkar, S., Phillips, P., Liu, J., Vega, I., Grother, P. ve Bowyer, K., The HumanID Gait Challenge Problem: Data Sets, Performance, and Analysis, IEEE Transactions on Pattern Analysis, Machine Intelligence, 27,2 (2005) 162-177.
69. Shutler, J. ve Nixon, M., Zernike Velocity Moments for Description and Recognition of Moving Shapes, Proceedings of the British Machine Vision Conference (BMVC 2001), Eylül 2001, Manchester, United Kingdom, 705-714.
70. Sundaresan, A., Chowdhury, A. ve Chellappa, R., A Hidden Markov Model Based Framework for Recognition of Humans from Gait Sequences, Proc. International Conference Image Processing (ICIP 2003), Eylül 2003, Barcelona, Spain, 143-150.
71. Tolliver, D. ve Collins, R., Gait Shape Estimation for Identification, International Conference Audio and Video-Based Biometric Person Authentication, Lecture Notes in Computer Science, 2668 (2003) 734-742.
72. Vega, I. R. ve Sarkar, S., Statistical Motion Model Based on the Change of Feature Relationships: Human Gait-Based Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 25,10 (2003) 1323-1328.
73. Veres, G., Carter, J.N. ve Nixon, M.S., What Image Information is Important in Silhouette-Based Gait Recognition, In Proc. IEEE Computer Vision and Pattern Recognition (CVPR 2004), Haziran 2004, Washington DC, USA, 776-782.
74. Wang, L., Tan, T.N., Hu, W.M. ve Ning, H.Z., Automatic Gait Recognition Based on Statistical Shape Analysis, IEEE Transactions on Image Processing, 12,9 (2003) 1120-1131.
75. Wang, L., Tan, T., Ning, H.Z. ve Hu, W.M., Silhouette Analysis-Based Gait Recognition for Human Identification, IEEE Transactions on Pattern Analysis and Machine Intelligence, 25,12 (2003) 1505-2528.
76. Yu, S., Tan, T., Huang, K., Jia, K. ve Wu, X., A Study on Gait Based Gender Classification, IEEE Transactions on Image Processing, 18,8 (2009) 1905-1909.
77. Zhao, G., Chen, R., Liu, G. ve Hua, L., Amplitude Spectrum-Based Gait Recognition, Sixth IEEE International Conference on Automatic Face and Gesture Recognition (FGR'04), Mayıs 2004, Seoul, Korea, 23-28.
78. Ekinci, M. ve Aykut, M., Improved Gait Recognition by Multiple-Projections Normalization, Machine Vision Applications, 21,2 (2010) 143-161.

79. Cuntoor, N., Kale, A. ve Chellappa, R., Combining Multiple Evidences for Gait Recognition, International Conference on Multimedia and Expo (ICME'03), Temmuz 2003, Baltimore, MD, USA, 113-116.
80. Huang, X. ve Boulgouris, N.V., Human Gait Recognition Based on Multiview Gait Sequences, EURASIP Journal on Advances in Signal Processing, 2008 (2008) 1-8.
81. Yu, S., Tan, D. ve Tan, T., A Framework for Evaluating the Effect of View Angle, Clothing and Carrying Condition on Gait Recognition, 18th International Conference on Pattern Recognition, Ağustos 2006, Hong Kong, China, 441-444.
82. Singh, S. ve Biswas, K.K., Biometric Gait Recognition with Carrying and Clothing Variants, Pattern Recognition and Machine Intelligence, Lecture Notes in Computer Science, 5909 (2009) 446-451.
83. Chen, C., Liang, J., Zhao, H. ve Tian, J., Frame Difference Energy Image for Gait Recognition with Incomplete Silhouettes, Pattern Recognition Letters, 30,11 (2009) 977-984.
84. Lu, J. ve Tan, Y.P., Uncorrelated Discriminant Simplex Analysis for View-Invariant Gait Signal Computing, Pattern Recognition Letters, 31,5 (2010) 382-393.
85. Liu, J., Zheng, N. ve Xiong, L., Silhouette Quality Quantification for Gait Sequence Analysis and Recognition, Signal Processing, 89,7 (2009) 1417-1427.
86. Yang, X., Zhou, Y., Zhang, T., Shu, G. ve Yang, J., Gait Recognition Based on Dynamic Region Analysis, Signal Processing, 88,9 (2008) 2350-2356.
87. Lee, H., Hong, S. ve Kim, E., Neural Network Ensemble with Probabilistic Fusion and Its Application to Gait Recognition, Neurocomputing, 72 (2009) 1557-1564.
88. Bashir, K., Xiang, T. ve Gong, S., Feature Selection on Gait Energy Image for Human Identification, In Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2008), Mart 2008, Las Vegas, Nevada, USA, 985-988.
89. Lam, T.H.W., Lee, R.S.T. ve Zhang, D., Human Gait Recognition by the Fusion of Motion and Static Spatio-Temporal Templates, Pattern Recognition, 40 (2007) 2563-2573.
90. Ioannidis, D., Tzovaras, D., Damousis, I.G., Argyropoulos, S. ve Moustakas, K., Gait Recognition Using Compact Feature Extraction Transforms and Depth Information, IEEE Transactions on Information Forensics and Security, 2,3 (2007) 623-630.
91. Boulgouris, N.V. ve Chi, Z.X., Gait Recognition Using Radon Transform and Linear Discriminant Analysis, IEEE Trans. on Image Processing, 16,3 (2007) 731-740.
92. Boulgouris, N.V., Plataniotis, K.N. ve Hatzinakos, D., Gait Recognition Using Linear Time Normalization, Pattern Recognition, 39 (2006) 969-979.

