

İnsan Vücut Parçalarından Pozun Tanınması

Nazmi Alper Kale

**YÜKSEK LİSANS TEZİ**

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Temmuz 2007

Human Posture Recognition from Detected Body Parts

Nazmi Alper Kale

**MASTER OF SCIENCE THESIS**

Department of Electrical & Electronics Engineering

July 2007

İnsan Vücut Parçalarından Pozun Tanınması

Nazmi Alper Kale

Eskişehir Osmangazi Üniversitesi  
Fen Bilimleri Enstitüsü  
Lisansüstü Yönetmeliği Uyarınca  
Elektrik-Elektronik Mühendisliği Anabilim Dalı  
Telekomünikasyon - Sinyal İşleme Bilim Dalında  
YÜKSEK LİSANS TEZİ  
Olarak Hazırlanmıştır

Danışman: Yrd. Doç. Dr. Nihat Adar

Temmuz 2007

Nazmi Alper Kale'nin YÜKSEK LİSANS tezi olarak hazırladığı “İnsan Vücut Parçalarından Pozun Tanınması” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.

Üye: Yrd. Doç. Dr. Nihat Adar (Danışman)

Üye: Yrd. Doç. Dr. Rifat Edizkan

Üye: Yrd. Doç. Dr. Selçuk Canbek

Üye: Yrd. Doç. Dr. Erol Seke

Üye: Doç. Dr. M. Bilginer Gülmezoğlu

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ..... tarih ve ..... sayılı kararıyla onaylanmıştır.

Prof. Dr. Abdurrahman Karamancıoğlu

Enstitü Müdürü

## ÖZET

Bu çalışmada, verilen bir resim içindeki insan üst vücut parçalarının tespit edildikten sonra insan vücudu olarak tanınması süreci sunulmaktadır. Çalışmada insan üst vücudu, kafa, gövde, üst-kollar ve eller olmak üzere altı vücut parçası ile temsil edilmektedir. Destek vektör makinesi tabanlı parça bulucularla vücut parçalarının imgedeki olası konum ve büyüklükleri tespit edilip insan üst vücudu aday katışımlar oluşturulmaktadır. İnsan vücudunu oluşturan doğru katışım, saklı Markov modeli vasıtasıyla bulunmakta ve insan üst vücudu olarak belirlenmektedir. Parçaların örtülü olma durumları göz önünde bulundurularak beş farklı saklı Markov modeli tasarlanmaktadır. Tüm modeller karar verici bir süreçle birleştirilmekte ve vücut parçalarından örtülü olanların olması durumunda da insan vücudu oluşturan parçalar, örtülü durumun tanımı ile birlikte başarılı olarak bulunabilmektedir. MIT yaya veritabanı ve farklı boyutlarda insan görüntüleri içeren resimler kullanılarak önerilen yöntemin başarımlı sonuçları elde edilmektedir. Üst vücut parçalarının insan vücuduna birleştirilmesi sürecinde saklı Markov modelinin yöntem olarak sınanması, destek vektör makinesi ve çok değişkenli Gauss dağılımı yöntemleriyle elde edilen başarı oranları ile karşılaştırılarak gerçekleştirilmektedir.

Anahtar Kelimeler: İnsan vücut parçası tespiti, poz tanıma, saklı Markov modeli

## SUMMARY

In this work, the process of detecting human upper body parts in an image and assembling them into human figure is presented. In the process, human upper body is represented by six body parts: face, torso, upper-arms and hands. Possible locations and scales of human body parts in the image are detected by support vector machine based part detectors, and assemblies, which constitute candidates for human upper body, are constructed. The most likely candidate for human body configuration is determined via hidden Markov model and selected to represent human upper body figure. In regard to occluded cases of body parts, there are five hidden Markov models composed. Models are congregated in a decision process and body parts that represent human body figure in occluded cases can also be determined successfully with the definition of the occluded case. The detection method shows promising results when tested on images from MIT pedestrian database and additional pictures that contain pedestrians. The choice of using hidden Markov model in assembling body parts into human figure is verified by comparing the results with those of obtained from support vector machines and multivariate Gaussian distribution.

Keywords: Human body-part detection, posture recognition, hidden Markov model

## **TEŞEKKÜR**

Tez çalışmam boyunca beni yönlendiren, bilgisini, değerli görüşlerini ve deneyimlerini bana aktarıp her türlü olanağı bana sağlayan danışmanım Sayın Yrd. Doç. Dr. Nihat ADAR'a çok teşekkür ederim.

## İÇİNDEKİLER

### Sayfa

ÖZET .....	iv
SUMMARY .....	v
TEŞEKKÜR .....	vi
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ.....	x
SİMGELER VE KISALTMALAR DİZİNİ.....	xi
<b>1. GİRİŞ VE ÖNCEKİ ÇALIŞMALAR.....</b>	<b>1</b>
1.1 Önceki Çalışmalar.....	1
1.2 Önerilen Yöntem.....	4
<b>2. VÜCUT PARÇALARININ ÖN TESPİTİ.....</b>	<b>6</b>
2.1 Destek Vektör Makineleri.....	6
2.2 Destek Vektör Makinesi Tabanlı Parça Bulucu Oluşturulması ve Parça Adaylarının Bulunması .....	8
<b>3. DOĞRU PARÇA VE KATIŞIMLARIN BULUNMASI.....</b>	<b>11</b>
3.1 Katışım Oluşturma.....	11
3.2 Öznitelik Vektörü Çıkarma.....	12
3.3 Saklı Markov Modeli .....	14
3.3.1 Ayrık zamanlı Markov süreci .....	14
3.3.2 Saklı Markov modeli ve elemanları.....	16
3.3.3 Saklı Markov modeline ilişkin üç problem.....	17
3.3.3.1 Olasılık hesabı.....	17
3.3.3.2 En uygun durum dizisi.....	19
3.3.3.3 Model parametrelerinin hesaplanması .....	21
3.3.4 Saklı Markov modeli tipleri.....	22
3.3.5 Çoklu gözlem dizileri.....	24
3.4 Saklı Markov Modeli Vasıtasıyla Sınıflandırıcı Tasarlama .....	25
3.4.1 Gözlem sembollerinin çıkarılması .....	26
3.4.2 Sınıflandırıcının eğitimi ve model parametrelerinin elde edilmesi .....	27
3.4.3 Doğru katışımın bulunması.....	28
3.5 Parça Örtülü Durumlara Göre Genel Bir Sınıflandırıcı Oluşturma .....	29