93. Tan, D., Huang, K., Yu, S. ve Tan, T., Uniprojective Features for Gait Recognition, Lecture Notes in Computer Science, 4642 (2007) 673–682.
94. Lee, S., Liu, Y. ve Collins, R., Shape Variation-Based Frieze Pattern for Robust Gait Recognition, IEEE Conference on Computer Vision and Pattern Recognition (CVPR'07), Haziran 2007, Minneapolis, Minnesota, USA, 1-8.
95. Xu, D., Yan, S., Tao, D., Zhang, L., Li, X. ve Zhang, H.J., Human Gait Recognition with Matrix Representation, IEEE Transactions on Circuits and Systems for Video Technology, 16,7 (2006) 896-902.
96. Zongyi, L. ve Sarkar, S., Improved Gait Recognition by Gait Dynamics Normalization, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28,6 (2006) 863-876.
97. Tao, D., Li, X., Wu, X. ve Maybank, S.J., General Tensor Discriminant Analysis and Gabor Features for Gait Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 29,10 (2007) 1700-1715.
98. Chai, Y., Ren, J., Zhao, R. ve Jia, J., Automatic Gait Recognition Using Dynamic Variance Features, Proceedings of the 7th International Conference on Automatic Face and Gesture Recognition (FGR'06), Mart 2006, United Kingdom, 475-480.
99. Nixon, M.S., Carter, J.N., Grant, M.G., Gordon, L. ve Hayfron-Acquah, J.B., Automatic Recognition by Gait: Progress and Prospects, The Emerland Research Register, 23,4 (2003) 233-331.
100. Kale, A., Rajagopalan, A.N., Cuntoor, N. ve Kruger, V., Gait-Based Recognition of Humans Using Continuous HMMs, Proceedings of the Fifth IEEE International Conference on Automatic Face and Gesture Recognition (FGR'02), Mayıs 2002, Washington DC, USA, 336-341.
101. Kale, A., Cuntoor, N., Yegnanarayana, B., Rajagopalan, A.N. ve Chellappa, R., Gait Analysis for Human Identification, Proc. of the 4th International Conf. on Audio and Video-Based Biometric Person Authentication (AVBPA 2003), Haziran 2003, Guildford, United Kingdom, 706-714.
102. Xu, D., Yan, S., Tao, D., Lin, S. ve Zhang, H.-J., Marginal Fisher Analysis and Its Variants for Human Gait Recognition and Content-Based Image Retrieval, IEEE Transactions on Image Processing, 16,11 (2007) 2811-2821.
103. Wang, W., Liang, J., Hu, H. ve Zhao, H., Human Gait Recognition Based on Kernel Independent Component Analysis, 9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications (DICTA 2007), Aralık 2007, Glenelg, Australia, 573-578.
104. Lee, L., Dalley, G. ve Tieu, K., Learning Pedestrian Models for Silhouette Refinement, Proceedings of the Ninth IEEE International Conference on Computer Vision (ICCV'03), Ekim 2003, Nice, France, 663-670.

105. Lu, J. ve Zhang, E., Gait Recognition for Human Identification Based on ICA and Fuzzy SVM Through Multiple Views Fusion, Pattern Recognition Letters, 28,16 (2007) 2401-2411.
106. Cheng, M.H., Ho, M.F. ve Huang, C.L., Gait Analysis for Human Identification Through Manifold Learning and HMM, Pattern Recognition, 41,8 (2008) 2541-2553.
107. Vega, I.R. ve Sarkar, S., Experiments on Gait Analysis by Exploiting Nonstationarity in the Distribution of Feature Relationships, Proceedings of the 16th International Conference on Pattern Recognition (ICPR'02), 2002, Quebec, Canada, 10001.
108. Phillips, P.J., Grother, P., Sarkar, S., Robledo, I. ve Bowyer, K., Baseline Results for the Challenge Problem of Human ID Using Gait Analysis, Proceedings of the Fifth IEEE International Conference on Automatic Face and Gesture Recognition (FGR'02), Mayıs 2002, Washington DC, USA, 137-142.
109. Ekinci, M. ve Aykut, M., Human Gait Recognition Based on Kernel PCA Using Projections, Journal of Computer Science and Technology, 22,6 (2007) 867-876.
110. Ekinci M., Gait Recognition Using Multiple Projections, In Proceeding of IEEE International Conference on Automatic Face and Gesture Recognition (FGR'06), Nisan 2006, Southampton, United Kingdom, 517-522.
111. Ekinci, M., A New Approach for Human Identification Using Gait Recognition, Lecture Notes in Computer Science, Computational Science and Its Applications, 3982 (2006) 1216-1226.
112. Ekinci, M., Aykut, M. ve Gedikli, E., Gait Recognition by Applying Multiple Projections and Kernel PCA, In Proceedings of Machine Learning and Data Mining in Pattern Recognition, Lecture Notes in Art. Intel., 4571 (2007) 727-741.
113. Ekinci, M. ve Gedikli, E., Gait Recognition Using View Distance Vectors, Lecture Notes in Artificial Intelligence, 3801 (2005) 973-978.
114. Ekinci, M. ve Gedikli, E., A Novel Approach on Silhouette Based Human Motion Analysis for Gait Recognition, Lecture Notes in Comp. Sci., 3804 (2005) 219-226.
115. Gedikli, E. ve Ekinci, M., Siluete Dayalı Kişi Tanıma, 15. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU'07), Haziran 2007, Eskişehir, CD-ROM.
116. Ekinci, M. ve Gedikli, E., Siluet Değişimine Dayalı Periyodik Hareket Analizi, Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Mayıs 2005, Kayseri, 320-323.
117. Ekinci, M., Gedikli, E. ve Nabiye, V.V., View Distance Based Human Motion Analysis, IAPR Conference on Machine Vision Applications (MVA2005), Mayıs 2005, Tsukuba Science City, Japan, 233-236.
118. Gedikli, E. ve Ekinci, M., Yürüme Örüntüsü Üretimine Farklı Bir Yaklaşım, Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Nisan 2009, Antalya, CD-ROM.