## İÇİNDEKİLER (devam)

	<u>Sayfa</u>
<b>4. DENEYSEL ÇALIŞMALAR.....</b>	<b>32</b>
4.1    Eğitim ve Test Verileri .....	32
4.2    Testler .....	34
4.2.1    Bireysel testler .....	34
4.2.2    Genel sınıflandırıcı ile yapılan test .....	35
4.3    Farklı Yöntemlerle Oluşturulan Sınıflandırıcıların Karşılaştırılması .....	36
<b>5. SONUÇLAR.....</b>	<b>39</b>
<b>KAYNAKLAR DİZİNİ .....</b>	<b>41</b>

## ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
1.1 Sistemin genel yapısı .....	5
2.1 Üst vücut parçaları .....	6
2.2 Ayırıcı düzlem ve destek vektörleri.....	7
2.3 Üst vücut parçaları için öznitelik kümesi .....	9
2.4 İmgenin farklı ölçek ve dönüşlerde taranması .....	10
3.1 Vücut parçası adaylarından katışımlar oluşturma.....	12
3.2 Üst vücut parçaları ve bağlantıları .....	13
3.3 Üç durumlu Markov Modeli .....	15
3.4 Dört durumlu ergodik saklı Markov modeli .....	23
3.5 Dört durumlu soldan-sağa bir atlamalı saklı Markov modeli .....	24
3.6 Saklı Markov modelinin eğitilmesi.....	28
3.7 Viterbi algoritması ile doğru katışımın bulunması .....	29
3.8 Genel sınıflandırıcı .....	31
4.1 Test resmi parça işaretleme ve test alanı belirleme: a) Üst kol 1, b) Kafa .....	33

## ÇİZELGELER DİZİNİ

<b><u>Çizelge</u></b>	<b><u>Sayfa</u></b>
3.1 Örtülü parçalar ve kullanılan bağlantılar .....	13
4.1 Sınıflandırıcılarda kullanılan veriler .....	33
4.2 Başarım oranları.....	34
4.3 Sıradüzensel genel sınıflandırıcı için başarım oranları.....	35
4.4 Sıradüzensel olmayan genel sınıflandırıcılar için başarım oranları.....	36
4.5 Bireysel sınıflandırıcılar için başarım oranları .....	37
4.6 Genel sınıflandırıcılar için başarım oranları .....	38

## SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler</u>	<u>Açıklama</u>
A	Durum geçiş olasılıkları matrisi
b	Bağıl konum değeri
B	Gözlem sembolü olasılıkları matrisi
d	Vektör uzayının boyutu
D	Parçaların merkezleri arası birim uzaklık
K	Çekirdek fonksiyonu
M	Gözlem sembolü sayısı
n	Eğitim kümesindeki vektör sayısı
N	Durum sayısı
$N_p$	Bir parça türü için aday sayısı
o	Gözlem değişkeni
O	Gözlem dizisi
q	Durum değişkeni
Q	Durum sırası
r	Doğru katışım
R	Parça büyüklükleri arasındaki oran
S	Durum
t	Ayrık zaman dilimi değişkeni
T	Gözlem dizisinin uzunluğu
v	Gözlem sembol değişkeni
V	Gözlem sembolleri kümesi
w	Normal vektörü
x	Veri kümesini oluşturan vektör değişkeni
y	Veri kümesini oluşturan vektör etiketi değişkeni
$\sigma$	Standart sapma
$\Pi$	Başlangıç durum olasılıkları vektörü
$\lambda$	Saklı Markov modeli
$\alpha$	İleri-yön değişkeni

## SİMGELER VE KISALTMALAR DİZİNİ (devam)

<b><u>Simgeler</u></b>	<b><u>Açıklama</u></b>
$\beta$	Geri-yön değişkeni
$\gamma$	Ara olasılık değişkeni
$\delta$	Ara olasılık değişkeni
$\psi$	İz sürme matrisi
$\xi$	Ara olasılık değişkeni
$\Delta_i$	Atlanan durum sayısı
$\mu$	Ortalama vektörü
$\Sigma$	Ortak değişinti matrisi

<b><u>Kısaltmalar</u></b>	<b><u>Açıklama</u></b>
HMM	Hidden Markov model
LoG	Laplacian of Gaussian
MIT	Massachusetts Institute of Technology
RANSAC	Random Sample Consensus
SVM	Support vector machines
U.T.	Uzaklık toplamı

## BÖLÜM 1

### GİRİŞ VE ÖNCEKİ ÇALIŞMALAR

İnsan – makine etkileşimi, son yıllarda araştırmacıların üzerinde durduğu, daha pratik hale gelmesi için arabirimler tasarladıkları konulardan biridir. İnsan vücudunun modelinin imgelerden çıkarılması da bu başlık altında incelenen bir problemdir. Görüntü içinden insan vücudunun tespit edilmesi, güvenlik ya da spor görüntü kayıtlarının incelenmesi gibi konulardaki uygulamalarda kendine yer bulmaktadır.

Yapılan çalışmada, parça bulucularla elde edilen vücut parçası adaylarıyla, adayın kimliği (hangi parça için aday olduğu) göz önüne alınarak, oluşturulan katışımların sınıflandırılarak hangi katışımın üst vücut modelini oluşturduğu saklı Markov modeli (HMM, Hidden Markov Model) kullanılarak gerçekleştirilmiştir.

#### 1.1 Önceki Çalışmalar

İmgelerden insan vücudu modelinin çıkarılması konusunda yapılan çalışmalarda çeşitli yöntemler denenmiştir. İmge içerisinde insan vücudu bir bütün olarak aranabilirken, insan vücudunu parçalar birleşimi olarak kabul edip imgede bu parçaların tespitine de çalışılabilir. Öte yandan, verilen imgeyi bir parçalar bütünü olarak görüp bu parçalardan insan vücuduna ait olanları bularak insan vücudunu çıkarmak da mümkündür.

İnsan vücut modelinin imgelerden çıkarılması için akla gelebilecek ilk yöntem insan vücutlarını imgeler içinde bütün olarak aramaktır. Dalgacık şablonu çıkararak imgelerde insan vücudunu bütün olarak tespit etmek bunun sık kullanılan bir yoludur (Oren, et al., 1997; Elzein et al., 2003). Bunun için, girilen görüntüleri ‘insan’ ve ‘insan değil’ şeklinde sınıflayacak şekilde bir sınıflandırıcı eğitilmektedir. Bu şekilde, akıllı araba uygulaması için dalgacık tabanlı şablon uyumlama ile yayaların tespiti üzerinde çalışılmıştır (Elzein et al., 2003). Başka bir çalışmada ise, videolarda ön plan/arka plan ayrıştırması yapılarak hareketli nesnelere tespit edilmekte, elde edilen görüntüler LoG (Laplacian of Gaussian) filtresinden geçirildikten sonra yine verileri ‘insan’ ve ‘insan değil’ olarak sınıflandıracak biçimde eğitilmiş bir sinir ağı ile insan vücudu tespiti

gerçekleştirmektedir (Zhao and Thorpe, 1999). Başarılı sonuçlar vermesine karşın, vücudun bütün olarak tespiti, pozun belirlenmesi aşamasında etkin olarak kullanılabilecek bir yol değildir.

Diğer bir düşünce ise verilen imgeyi parçalara ayırarak çalışmaktır (Mori, et al., 2004). Bu yöntemde, öncelikle resim, düzelenmiş kesikler (Normalized-Cuts) algoritmasıyla bölgelere ve süperpiksellere bölütlenmektedir. Her bölge vücut parçaları için birer aday teşkil etmektedir. Uzunların ve gövdenin (kafa ve gövde) bulunması iki ayrı bölümde incelenmektedir. Uzunlar bulunurken, çevrit, şekil, gölgelendirme ve odak gibi imlere (cue) ağırlıklandırılmış şekilde bakılmaktadır. Bulunan yarı-uzunlar süperpiksellere dayanarak birleştirilerek uzun adayları elde edilmektedir. Gövde adayları da aynı şekilde tespit edildikten sonra parça adayları gruplandırılmaktadır. Parça adayları arasındaki bağıl genişlikler, gövde uzunluğu, bitişiklik ve giysi simetrisi gibi imlerle kısmi olasılıklar elde edilmektedir. Bu olasılıkların doğrusal toplamının değerine bakılarak doğru gruplama seçilmekte, dolayısıyla doğru parçalar tespit edilmektedir. Bölütleme işleminin arttırdığı hesap yükü göz önüne alındığında sonuçların çok iyi olmaması ve giysilerin simetrik olmadığı durumlarda başarısız olması yüzünden tercih edilebilir bir yöntem değildir.

İnsan vücudunu oluşturan parçaları bireysel olarak bulup insan oluşturacak şekilde birleştirme yaygın olarak çalışılmış bir yöntemdir. Paralel kenar bölüt bulucu ile vücut parçalarını işaretlemek ve bunları insanı oluşturacak şekilde bir sınıflayıcı ile birleştirmek bunun bir yoludur (Ioffe and Forsyth, 2001). Başka bir grup araştırmacı ise, resimlerin Gauss filtre değerlerini öznitelik kümesi olarak kullanarak destek vektör makinelerini (SVM, Support Vector Machines) eğitmektedir (Ronfard, et al., 2002). Bu çalışmada, genelde evet/hayır kararı üretme özelliklerinden yararlanan destek vektör makineleri, olasılık üretmek için kullanılmakta; parça adaylarının olasılıklarıyla birlikte, parçaların birbirlerine göre konumlarının da kullanıldığı bir algoritmayla gruplama oluşturulmaktadır. Yüksek olasılıklı gruplamalar doğru gruplama olarak alınmaktadır. Ancak, sınıflandırıcılarında kullanılan görelî pozisyon bilgileri farklı büyüklükteki vücut parçalarında çalışırken yeterli olamamaktadır. Bu kısım için parça-bulucu olasılıkları yerine, görelî yer ve büyüklüklerle işlem yapabilecek bir sınıflandırıcı kullanmak daha uygun olacaktır. Farklı özniteliklerden yararlanan bir çalışmada yine 5 üst-vücut parçası ve bacaklar için parça bulucular kullanılmaktadır (Micilotta, et al.,

2005). Bu kez, parça bulucularda kullanılan öznitelikler, Adaboost ile geliştirilmekte ve her parça bulucu belirlemeleriyle birlikte olasılıklarını da üretmektedir. Performans - doğruluk dengesini seçebilme bakımından kullanışlı bir algoritma olan Adaboost, eğitim süreci uzun olduğu için parça bulucularda genellikle kalıplaşmış öznitelikler (filtreler) kullanılmaktadır. Bu çalışmada belirlenen parçalar RANSAC algoritması ile gruplanmakta ve vücut adayları oluşturulmaktadır. Ayrıca, gruplamaya geçmeden önce ten rengi bilgisi kullanılarak bazı yanlış el ve yüz tespitleri, Da Vinci'nin ideal birim vücut uzunlukları kullanılarak da belirgin bir şekilde uyumsuz olan adaylar elenmektedir. Kalanlar içinden en yüksek olasılığa sahip olan aday gruplama yine RANSAC tarafından seçilmektedir. Yöntem oldukça fazla işlem yükü getirdiğinden gerçek zamanlı imgelerde kullanımında sorunlar olacaktır. Parçaların tek tek bulunup insan vücudu elde edilmesinde kullanılan farklı bir yol da, bazı parçalara öncelik atamaktır. Bu şekilde üst-vücut pozunun bulunması üzerine yapılan bir çalışmada, parçaların belirlenmesi için sıradüzensel bir arama yöntemi geliştirilmiştir (Navaratnam et al., 2005). Buna göre doğru belirlenmesi en olası parçalar bulunmakta, diğer parçaların belirlenmesi de bu parçalara tutunularak gerçekleştirilmektedir. Gruplama için skor üretilirken koşullu olasılıklar kullanılmaktadır. Belli parçaların belirlenmesindeki doğruluk oranı daha yüksek olsa da, bu parçaların doğru belirlenmesi yerine gruplamaların doğruluğu üzerine yoğunlaşmak, hem verimlilik, hem de öncelikli parçaların yanlış belirlenmesi sonucunda pozun tamamen yanlış bulunması riskinin azaltılması bakımından daha uygun olacaktır. Buna benzer bir yaklaşımın kullanıldığı bir çalışmada, siluet çıkarımı ve renk (ten) bilgisi gibi özniteliklerle tespit edildikten sonra çubuklarla temsil edilen parçalara rastgele "roller" atanarak tahminler oluşturulmaktadır (Ben-Arie, et al., 2003). Bağlı olasılık fonksiyonlarıyla en yüksek skor üreten tahmin, doğru katışım ve doğru parçalar olarak belirlenmektedir. Yöntemin dezavantajı ise, parça adayları çıkarılırken oluşan hesap yükünün oldukça fazla olmasıdır.