119. Zhang, E., Zhao, Y. ve Xiong, W., Active Energy Image Plus 2DLPP for Gait Recognition, Signal Processing, 90 (2010) 2295-2302.
120. Bashir, K., Xiang, T. ve Gong, S., Gait Recognition Without Subject Cooperation, Pattern Recognition Letters, 31,13 (2010) 2052-2060.
121. Xue, Z., Ming, D, Song, W., Wan, B. ve Jin, S., Infrared Gait Recognition Based on Wavelet Transform and Support Vector Machine, Pattern Recognition, 43 (2010) 2904-2910.
122. Amin, T. ve Hatzinakos, D., Wavelet Analysis of Cyclic Human Gait for Recognition, Proceedings of the 16th International Conference on Digital Signal Processing, Temmuz 2009, Santorini, Greece, 633-638.
123. Su, H., Liao, Z.W. ve Chen, G.Y, A Gait Recognition Method Using L1-PCA and LDA, Proceedings of the Eighth International Conference on Machine Learning and Cybernetics, Temmuz 2009, Baoding, China, 3198-3203.
124. Yu, S., Wang, L., Hu, W. ve Tan, T., Gait Analysis for Human Identification in Frequency Domain, Third International Conference on Image and Graphics (ICIG'04), Aralık 2004, Hong Kong, China, 282-285.
125. Bissacco, A., Saisan, P. ve Soatto, S., Gait Recognition Using Dynamic Affine Invariants, In Proc. Int'l Symp. Math. Theory of Networks and Systems (MTNS'04), Temmuz 2004, Leuven Belgium, 610-617.
126. Chen, S. ve Gao, Y., An Invariant Appearance Model for Gait Recognition, IEEE International Conference on Multimedia and Expo (ICME'07), Temmuz 2007, Beijing, China, 1375-1378
127. Zhang, E.H., Ma, H.B., Lu, J.W. ve Chen Y.J., Gait Recognition Using Dynamic Gait Energy and PCA+LPP Method, In IEEE International Conf. on Machine Learning and Cybernetics (ICMLC'09), Temmuz 2009, Baoding, China, 50-53.
128. Das, S.R., Wilson, R.C., Lazarewicz, M.T. ve Finkel, L.H., Two-Stage PCA Extracts Spatiotemporal Features for Gait Recognition, Jou. of Multimedia, 1,5 (2006) 9-17.
129. Duda, R.O., Hart, P.E. ve Stork, D.G., Pattern Classification, 2.Baskı, Wiley Publishing, New York, 2001.
130. Alpaydın, E., Introduction to Machine Learning, The MIT Press, London, 2004.
131. Sirovich, L. ve Kirby, M., Low-Dimensional Procedure for the Characterization of Human Faces, Journal of the Optical Society of America, 2 (1987) 519-524.
132. Schölkopf, B. ve Smola, A. J., Learning with Kernels, The MIT Press, London, 2002.

133. Press, W.H., Teukolsky, S.A., Vetterling, W.T. ve Flannery, B.P., Numerical Recipes in C++: The Art of Scientific Computing, 2. Baskı, Cambridge University Press, United Kingdom, 2002.
134. Vapnik, V.N., The Nature of Statistical Learning Theory, Springer Verlag, New York, 1995.
135. Belhumeur, P.N., Hespanha, J. ve Kriegman, D.J., Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, IEEE Transactions on PAMI, 19,7 (1997) 711-720.
136. Mika, S., Ratsch, G., Wetson, J., Schölkopf, B. ve Müller K.R., Fisher Discriminant Analysis with Kernels, IEEE International Workshop on Neural Networks for Signal Processing IX, Ağustos 1999, Madison, USA, 41-48.
137. Yu, H. ve Yang, J., A Direct LDA Algorithm for High Dimensional Data with Application to Face Recognition, Pattern Recognition, 34,12 (2001) 2067-2070.
138. Chen, L., Liao, H., Ko, M., Lin J. ve Yu, G., A New LDA Based Face Recognition System Which can Solve the Small Sample Size Problem, Pattern Recognition, 33,10 (2000) 1713-1726.
139. Cristianini, N. ve Taylor, J. S., An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods, Cambridge University Press, United Kingdom, 2000.
140. Scholkopf, B., Smola, A. ve Muller, K.R., Nonlinear Component Analysis as a Kernel Eigenvalue Problem, Neural Computation, 10 (1998) 1299-1319.
141. Kim, K.I., Jung, K. ve Kim, H.J., Face Recognition Using Kernel Principal Component Analysis, IEEE Signal Processing Letters, 9,2 (2002) 40-42.
142. Shawe-Taylor, J. ve Cristianini, N., Kernel Methods for Pattern Analysis, Cambridge University Press, United Kingdom, 2004.
143. Souza, C., Kernel Functions for Machine Learning Applications.
<http://crsouza.blogspot.com/2010/03/kernel-functions-for-machine-learning.html> 15 Temmuz 2010.
144. Baudat, G. ve Anouar, F., Generalized Discriminant Analysis Using a Kernel Approach, Neural Computation, 12,10 (2000) 2385-2404.
145. Nabiyeu, V.V., Yapay Zeka, Seçkin Yayınevi, Ankara, 2005.
146. Chang, C.C. ve Lin, C.J., LibSVM: A Library for Support Vector Machines.
<http://www.csie.ntu.edu.tw/~cjlin/libsvm/> 15 Temmuz 2010.
147. Abe, S., Pattern Classification: Neuro-Fuzzy Methods and Their Comparison, Springer Verlag, London, 2001.


148. Baytan, Ş.H., Ekinci, M., Alkanat, M., Gedikli, E., Okuyan, M., Erdogmus, E. ve Akgün, A., Alcohol Affects Gait Analysis in Rats, 10th International Conference on Cognitive Neuroscience, Eylül 2008, Bodrum, Turkey.
149. Gedikli, E., Ekinci, M., Baytan Ş.H. ve Alkanat, M., Fiziksel ve Psikolojik Değerlendirmeler İçin Kameralı Labirent, Ç.Ü. Mühendislik-Mimarlık Fakültesi 30. Yıl Sempozyumu, Ekim 2008, Adana, 6-10.
150. Baytan, S.H., Alkanat, M., Okuyan, M., Ekinci, M., Gedikli, E., Özeren M. ve Akgün, A., Simvastatin Impairs Spatial Memory in Rats at a Specific Dose Level, The Tohoku Journal of Experimental Medicine, 214 (2008) 341-349.
151. Kong, H., Wang, L., Teoh, E.K., Wang, J.G. ve Ronda, V., Generalized 2D Principal Component Analysis, International Joint Conference on Neural Networks (IJCNN 2005), Temmuz 2005, Montréal, Québec, Canada, 585-594.
152. Yang, J., Zhang, D., Frangi, A.F. ve Yang, J., Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition, IEEE Transactions on PAMI, 26,1 (2004) 131-137.
153. Turk, M. ve Pentland, A., Eigenfaces for Recognition, Journal of Cognitive Neuroscience, 3,1 (1991) 71-86.
154. Zhao, L. ve Yang, Y., Theoretical Analysis of Illumination in PCA-Based Vision Systems, Pattern Recognition, 32,4 (1999) 547-564.
155. Lu, J., Plataniotis, K.N. ve Venetsanopoulos, A.N., Face Recognition Using Kernel Direct Discriminant Analysis Algorithms, IEEE Transactions on Neural Networks, 14,1 (2003) 117-126.
156. BenAbdelkader, C., Cutler, R.G. ve Davis L.S., Gait Recognition Using Image Self-Similarity, EURASIP Journal on Applied Signal Processing, 4 (2004) 572-585.