Saklı Markov modeli, şimdiye kadar, ses tanıma (Rabiner and Juang, 1993), el yazısı tanıma (Lee, et al., 2001), yüz bulma ve tanıma (Nefian and Hayes, 1999), bilgisayar görüşü ve örüntü tanıma gibi birçok uygulamada kendine yer edinmiştir. Bunların dışında, Amerikan işaret dilinin görsel tanınması (Starner and Pentland, 1998), değişik fiillerin pozunun tanınması (Lee and Kim, 1999) ya da imgede tavır tanınması



(Davis, et al., 2004) gibi çalışmalarda da saklı Markov modeli yöntemi kullanılmıştır. Son yıllarda ise saklı Markov modeli, ses sinyalini parçalı durağan olarak inceleme olanağı sağladığından ve sade yapısıyla daha az işlem yükü gerektirdiğinden ses tanıma uygulamalarının temelini teşkil eden vazgeçilmez bir yöntem haline gelmiştir.

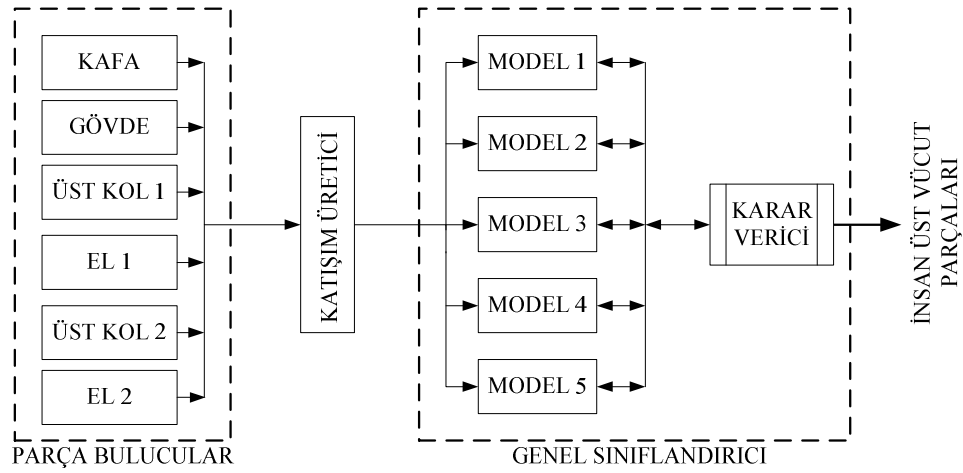
## 1.2 Önerilen Yöntem

Önerilen yöntemde ise, altı üst-vücut parçası (kafa, gövde, kollar ve eller) için, imgelerden destek vektör makinesi tabanlı parça bulucularla elde edilen parça adaylarının tür, konum ve büyüklük bilgileri kullanılmaktadır. Micilotta vd.'nin (2005) çalışmasına benzer olarak, parça bulucularla elde edilen adaylarla oluşturulabilecek tüm katışımlar (kombinasyonlar) için saklı Markov modeli vasıtasıyla olasılıklar üretilmekte, en yüksek olasılık değerine sahip olan katışım doğru gruplama olarak belirlenmektedir. Ancak, yapılan çalışmada, parçaların salt konum bilgileri yerine, bazı çalışmalardaki gibi (Ronfard, et al., 2002; Mori, et al., 2004), birbirlerine göre göreceli pozisyonları esas alınmaktadır.

Sunulan modelde, parça bulucuların imgeden çıkardığı parça adaylarından oluşturulan katışımlar için parçalar arası birim uzaklıklar ve oranlar kullanılarak öznitelik vektörü oluşturulmaktadır. Uygun bir kodlama ile öznitelik vektöründen gözlem vektörü elde edilmekte ve saklı Markov modeli tabanlı sınıflandırıcıya verilmektedir. Sonuç olarak yalnızca bir katışım doğru olarak belirlenmektedir. Önerilen modelin kilit noktası, işlem yoğunluğunu parça buluculardan katışım sınıflandırıcıya kaydırmaktır. Böylece parça bulucuların yüksek başarımla çalışmaları gerekmediğinden, karmaşık öznitelik ya da özniteliklerin kullanılmasına gereksinim duyulmayacaktır. Katışımlardan çıkarılan öznitelik vektörlerinin boyutu, her zaman parça bulucularda kullanılan öznitelik vektörlerinin boyutundan çok küçük olduğundan, işlem yoğunluğunu katışım sınıflandırıcı tarafına kaydırmak, işlem yükünü gözle görülür bir şekilde azaltacaktır. Bununla beraber, tek bir katışım doğru gruplama olarak belirlendiğinden ve her katışım vücut parçalarının yer ve büyüklük bilgilerini taşıdığından insanın pozu da tespit edilmiş olacaktır.

Verilen imgede, insanın ya da kameranın duruş açısı nedeniyle bazı vücut parçaları örtülü olarak kalabilir. Bu nedenle, eksik parça olması halinde kalan

parçalardan insan vücudu kurabilmek için, eksik parçanın türüne göre, birden fazla model kullanılmaktadır. Parça bulucular, örtülü parça olması durumunda da bu parça türü için, yanlış da olsa, aday parça tespit edecektir. Bu nedenle hangi parça ya da parçaların örtülü olduğunu sınıflandırmaya gitmeden bilmek mümkün olmayacağından, verilen katışımların tüm modellere göre sınanması gerekmektedir. Bunun için de sıradüzensel bir sınıflandırma süreci oluşturulmuştur. Şekil 1.1’de sistemin genel yapısı verilmiştir.



Şekil 1.1 Sistemin genel yapısı


İnsan üst vücudunu oluşturan katışımın bulunmasında kullanılan yöntem tercihinin ne derece doğru olduğunun sınanması için, saklı Markov modeli ile geliştirilen sınıflandırıcılar ile çok değişkenli Gauss dağılımı ve destek vektör makinesi ile geliştirilen sınıflandırıcıların performansları karşılaştırılmaktadır.

Bölüm 2’de üst-vücut parçalarının imgedeki olası yer ve büyüklüklerinin tespiti anlatılmaktadır. Bölüm 3’te, bu tespitlerle oluşturulan katışımlardan insan üst vücudunu teşkil edenin bulunması için saklı Markov modeli ile yapılandırılan model sunulmaktadır. Tasarlanan yöntemin sınanması ve başarı oranlarının diğer sınıflandırma yöntemleriyle karşılaştırılması ise bölüm 4’te verilmektedir.

## BÖLÜM 2

### VÜCUT PARÇALARININ ÖN TESPİTİ

İlk aşamada altı üst-vücut parçasının (Şekil 2.1) her birinin imge içerisindeki olası konum ve büyüklükleri tespit edilmektedir. Bu işlem, her parça için ayrı ayrı eğitilmiş bireysel parça bulucularla gerçekleştirilmektedir. Ağırlıklı olarak Ronfard vd.'nin (2002) bu konuyla ilgili çalışması temel alınmakta ve parça bulucular destek vektör makinesi tabanlı tasarlanmaktadır. Ancak, bu çalışmadan farklı olarak ayırıcı vektör makinesi (RVM, Relevance Vector Machine) kullanılmamaktadır.



Şekil 2.1 Üst vücut parçaları

Her bir parça bulucu, ilgili olduğu parça türü için tespit ettiği parça adaylarının imge içerisindeki merkez koordinatları, büyüklük ve açı bilgilerini getirmektedir.

#### 2.1 Destek Vektör Makineleri


Destek vektör makineleri, ikili sınıflandırma (örüntü tanıma) ve gerçel değerli fonksiyon yaklaşıklama (bağlanım kestirimi [regression estimation]) için kullanılan bir öğreticiyle öğrenme (supervised learning) yöntemleri kümesi olarak tanımlanabilir. Diğer bir ifadeyle, işaretlenmiş eğitim verilerinden fonksiyon üretmek için geliştirilmiş

bir yöntemdir. Bu fonksiyon, bir sınıflandırma fonksiyonu ya da genel bağlanım fonksiyonu olabilir (Platt, 2000).

Destek vektör makinesi ile sınıflandırma, eldeki veri kümesini iki bölüme ayıran d-boyutlu bir aşırıdüzlem (hyperplane) oluşturularak gerçekleştirilir. Temelde ikili sınıflandırıcı olan destek vektör makineleri ile çoklu sınıflandırma problemi ise veri kümesinin farklı biçimlerde ikiye bölünmesiyle çözülür.

Örüntü tanıma problemlerinde aşırıdüzlem, eğitim kümesindeki pozitif ve negatif örnekleri ayırma işlevini görür. Veri kümelerindeki elemanların dağılımlarına göre birden fazla ayırıcı aşırıdüzlem olabilir. Bu durumda, kendisine en yakın pozitif ve negatif verinin uzaklıkları en büyük olan ayırıcı düzlem seçilir. Ayırıcı düzleme en yakın pozitif ve negatif veriler "destek vektörleri" olarak adlandırılır ve karar sınırını belirler (Burges, 1998).

Şekil 2.2'de ayırıcı düzlem (ortadaki kalın çizgi), normal vektörü  $w$  ve destek vektörleri (daire içine alınmış veriler) belirtilmektedir.



Şekil 2.2 Ayırıcı düzlem ve destek vektörleri

Veri kümesindeki vektörleri ifade eden değişken  $x$ , bağıl konum (ofset) değeri  $b$  ve ayırıcı düzlemin normal vektörü  $w$  olmak üzere ayırıcı düzlem,  $w \cdot x + b = 0$  doğrusu ile ifade edilebilir.  $n$  adet örnek içeren eğitim kümesindeki sınıflarına (pozitif ya da negatif) göre işaretlenmiş veriler (vektörler) kullanılarak en iyi ayırıcı düzlem,  $x_i$  d-boyutlu eğitim vektörü,  $y_i$  bu vektörün sınıfı ve  $b$  de ofset değeri olmak üzere, aşağıdaki ifadeyle elde edilebilir:

$$y_i(w \cdot x_i + b) - 1 \geq 0, \quad i = 1, 2, \dots, n, \quad x_i \in \mathbb{R}^d, y_i \in \{-1, 1\} \quad (2.1)$$

Burada, en yakın eğitim örneği ile arasındaki uzaklık (margin) değeri  $2 / \|w\|$  en büyük olan düzlem, ayırıcı düzlem olarak belirlenir.

Ayırıcı düzlemi belirlenmiş (eğitilmiş) bir destek vektör makinesi için, verilen yeni bir verinin sınıflandırılması ( $y_i$ 'nin bulunması) ise şu denklemle gerçekleştirilebilir (Müller, et al., 2001):

$$y_i = \text{sgn}(\mathbf{w} \cdot \mathbf{x}_i + b) \quad (2.2)$$

En iyi ayırıcı düzlemi bulmak için en yakın eğitim örneğine olan uzaklığa bakma yöntemi, doğrusal destek vektör makinelerinde kullanılabilir. Doğrusal olarak sınıflandırılmayan veriler için ise, verilerin doğrusal olarak sınıflandırılabileceği ve iç çarpımın tanımlı olduğu başka bir uzaya dönüşüm için çeşitli çekirdek fonksiyonları (kernel function) tanımlanmaktadır. Doğrusal çekirdek fonksiyonu aşağıdaki gibi ifade edilmektedir:

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (2.3)$$

Farklı uygulamalar ve amaçlar için farklı çekirdek fonksiyonları kullanılabilir. Doğrusal çekirdek fonksiyonuyla birlikte en sık kullanılanlar şunlardır:

$$\text{Polinom: } K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i \cdot \mathbf{x}_j)^d \quad (2.4)$$


$$\text{Radyal taban: } K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\sigma^2) \quad (2.5)$$

$$\text{İki katmanlı algı (perceptron): } K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\beta_0 \mathbf{x}_i \cdot \mathbf{x}_j + \beta_1) \quad (2.6)$$

## 2.2 Destek Vektör Makinesi Tabanlı Parça Bulucu Oluşturulması ve Parça Adaylarının Bulunması

Üst-vücut parçalarının imgedeki olası konum ve büyüklükleri bulunurken, her parça bulucu için, verilen imge parçasını 'vücut parçası' ve 'vücut parçası değil' şeklinde sınıflandıran destek vektör makinelerinden faydalanılmaktadır. Parça bulucular, doğru parçaların tamamını bulurken yanlış parçaların da doğru olarak bulunmasına belli bir yere kadar izin verilecek şekilde tasarlanmaktadır. Diğer bir ifadeyle, yanlış pozitif oranı işlem yükünü azaltacak şekilde belli bir ölçüde yüksek tutulabilirken, yanlış negatif oranı sifıra yakın olmalıdır. Buradaki asıl amaç, doğru parçaların hiçbirini kaçırmadan vücut parçası olmadığı belirgin olan bölgelerin elenmesidir. Kalan vücut parçalarının içinden doğru olanların bulunması, pozun tanınmasıyla birlikte, saklı Markov modeli ile oluşturulan sınıflandırıcı tarafından yapılmaktadır.