7. EKLER

Ek-1. Yürüyüş Veritabanları

7.1.1. CMU Yürüyüş Veritabanı

Mart 2001 de Carnegie Mellon Üniversitesi, Robotik Enstitüsü tarafından oluşturulmuştur. Motion of Body (MoBo) diye geçen veritabanında 25 kişi (23 erkek, 2 bayan) yürüme bandında yavaş, hızlı ve eğik yürüyüşlerin top taşırken ve normal durumlarda, 6 farklı görüş açısından çözünürlüğü yüksek kameralarla kayıt edilmiştir. Her kişi için 11 saniyede, ortalama 10 periyotluk yürüyüş görüntü kaydı yapılmıştır. Görüntüler 24-bit renk olarak 640x480 çözünürlüktedir. Veritabanında, her bir kişi için ortalama 15 dakika süre içerisinde alınan kayıtlardan, toplamı 7 GB olan 8160 görüntü üretilmiştir. Veritabanı tamamı, sıkışmamış halde 175 GB (PPM format), sıkışmış halde 9.9 GB (JPG format) kapasiteye ihtiyaç duyar.



Ek Şekil 1. CMU MoBo veritabanı için kameraların konumu

Ek Tablo 1. CMU yürüyüş veritabanı özeti

Yürüyüş yeri	Kapalı ortam, yürüme bandı
Kişiler	25
Görüş, bakış	6
Senkronizasyon	Evet
Yürüme şekilleri	4
Dizi uzunluğu (sn)	11
Piksel yüksekliği	500
Çerçeve oranı (fps)	30
Sıkışmamış boyut (GB)	175
Sıkışmış boyut (GB)	9.9

Ek-1'in devamı



V1=vr13_7 V2=vr05_7 V3=vr07_7 V4=vr03_7 V5=vr16_7 V6=vr17_7

Ek Şekil 2. CMU MoBo veritabanı örnek resimler

Veritabanı yürüme özellikleri şöyledir:

- Yavaş Yürüme: Yürüme bandının hızı, yürüme hızına ayarlanmıştır. Ortalama yürüme hızı 2,06 mph¹
- Hızlı Yürüme: Yürüme bandının hızı 2,82 mph'ye ayarlanmıştır.
- Eğik Yürüme: Yürüme bandının önü 15 derece kadar yukarı kaldırılmıştır. Yürüme hızı 1,96 mph'dir.
- Top ile beraber yürüme : Top iki el ile beraber göğüs hizasında tutulur. Normal yürüyüştür. Yürüme hızı ortalama 2,04 mph'dir.

Ek Tablo 2. CMU yürüyüş veritabanı kayıt düzeni

Kişi NO	Aktivite	Bakış	İmgeler
04006	ball	Vr03_7	im25_03292400.ppm im25_03292401.ppm im25_032925009.ppm
		Vr03_7	
		Vr03_7	
		Vr03_7	
		Vr03_7	
		Vr03_7	
	slowWalk		
	FastWalk		
	Incline		
	bgImage		

¹ Saatte alınan mil miktarı, 1 mil = 1609.334 metre (karada) , 1852.2 metre (denizde)

Ek-1'in devamı

CMU yürüyüş veritabanı için yayınlarda kullanımına izin verilen görüntüler 04002, 04006, 04013, 04015 ve 04086'dır. Veritabanının oluşturulması, U.S. Office of Naval Research (ONR), N00014-00-1-0915 nolu anlaşma ile desteklenmiştir.

7.1.2. SOTON Yürüyüş Veritabanı

Yürüyüşten kişi tanıma için Southampton Üniversitesi'nde oluşturulmuş iki tip veritabanı vardır: Büyük veritabanı (116 kişi) ve küçük veritabanı (12 kişi).²

SOTON Büyük (Large) Yürüyüş Veritabanı : SOTON büyük veritabanı 2001 yazında kaydedilmiştir. Her bir nesnenin 6 farklı kaydı vardır: Önden, paralel ve eğri yönlerin her biri için 2 şer tane dizi. 3 senaryo vardır: Dışarıda, içeride normal yürüme ve içeride yürüme bandı ile yürüme. Bütün veriler digital video (DV) dosyası olarak en az bir periyot yürüyüş içerecek parçalar şeklinde kayıt edilmiştir. SOTON büyük veritabanının dosya kayıt biçimi "SSSCNNNT00D.dv" şeklindedir. İsimlendirme aşağıdaki anlama gelir.

- SSS : oturum numarası
- C : Kamera no
 - o "a" : normal yürüme
 - o "d" : eğik yürüme
 - o "b" : normal yürüme bandı
 - o "c" : eğik yürüme bandı
 - o "e" : dışarıda normal
 - o "f" : dışarıda eğik
- NNN : nesne numarası
- T : veri tipi
 - o "b" : arkaplan
 - o "s" : nesne
- 00 : Dizi numarası
- D : yürüme yönü
 - o "L" : sahnede sola doğru yürüme
 - o "R" : sahnede sağa doğru yürüme

Ek Şekil 3'te SOTON büyük veritabanı ve Ek Şekil 4'te SOTON küçük veritabanı için örnek görüntüler verilmiştir.

² <http://www.gait.ecs.soton.ac.uk/links.php3>

Ek-1'in devamı



(a) (b) (c)
Ek Şekil 3. SOTON büyük veritabanı, (a) normal yürüme, (b) yürüme bandında normal yürüme, (c) dışarıda normal yürüme

SOTON Küçük (small) Yürüyüş Veritabanı : Küçük veritabanı en az 10 (sonradan 2 tane daha eklenerek 12) nesnenin içeride bir yeşil arka font önündeki yürüyüş kayıtlarıdır. Her bir nesne çeşitli ayakkabı, giysi giyer ve farklı çantalar taşırlar. Kişilerin farklı hızlarda kayıtları alınmıştır. Kayıt biçimi, still fotoğraf (2240x1680) formatındadır.



(a) normal yürüme



(b) eğik yönde yürüme



(c) normal rahat yürüme



(d) dikey yürüme

Ek Şekil 4. SOTON küçük veritabanı yürüyüş senaryoları

Ek-1'in devamı

Dosya biçimi 'SSSCNNNTEEEe00D.dv' şeklindedir. İsimlendirme aşağıdaki anlamları taşır.