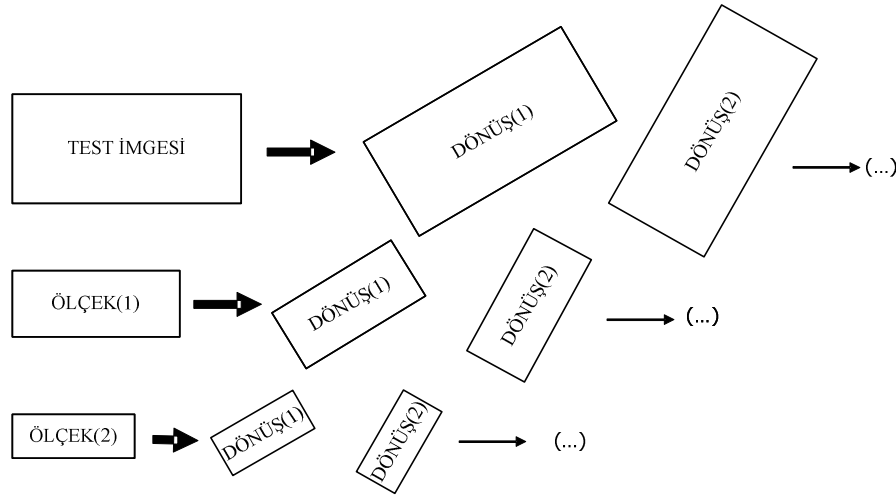
Öznitelik kümesi olarak, Ronfard vd.'nin (2002) çalışmasındaki gibi, Gauss filtresinden geçirilmiş imge parçaları ( $\sigma = 1$ ) ve bunların türevlerinin birleşimi alınmaktadır (Şekil 2.3). Renkli imgelerin yalnızca ışıklılık (luminance) bileşeni kullanılmaktadır.



Şekil 2.3 Üst vücut parçaları için öznitelik kümesi

Destek vektör makinelerinin karakteri gereği, parça bulucuların eğitimi için pozitif verilerin yanında negatif verilerin de kullanılması gerekmektedir. Eğitim kümesi oluşturulurken, pozitif veriler olarak, farklı imgelerden alınmış ilgili (parça bulucunun türünde) vücut parçaları; negatif veriler olarak ise bu imgelerdeki arkaplan parçaları ve ilgisiz (farklı) vücut parçaları alınmaktadır. Bu verilerle öznitelik vektörleri oluşturulduktan sonra, her bir vücut parçası için ayrı bir destek vektör makinesi eğitilmektedir. Destek vektör makinelerinin yapısında, radyal tabanlı çekirdek fonksiyonu kullanılmaktadır.

İmge içinde olası vücut parçaları aranırken, her parça bulucu ile 8 ölçekte ve imgenin kendi ekseni etrafında  $10^\circ$  aralıklı 36 dönüş durumu için tarama yapılmaktadır (Şekil 2.4). Farklı büyüklüklerde elde edilen imge parçaları, eğitimde kullanılan standart büyüklüklere ölçeklenip filtrelendikten sonra destek vektör makinelerine girdi olarak verilmektedir.



Şekil 2.4 İmgenin farklı ölçek ve dönüşlerde taranması

Altı üst-vücut parçası için tespit edilen olası konum ve büyüklük bilgilerinden; parça adaylarının imgedeki merkez koordinatları ve büyüklükleri saklı Markov modeli ile oluşturulan sınıflandırıcıda kullanılmakta, açılı bilgileri ise pozun tespiti için saklı tutulmaktadır.

## BÖLÜM 3

### DOĞRU PARÇA VE KATIŞIMLARIN BULUNMASI

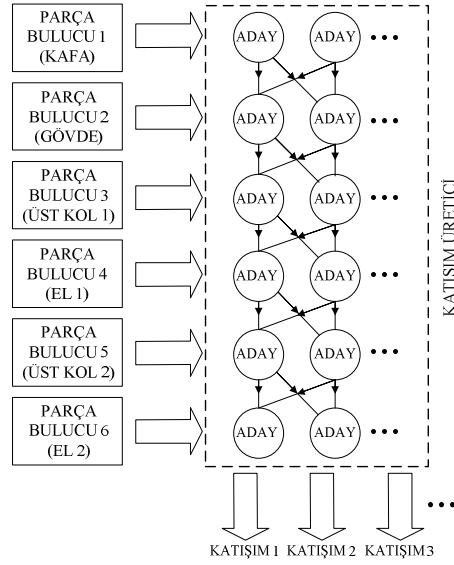
Altı üst vücut parçasının her biri için oluşturulan parça bulucular, imgedeki vücut parçalarının olası yer ve büyüklüklerinde olan farklı sayıda aday vücut parçası tespit etmektedir. Bu noktadan sonra parçaların bireysel niteliklerine göre değil, parçaların birbirine göre niteliklerine göre sınıflandırma yapılmaktadır. Bu yüzden, vücut parçası adaylarının kendi aralarında oluşturabileceği tüm katışımlar (konfigürasyonlar) göz önüne alınmaktadır. Bu katışımlardan, katışımı oluşturan parça adaylarının arasındaki konum ve büyüklük ilişkilerini içeren öznitelik (feature) vektörleri çıkarılmakta; elde edilen öznitelik vektörleri saklı Markov modeli tabanlı sınıflandırıcıya verilmektedir. Parça örtülü olma durumlarına göre tasarlanmış olan beş ayrı saklı Markov modeli tabanlı sınıflandırıcıdan, tanımlanan her parça örtülü durumda çalışabilen sıradüzensel yapıda genel bir sınıflandırıcı oluşturulmaktadır. Böylece, doğru katışım ve bu katışımı oluşturan vücut parçaları, hangi parça ya da parçaların örtülü olduğu (ya da olmadığı) bilgisiyle birlikte tespit edilebilmektedir.

#### 3.1 Katışım Oluşturma

Tasarlanan yöntemde, bir parça bulucu tarafından tespit edilen vücut parçası adaylarının tümünün insan üst vücudunu oluşturan doğru parça olma şansı eşittir. Bu yüzden, altı vücut parçası türünün her biri için tespit edilmiş adaylarla oluşturulabilecek tüm insan üst vücudu katışımlarının doğru olma şansı da başlangıçta (sınıflandırıcıya sokulmadan önce) eşittir.

Katışım oluştururken, bir parça türü için tespit edilmiş bir adayla diğer parça türleri için tespit edilen tüm adaylar eşlenmektedir (Şekil 3.1).





Şekil 3.1 Vücut parçası adaylarından katışımlar oluşturma


Altı üst vücut parçası için parça bulucularla tespit edilmiş aday parça sayıları sırasıyla  $N_{P1}$ ,  $N_{P2}$ ,  $N_{P3}$ ,  $N_{P4}$ ,  $N_{P5}$  ve  $N_{P6}$  ise insan üst vücut modeli için toplam  $N_{P1} \times N_{P2} \times N_{P3} \times N_{P4} \times N_{P5} \times N_{P6}$  katışım oluşturulmaktadır. Bir katışımı meydana getiren adayların nitelikleriyle o katışım için bir öznitelik vektörü oluşturulmakta ve bu öznitelik vektörü (ikinci) sınıflandırıcıya girdi olarak verilmektedir. Bir katışımı oluşturan parça adayları, en az biri hariç, başka bir katışımı oluşturan adaylarla aynı olabilir.

### 3.2 Öznitelik Vektörü Çıkarma

Parça bulucularla elde edilen adayların imge içindeki konum ve büyüklüklerini salt olarak kullanarak insan vücudunu oluşturan katışımı bulabilecek etkili bir sınıflandırılma yapılması düşünülemez. Bu yüzden bir katışımı oluşturan vücut parçası adaylarının taşıdığı nitelikleri (konum ve büyüklük) birbiriyle karşılaştırarak göreceli nitelikler üretilmesi gerekmektedir. Bu göreceli nitelikler, tüm örüntü tanıma problemlerinde olduğu gibi, bir öznitelik vektöründe toplanacak ve sınıflandırıcı için girdi teşkil edecektir.

Bu çalışmada, bir katışım için öznitelik vektörü, katışımı oluşturan parçaların aralarındaki birim uzaklıklar ve oranlarla oluşturulmaktadır. Farklı parça örtülü durumlarında, başarılı bir sınıflandırma yapılabilmesi için, farklı parça adayları

arasındaki nitelikler değerlendirilebilir. Çıkarılan öznelik vektörleri de birbiriyle karşılaştırılacak parça adaylarının seçimine göre farklıdır. Şekil 3.2’de ve Çizelge 3.1’de, parça örtülü durumlar ve bu durumlarda kullanılan parçaların içinden birbirleriyle karşılaştırılacak olanları belirten bağlantılar verilmektedir.



Şekil 3.2 Üst vücut parçaları ve bağlantıları

Çizelge 3.1 Örtülü parçalar ve kullanılan bağlantılar

Parça Örtülü Olma Durumu	Örtülü Parça(lar)	Bağlantılar
1	-	D1, D2, D3, D4, D5, D6, D7
2	Tek El	D1, D2, D3, D4, D5, D6, D9
3	Kollar	D1, D6, D7, D8, D9
4	Eller	D1, D2, D3, D4, D5
5	Tek El ve Tek Kol	D1, D3, D5, D7, D9

Çizelge 3.1’deki her parça örtülü olma durumu bir saklı Markov modeline karşılık gelmektedir. Bir katışım için çıkarılan öznelik vektörü, Çizelge 1’deki bağlantıların uzunlukları ve bağlanan elemanların büyüklükleri arasındaki oranlardan ibarettir. Bir katışımındaki parçalar arası uzunluklar, katışımındaki kafa adayının uzunluğunun yarısına bölünerek düzelenmekte (normalize edilmekte) ve ‘birim uzaklık’ haline getirilmektedir. Böylece uzaklıklar, imge içindeki insan vücudunun büyüklüğünden bağımsız hale gelmektedir. Bağlantılı elemanların büyüklükleri arası oranlar hesaplanırken büyüklük, en - boy çarpımı olarak tanımlanmaktadır.

Beş farklı parça örtülü olma durumuna göre beş türde öznitelik vektörü çıkarılmaktadır. Bu öznitelik vektörleri, karşılık geldiği saklı Markov modeli tabanlı sınıflandırıcıda işlenmektedir.

### 3.3 Saklı Markov Modeli

Saklı Markov modeli, bir örneği oluşturan bileşenlerin spektral (izgesel) özelliklerini karakterize etmekte kullanılan istatistiksel bir modeldir. Bazı parametrelerin bilinmediği bir Markov süreci olarak tanımlanabilir. Herhangi bir istatistiksel modelde olduğu gibi, saklı Markov modelinde de ana tema, verilen gözlem vektörünün parametrik bir rassal süreç (random process) olarak karakterize edilebilmesi ve bu stokastik süreç için ayrıntılı ve hassas parametreler elde edilmesidir (Rabiner and Juang, 1993).

Bu bölümde Markov sürecinin temel özellikleri ve saklı Markov modeline gelişimi ile saklı Markov modelinin yapısı ve işleyiş biçimi anlatılmaktadır.

#### 3.3.1 Ayrık zamanlı Markov süreci

Sabit aralıklı,  $t = 1, 2, \dots, T$  şeklinde gösterilen herhangi bir ayrık zaman diliminde,  $\{S_1, S_2, \dots, S_N\}$  şeklinde dizilmiş  $N$  farklı durumun herhangi birinde bulunan bir sistemde; her ayrık zaman dilimi için durumlar arasında (ya da aynı durumda kalınmak üzere) geçiş yapılabilmektedir. İki durum arası geçiş, durumlarla ilgili olasılıklara göre gerçekleşmektedir. Bu şekilde tanımlanan bir sistemde, bir durumdan diğerine geçiş olasılığı, daha önce bulunulan tüm durumlara bağlıdır ve  $t$  ayrık zaman diliminde bulunulan durum  $q_t$  olmak üzere şu şekilde ifade edilir:

$$P[q_t = S_j | q_{t-1} = S_i, q_{t-2} = S_k, \dots] \quad (3.1)$$

Ancak, özel tanımlı, birinci derece ayrık Markov zinciri için, (3.2)'de görüldüğü üzere, yalnızca bir önceki duruma bağlılık vardır.

$$P[q_t = S_j | q_{t-1} = S_i, q_{t-2} = S_k, \dots] = P[q_t = S_j | q_{t-1} = S_i] \quad (3.2)$$

Bununla birlikte burada, eşitliğin (3.2) sağ tarafının zamana bağlı olmadığı süreçler göz önüne alınmaktadır. Bu tanıma göre  $\mathbf{A} = [a_{ij}]$  durum geçiş olasılıkları matrisi

$$a_{ij} = P[q_t = S_j | q_{t-1} = S_i], \quad 1 \leq i, j \leq N, a_{ij} \geq 0 \text{ ve } \sum_{j=1}^N a_{ij} = 1, \quad \forall j, i \quad (3.3)$$


şeklinde oluşturulabilir.