- SSS : oturum numarası
- C : Kamera no
 - o "a" : normal yürüme
 - o "d" : eğik yürüme
 - o "e" : dışarıda normal
 - o "f" : dışarıda eğik
- NNN : nesne numarası
- T : veri tipi
 - o "b" : arkaplan
 - o "s" : nesne
- EEEe : Deney numarasıdır. Buradaki küçük "e" - ayıraç karakteridir.
 - o "000" : terlikle(parmak arasına girer, flip flop) yürüme
 - o "001" : çıplak ayakla yürüme
 - o "002" : çorapla yürüme
 - o "003" : botla yürüme
 - o "004" : eşofman ile yürüme
 - o "005" : kişinin kendi ayakkabıları ile yürümesi
 - o "006" : yağmurluk giyerek yürüme
 - o "007" : uzun palto (dize kadar inen) ile yürüme
 - o "008" : el çantası ile yürüme
 - o "009" : sırtı komple kaplayacak şekilde büyük sırt çantası ile yürüme
 - o "010" : el veya omuzda taşınabilen çanta ile yürüme
 - o "011" : sırt çantası ile yürüme
 - o "012" : yavaş yürüme
 - o "013" : hızlı yürüme
 - o "014" : "005" teki şartlarda normal yürüme
- 00 : Dizi numarası
- D : yürüme yönü
 - o "L" : sahnede sola doğru yürüme
 - o "R" : sahnede sağa doğru yürüme

Mayıs 2001

Ayakkabı	Çanta yok		Çantalı	
A	CAL	GAL	CAL	GAL
B	CBL	GBL	CBL	GBL
A	CAR	GAR	CAR	GAR
B	CBR	GBR	CBR	GBR
	Beton	Çim	Beton	Çim

Kasım 2001

Çanta yok		Çantalı		
CAL	GAL	CAL	GAL	Sol
CBL	GBL	CBL	GBL	kamera
CAR	GAR	CAR	GAR	Sağ
CBR	GBR	CBR	GBR	kamera
Beton	Çim	Beton	Çim	

Ek Şekil 5. USF yürüyüş veritabanları değişken tablosu

Ek-1'in devamı

7.1.3. USF Yürüyüş Veritabanları

USF veritabanları, South Florida (USF) Üniversitesi tarafından 122 kişi ile 20-21 Mayıs ve 15-16 Kasım 2001 tarihlerinde oluşturulmuştur. Her iki zamanda ortak 33 kişinin kaydı vardır. Kayıtlarda 5 periyotluk yürüme verisi mevcuttur. Kayıtlar dışarıda, sabit bir kamera önünde eliptik bir yol üstündeki yürüyüşleri içermektedir. Her bir kişi 5 farklı şekilde yürümüştür:

- 2 farklı ayakkabı (A ve B),
- 2 farklı yük (çantalı veya çantasız),
- 2 farklı yüzey (çim ve beton),
- 2 farklı yön (sağ ve sol)
- 2 farklı zaman

Yani her bir kişinin 32 farklı yürüyüş şekli olabilir. Fakat veritabanında herkes için bütün şartlarda yürüme kaydı yoktur. Veritabanının 122 kişinin 1870 dizisi paylaşılmaktadır. Toplam sıkışmamış boyutu 1.2 TB'tır. USF Veriseti düzeni Ek Şekil %'te verilmiştir.



Ek Şekil 6. USF Veritabanı için kayıt sahneleri

7.1.4. CASIA Yürüyüş Veritabanları

CASIA yürüyüş veritabanı, yürüyüş tanıma amacıyla The Institute of Automation, Chinese Academy of Sciences (CASIA) oluşturulmuştur. Üç veri setinden oluşur: A veri seti, B veri seti (Çok yönlü veriset), veri seti C (infrared veriset).

CASIA Veriset A : 10.12.2001 tarihinde oluşturulmuş 20 kişilik bir veri tabanıdır. Daha önceden NLPR Yürüyüş veritabanı olarak bilinir. Her kişi 12 imge dizisine sahiptir. Paralel, 45 ve 90 derece olmak üzere 3 yönün her biri için 4 dizi. Her bir dizinin uzunluğu yürüme hızına bağlı olarak değişir. A verisetinin büyüklüğü 2.2 GB kadardır ve 19139 PNG formatlı imgeden oluşur. Her bir imgenin dosya ismi 'xxx-mm_n-ttt.png' dir. Adlandırma aşağıdaki anlamı taşımaktadır:

Ek-1'in devamı

- xxx : nesne (kişi) no
- mm : yön
- n : dizi numarası
- ttt : dizideki imge çerçeve numarası



V00



V90



V45

Ek Şekil 7. CASIA-A verisetindeki senaryolar

CASIA Veriset B : Ocak 2005'te oluşturulan B veriseti bir çok yönden görüntülemeyi içerir. 124 nesne (kişi) 'nin 11 farklı yönden imge dizileri oluşturulmuştur. Toplam 3 farklı varyasyon vardır : açı, elbise ve eşya taşıma.




Ek Şekil 8. CASIA-B verisetindeki senaryolar

Ek-1'in devamı

Kapalı ortamda kaydın yapılacağı bir bölge seçilmiş ve arkaplan renginden farklı bir renkle işaretlenmiştir. Yürüyüş alanının etrafında 18°'lik açılarla 11 tane USB kamera yerleştirilmiştir.

Video dosyalarının isim formatı 'xxx-mm-nn-ttt.avi' dir.

- xxx : Nesne (kişi) no, (001 den 124'e kadar)
- mm : yürüme durumu, 'nm'(normal), 'cl' (palto, ceket) veya 'bg' (çanta)' lı.
- nn : dizi numarası
- ttt : bakış açısı, '000', '018', ... , '180'



Ek Şekil 9. CASIA-C verisetindeki senaryolar

CASIA Veriset C : Temmuz- Ağustos 2005'te infrared(thermal) kamera ile oluşturulmuştur. 153 nesne (kişi) dört farklı koşulda yürümüşlerdir : normal yürüyüş, yavaş yürüyüş, hızlı yürüyüş ve çanta ile normal yürüyüş. Tüm videolar gece çekilmiştir. Veriset C' nin dosya formatı '01xxxmmnn.avi' şeklindedir.

- xxx : nesne no, (001 den 153 e kadar)
- mm : yürüme durumu, 'fn'(normal), 'fq' (hızlı yürüme), 'fs' (yavaş yürüme) veya 'fb' (çantalı yürüme)
- nn : dizi numarası

Ek-2. Çekirdek Fonksiyonları

Ek Tablo 3. Doğrusal Olmayan Uzaya Eşleme Yaparken Kullanılan Çekirdekler

Doğrusal	$K(x, y) = x^T y + c$
Polinom	$K(x, y) = (\alpha x^T y + c)^d$
Gaussian Çekirdek (Rbf)	$K(x, y) = \exp(-\frac{\ x - y\ ^2}{2\sigma^2})$ veya $K(x, y) = \exp(-\gamma\ x - y\ ^2)$
Üstel	$K(x, y) = \exp(-\frac{\ x - y\ }{2\sigma^2})$
Laplacian	$K(x, y) = \exp(-\frac{\ x - y\ }{2\sigma})$
ANOVA	$K(x, y) = \left(\sum_{k=1}^n \exp(-\sigma(x_k - y_k)^2) \right)^d$
Hiperbolik Tanjant (Sigmoid)	$K(x, y) = \tanh(\alpha x^T y + c)$
Oranlı İkinci Dereceden Çekirdek	$K(x, y) = 1 - \frac{\ x - y\ ^2}{\ x - y\ ^2 + c}$
Multiquadric	$K(x, y) = \sqrt{\ x - y\ ^2 + c^2}$
Ters Multiquadric	$K(x, y) = \frac{1}{\sqrt{\ x - y\ ^2 + c^2}}$
Dairesel	$K(x, y) = \begin{cases} \ x - y\ & \ x - y\ < \sigma \\ 0 & \text{diğer} \end{cases}, \mathbb{R}^2$
Küresel	$K(x, y) = \begin{cases} \ x - y\ & \ x - y\ < \sigma \\ 0 & \text{diğer} \end{cases}, \mathbb{R}^3$

Ek-2'nin devamı

Ek Tablo 3'ün Devamı

Dalga	$K(x, y) = \frac{\theta}{\ x - y\ } \sin \frac{\ x - y\ }{\theta}$
Güç	$K(x, y) = -\ x - y\ ^d$
Logaritmik	$K(x, y) = -\log(\ x - y\ ^d + 1)$
Şerit (Spline)	$K(x, y) = 1 + xy + xy \min(x, y) - \frac{x + y}{2} \min(x, y)^2 + \frac{1}{3} \min(x, y)^3$
B-Spline (Radial Basis Function)	$K(x, y) = B_{2p+1}(x, y) \quad Burada \quad p \in N, B_{i+1} := B_i \otimes B_0$
Bessel	$K(x, y) = \frac{J_{v+1}(\sigma \ x - y\)}{\ x - y\ ^{-n(v+1)}}$
Cauchy	$K(x, y) = \frac{1}{1 + \frac{\ x - y\ ^2}{\sigma}}$
Chi-Square	$K(x, y) = 1 - \sum_{i=1}^n \frac{(x_i - y_i)^2}{\frac{1}{2}(x_i + y_i)}$
Histogram Keşisim	$K(x, y) = \sum_{i=1}^n \min(x_i, y_i)$
Genelleştirilmiş Histogram Keşisim	$K(x, y) = \sum_{i=1}^n \min(x_i ^\alpha, y_i ^\beta)$
Genelleştirilmiş T-Student	$K(x, y) = \frac{1}{1 + \ x - y\ ^d}$
Bayes	$K(x, y) = \prod_{l=1}^N \kappa_l(x_l, y_l) \quad burada$ $\kappa_l(a, b) = \sum_{c \in \{0,1\}} P(Y = c \mid X_l = a) P(Y = c \mid X_l = b)$

Ek-3. Deney Sonuçları

Bu ek bölümde, CMU, SOTON, USF ve CASIA veritabanları üzerinde literatürdeki eğitim-test formatlarına göre yapılan bazı deneylerin rakamsal sonuçları verilmiştir. Tablolarda, YEİ ve pCFEİ örüntülerinden TBA, D-DAA, ÇTBA ve ÇDAA yaklaşımlarıyla çıkarılan özelliklerin AÖU, kKAU, mnAÖU ve mnkKAU yöntemleriyle sınıflandırılma sonuçları görülmektedir.

Ek Tablo 4. CMU farklı özellik çıkarma yaklaşımlarının deney sonuçları

Eğitim-Test	YEİ				pCFEİ				YEİ				pCFEİ			
	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU
TBA								D-DAA								
V1-HY	76	81	88	96	41	80	40	88	77.3	80.9	76	80	67.3	73.8	72	84
V3-HY	91	92	100	100	33	93	28	96	95.5	96	100	100	96	98	100	100
V4-HY	79	85	80	92	35	77	32	88	84	83.5	84	84	71	79.5	76	80
V5-HY	82	85	92	96	21	75	16	84	91.5	90	96	96	71.5	74.5	76	80
V6-HY	92	92	100	100	53	88	60	96	95	93	100	96	89.5	92.5	96	96
V1-YH	88	88	96	100	70	84	84	100	90.5	87	96	96	89	83	96	88
V3-YH	94	95	100	100	51	97	44	100	98.5	99	100	100	98	99	100	100
V4-YH	72	79	88	92	70	90	68	100	81.5	83	88	84	82.5	83	84	80
V5-YH	88	84	96	92	77	91	76	96	91.5	96	92	96	93.5	89.5	96	96
V6-YH	88	89	100	100	53	92	48	96	95.5	93	100	96	95	94.5	96	96
ÇTBA								ÇDAA								
V1-HY	74	74	88	88	44	73	40	80	77.3	78.3	84	84	71.8	79.3	80	84
V3-HY	95	95	96	100	29	95	24	96	96.5	97	100	100	96	97.5	100	100
V4-HY	75	81	72	84	29	71	32	76	83.5	80.5	84	84	71	73.5	72	76
V5-HY	82	83	80	88	23	72	20	72	88.5	85.5	96	96	62.5	72	64	80
V6-HY	89	92	96	96	51	90	64	96	95	95	100	100	92.5	94	96	96
V1-YH	89	92	96	100	68	91	76	100	84.5	90.5	92	92	95	94	100	100
V3-YH	96	97	100	100	34	99	28	100	99	98.5	100	100	98.5	99.5	100	100
V4-YH	73	80	80	80	49	82	48	84	75.5	77.5	76	80	83	79	84	80
V5-YH	89	91	96	100	75	93	76	96	90.5	92	96	96	92	94	96	96
V6-YH	91	94	100	100	47	96	52	100	98	97.5	100	100	94.5	94.5	96	96

Ek-3'ün devamı

Ek Tablo 5. SOTON farklı özellik çıkarma yaklaşımlarının deney sonuçları

	YEİ				pCFEİ				YEİ				pCFEİ			
	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU
	TBA								D-DAA							
L2-L6	98.2	99.2	100	100	83	95.6	92.8	100	98.7	98.9	99.1	100	97	97.8	99.1	100
L3-L5	98.6	99.2	100	100	80.1	98.4	93.7	100	99.2	99.8	100	100	99	99.2	100	100
L4-L4	99.2	99.5	100	100	70.4	98.2	78.4	100	99.7	99.7	100	100	99.7	100	100	100
	ÇTBA								ÇDAA							
L2-L6	97.8	98.1	99.1	99.1	86.1	96.7	96.5	99.1	97.8	98.2	99.1	99.1	97.2	97.2	99.1	99.1
L3-L5	96.7	98.1	99.1	100	79.2	98.8	93.9	99.1	99	99.8	100	100	97.7	98.6	99.1	100
L4-L4	98.3	99.5	100	100	70.3	99.2	83.8	100	99.7	100	100	100	98.7	99.5	100	100

Ek Tablo 6. CASIA-A farklı özellik çıkarma yaklaşımlarının deney sonuçları

	YEİ				pCFEİ				YEİ				pCFEİ			
	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU
	TBA								D-DAA							
V00	93.6	92.4	100	100	83.5	89.8	95	100	89.8	88.6	100	95	81	84.8	85	100
V45	93.7	93.7	100	100	81.2	97.5	100	100	93.7	90	100	100	95	95	100	100
V90	97.5	100	100	100	97.5	100	100	100	100	100	100	100	100	100	100	100
	ÇTBA								ÇDAA							
V00	91.1	92.4	100	100	82.2	92.4	95	100	87.3	92.4	100	100	86	87.3	100	100
V45	93.7	92.5	100	100	70	95	100	100	92.5	95	100	100	91.2	93.7	100	100
V90	98.7	100	100	100	98.7	100	100	100	100	100	100	100	100	100	100	100

Ek Tablo 7. USF V1 farklı özellik çıkarma yaklaşımlarının deney sonuçları

	YEİ				pCFEİ				YEİ				pCFEİ			
	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU
	TBA								D-DAA							
A	71.3	75.8	87.3	92.9	61.3	67.3	80.2	88.7	87.2	89.7	97.1	97.1	84.9	84.6	94.3	92.9
B	57.4	61.3	70.7	78	45.5	49	56	70.7	68.8	69.3	75.6	70.7	63.8	64.3	65.8	70.7
C	41.5	43	63.4	73.1	30.1	36.6	48.7	63.4	56.4	61.8	75.6	78	50.9	55.9	70.7	70.7
D	16.5	18.9	20.8	26.8	12.6	15	16.4	25.3	25.9	24.3	28.3	26.8	23.7	22.5	29.8	26.8
E	10.2	10.7	21.4	21.4	15.6	15.1	21.4	21.4	21.4	20.9	30.9	26.1	18	16	26.1	19
F	9.5	10.1	11.9	17.9	8.2	8.8	16.4	8.9	19.3	17.4	22.3	20.8	18.4	15.3	16.4	14.9
G	10.8	12.8	16.6	16.6	10.8	12.3	9.5	16.6	15.7	15.7	21.4	19	15.7	13.7	14.2	14.2

Ek-3'ün devamı

Ek Tablo 7'nin devamı

	ÇTBA								ÇDAA							
A	78.1	82.1	92.9	97.1	60.7	76.7	85.9	91.5	86	84.9	97.1	91.5	83.2	82.9	92.9	92.9
B	61.3	65.3	68.2	70.7	43	53.9	58.5	70.7	66.3	65.3	70.7	70.7	58.9	59.9	70.7	73.1
C	46.5	54.4	60.9	70.7	31.6	42	36.5	63.4	58.9	56.4	75.6	68.2	50.9	50.9	68.2	73.1
D	18.9	18.9	22.3	26.8	12.3	18.3	8.9	28.3	23.4	26.2	29.8	32.8	22.2	22.8	28.3	23.8
E	10.7	12.1	16.6	19	14.1	14.1	9.5	19	15.6	16.5	16.6	19	17.5	15.6	26.1	19
F	11.9	12.2	14.9	16.4	11	14.1	8.9	14.9	18	17.7	23.8	22.3	14.7	15.6	14.9	16.4
G	8.8	11.3	19	21.4	13.3	11.8	9.5	14.2	17.2	17.7	21.4	21.4	10.8	12.3	19	14.2

Ek Tablo 8. USF V2 farklı özellik çıkarma yaklaşımlarının deney sonuçları

	YEİ				pCFEİ				YEİ				pCFEİ			
	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU
	TBA								D-DAA							
A	62.3	65	84.4	85.2	50.2	53.2	78.6	82.7	76.5	76	88.5	86	77.3	75.7	88.5	89.3
B	78.4	79.5	87	92.5	64.7	70.4	83.3	90.7	82.1	84.4	90.7	90.7	81.4	82.5	88.8	90.7
C	50.9	50.1	74	75.9	30.7	35.7	61.1	75.9	67.3	66.1	81.4	81.4	65.7	66.9	79.6	77.7
D	16.1	15.8	26	28.5	11.4	10.3	20.1	24.3	27.2	28.4	37.8	36.9	23.8	25.3	32.7	31.9
E	17.2	17.2	30.5	30.5	13.4	14.4	20.3	22	24.1	23.7	32.2	33.8	23.7	23.4	30.5	32.2
F	5.2	5.9	7.5	8.4	4.9	4.9	8.4	9.2	11.5	13.2	17.6	18.4	13	12.5	17.6	15.9
G	8.2	9.2	18.6	15.2	6.8	6.8	15.2	13.5	15.4	15.4	20.3	22	15.4	15.7	16.9	16.9
H	44.3	48.9	62.1	68	50.2	52.9	75.6	78.1	44.1	45.5	53.7	50.4	64.1	65.1	71.4	71.4
I	39.5	43.3	62.7	62.7	43.6	44	71.1	71.1	46.4	47.7	57.6	54.2	55.9	59.3	66.1	69.4
J	35.3	35.8	56.3	59.6	24	24.5	48.7	56.3	46.8	46.7	58.8	59.6	44.3	43.1	57.1	57.9
K	6.6	8.4	6	12.1	6	6	6	12.1	7.2	10.9	12.1	12.1	6	7.2	6	6
L	7.2	6.6	3	9	3.6	3	3	9	6	6	3	3	3	3	3	3
	ÇTBA								ÇDAA							
A	69	73.5	86	88.5	56.2	69.7	72.1	89.3	78.2	76.8	88.5	88.5	76.3	78.8	90.9	89.3
B	80.6	82.5	88.8	88.8	66.2	79.5	83.3	92.5	83.3	82.9	87	88.8	82.1	81.8	90.7	87
C	60	60.8	77.7	83.3	38.7	59.6	46.2	81.4	65.3	65.7	77.7	79.6	58.9	65.3	77.7	77.7
D	22.4	23.6	33.6	31.9	13.7	21.8	15.1	28.5	25.7	25.8	34.4	28.5	22.6	22.3	26.8	26
E	22.7	23.1	27.1	32.2	11	19.3	11.8	28.8	26.5	25.1	32.2	28.8	20	23.1	27.1	28.8
F	11	10.5	17.6	16.8	9	10.3	10.9	15.1	14.9	14.4	19.3	16.8	13	11.5	15.9	17.6
G	16	15.4	25.4	20.3	6.8	12.3	5	15.2	18.8	18.1	25.4	23.7	15.4	17.1	22	20.3
H	49.5	52.4	67.2	72.2	58.5	70	76.4	87.3	50.5	48.3	59.6	58.8	72.2	69.5	78.9	76.4
I	47	50.5	67.7	67.7	49.8	61	61	86.4	46.7	45.7	57.6	49.1	60	56.3	71.1	66.1
J	35.8	37.5	49.5	58.8	24.8	35.3	35.2	61.3	41.9	40.7	52.1	52.9	39.7	42.3	58.8	63.8
K	1.2	4.2	0	6	3	7.8	3	12.1	6	9	6	12.1	7.2	6.6	9	12.1
L	5.4	5.4	6	9	2.4	3	0	3	3.6	3.6	6	3	4.8	4.2	9	6

Ek-3'ün devamı

Ek Tablo 9. CASIA-C farklı özellik çıkarma yaklaşımlarının deney sonuçları

	YEİ				pCFEİ				YEİ				pCFEİ			
	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU
	TBA								D-DAA							
NM	95.8	99.1	100	100	61.8	96.3	64	100	99.8	99.8	100	100	98.6	99.3	99.3	100
FB	63.1	63.7	80.3	84.9	33.5	60.2	38.5	88.8	74	72.9	78.4	80.3	77.7	78.9	89.5	92.1
FQ	66.2	74.4	79	91.5	34.9	64.9	43.1	85.6	86	85.1	94.7	93.4	75.2	75.6	83.6	84.3
FS	68.6	74.6	83.6	90.1	17.8	59.9	12.4	77.7	85.4	84.3	94.7	94.1	71.8	75	81.6	83
	ÇTBA								ÇDAA							
NM	99.3	99.6	100	100	67.1	98.1	67.3	100	99.5	99.1	100	100	98.5	98.5	99.3	99.3
FB	55.9	60.2	66	73.2	22	77.5	24.1	93.4	55.6	56.9	65.3	66.6	79.2	81.5	89.5	93.4
FQ	72.4	77.3	84.3	88.2	31.8	73.7	29.4	85.6	72.9	74.4	80.3	77.1	72.4	67.6	83	75.8
FS	74.1	78.4	83	89.5	15.5	58.1	13.7	70.5	78.9	76.7	86.2	86.9	58.8	64.3	63.3	73.8

Ek Tablo 10. CASIA-B farklı özellik çıkarma yaklaşımlarının deney sonuçları

	YEİ				pCFEİ				YEİ				pCFEİ			
	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU	AÖÜ	kKAU	mnAÖÜ	mnkKAU
	TBA								D-DAA							
NM	94.4	96.2	99.1	100	84.5	92.2	91.6	99.1	99.1	99.3	100	100	98.5	98.7	100	100
BG	47	53.5	64.7	72.2	51	56.7	74.7	83.1	53.3	56.8	63.8	68	65.3	65.7	79.8	77.3
CL	42.4	46.1	55.4	63	34	42.2	46.2	68.9	29.4	32.4	31.9	35.2	40.3	42.4	44.5	49.5
	ÇTBA								ÇDAA							
NM	92.6	94.2	96.6	99.1	74.1	94.1	77.5	98.3	94.6	94.6	98.3	100	95.8	96.6	98.3	99.1
BG	42.2	41.5	57.9	54.6	31.5	64	28.5	83.1	44.7	46.8	49.5	54.6	66.1	66.3	79.8	77.3
CL	33.3	32.6	33.6	34.4	26	42	21	57.9	26	26.7	27.7	26.8	44.1	45.1	48.7	50.4

ÖZGEÇMİŞ

Eyüp Gedikli; 1979 yılında Trabzon-Akçaabat'ta doğdu. İlk ve orta öğrenimini Trabzon'da tamamladı. 1996 yılında, OSYS ile yerleştirildiği Karadeniz Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü'nü 2000 yılında bitirdi. 2004 yılında aynı bölümde yüksek lisansını tamamladı. Aynı yıl, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Anabilim Dalı'nda başladığı doktora çalışmalarına, daha sonra Bilgisayar Mühendisliği'nde açılan doktora programına yatay geçiş yaparak devam etti. 2001-2004 yıllarında Bilgisayar Mühendisliği ve 2004-2007 yıllarında Elektrik-Elektronik Mühendisliği Bölümlerinde, Fen Bilimleri Enstitüsü tarafından araştırma görevlisi olarak görevlendirildi. 2004 yılında, KOSGEB (TEKMER)'de kısa bir süre yazılım uzmanı olarak çalıştı. Doktora çalışmaları süresince, TUBITAK destekli 107E212 ve 106M423 projelerinde bursiyer statüsünde görev aldı. Halen K.T.Ü. Of Teknoloji Fakültesi'nde araştırma görevlisi olarak çalışmaktadır. İyi derecede İngilizce bilmektedir. Başlıca yayınları aşağıda verilmiştir.

Ekinci, M., ve **Gedikli, E.**, Gait Recognition Using View Distance Vectors, Lecture Notes in Artificial Intelligence, 3801 (2005) 973-978.

Ekinci, M. ve **Gedikli, E.**, A Novel Approach on Silhouette Based Human Motion Analysis for Gait Recognition, Lecture Notes in Computer Science, 3804 (2005) 219-226.

Ekinci, M., Aykut, M., ve **Gedikli, E.**, Gait Recognition by Applying Multiple Projections and Kernel PCA, In Proceedings of Machine Learning and Data Mining in Pattern Recognition, Lecture Notes in Artificial Intelligence, 4571 (2007) 727-741.

Baytan, S. H., Alkanat, M., Okuyan, M., Ekinci, M., **Gedikli, E.**, Özeren M. ve Akgün, A., Simvastatin Impairs Spatial Memory in Rats at a Specific Dose Level, The Tohoku Journal of Experimental Medicine, 214 (2008) 341-349.