Sistemin, ilk ayrık zaman diliminde ( $t = 1$ ) olduğuna dair  $\mathbf{\Pi} = [\pi_i]$  başlangıç durum olasılıkları vektörü ise,

$$\pi_i = P[q_1 = S_i], \quad 1 \leq i \leq N \quad (3.4)$$

şeklinde ifade edilir.

Şekil 3.3'te, 3 durumlu bir Markov modeli verilmektedir.



Şekil 3.3 Üç durumlu Markov Modeli

Bu şekilde, her ayrık zaman diliminde bulunulan durumun gözlemlenebilir bir olay teşkil ettiği ( $t$  anında  $q_t$ 'nin ne olduğunun bilindiği) süreç **gözlemlenebilir Markov modeli** olarak isimlendirilebilir. Diğer bir ifadeyle, verilen  $O = (o_1 o_2 \dots o_T)$  gözlem dizisine karşılık gelen durum sırası  $Q = (q_1 q_2 \dots q_T)$  bellidir.

$\mathbf{\Pi}$  ve  $\mathbf{A}$  matrisleri ile ifade edilen model için  $O = (o_1 o_2 \dots o_T)$  şeklinde verilen gözlem dizisi ve buna denk düşen  $Q = (q_1 q_2 \dots q_T)$  durum sırasının gerçekleşme olasılığı

$$\begin{aligned} P(Q|\mathbf{A}, \mathbf{\Pi}) &= P[q_1, q_2, \dots, q_T | \mathbf{A}, \mathbf{\Pi}] \\ &= P[q_1] P[q_2 | q_1] \cdots P[q_T | q_{T-1}] \\ &= \pi_{q_1} a_{q_1 q_2} \cdots a_{q_{T-1} q_T} \end{aligned} \quad (3.5)$$

olarak hesaplanabilir.

### 3.3.2 Saklı Markov modeli ve elemanları

Bu bölüme kadar değinilen Markov modelinde her durum belirli bir gözleme karşılık gelmektedir. Başka bir deyişle, bir durumun çıktısı rasgele değildir. Ancak böyle bir model, birçok uygulamada yetersiz kalmaktadır. Bu yüzden gözlemin, ilgili durumun olasılıksal bir fonksiyonu olduğu bir Markov modeli geliştirilmiştir. Saklı Markov modeli olarak isimlendirilen bu model, doğrudan gözlemlenemeyen ancak gözlem dizisi üreten başka bir rassal süreçle gözlemlenebilen gömülü bir stokastik süreçtir.

Saklı Markov modelinde, durum sırası gözlemlenebilir değildir (yani saklıdır); ancak durum sırasının etkilediği değişken dizisi (gözlem dizisi) bellidir. Diğer bir söylemle, sistemin herhangi bir  $t$  anında hangi durumda olduğu bilinmez, ancak bu durum sonucunda ortaya çıkan gözlem bellidir.

Standart ya da gözlemlenebilir Markov modelinde, durumlar gözlemci tarafından direk olarak bilindiğinden, parametreler durum geçiş olasılıkları (ve başlangıç durum olasılıkları) ile sınırlıdır. Saklı Markov modelinde ise, durum sırası belli olmadığından, elde edilen gözlemlere göre bir durum sırası tahmininde bulunabilmek için gözlemler ve durumlar arasında olasılıksal verilere ihtiyaç vardır.

Saklı Markov modelinde, bir gözlem dizisinin elemanlarını teşkil edebilecek  $M$  adet gözlem çeşidi (sembölü) bilinmektedir. Bu semboller  $V=\{v_1, v_2, \dots, v_M\}$  şeklinde ifade edilebilir. Sistemin herhangi bir  $t$  anında hangi durumda olduğu bilinmese de, sistemin olabileceği  $N$  farklı durum  $\{S_1, S_2, \dots, S_N\}$  da bellidir.

Saklı Markov modelinin ihtiyacı ise, bir gözlem sembolünün bir durumda olmasıyla ilgili olasılık verileridir. Bunun için de,  $b_j(k)$  sistem  $S_j$  durumundayken  $v_k$  gözleminin gelme olasılığı olmak üzere,  $\mathbf{B} = [b_j(k)]$  gözlem sembolü olasılıkları matrisi oluşturulmaktadır. Gözlem sembolü olasılıkları matrisi  $N \times M$ 'lik bir matris olup (3.6)'daki gibi ifade edilebilir.

$$b_j(k) = P[o_t = v_k | q_t = j], \quad 1 \leq k \leq M, 1 \leq j \leq N \quad (3.6)$$

Sonuç olarak;  $\mathbf{A}$ , durum geçiş olasılıkları matrisi;  $\mathbf{\Pi}$ , başlangıç durum olasılıkları matrisi ve  $\mathbf{B}$ , gözlem sembol olasılıkları matrisi olmak üzere bir saklı Markov modelini oluşturan sistem parametreleri şu şekilde ifade edilebilir:

$$\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi}) \quad (3.7)$$

Bu parametreler, verilen bir gözlem dizisi ( $O$ ) için olasılık ( $P(O|\lambda)$ ) üretmek için yeterlidir.

### 3.3.3 Saklı Markov modeline ilişkin üç problem

Bir önceki bölümde verilen saklı Markov modeli tanımını uygulamalarda kullanabilmek için üç temel problemin çözülmesi gerekmektedir.

Bunlardan ilki olasılık hesaplanmasıdır. Buna göre, gözlem dizisi  $O = (o_1 o_2 \dots o_T)$  ve model  $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$  verildiğinde, bu gözlem dizisinin verilen modele göre olasılığı  $P(O|\lambda)$  hesaplanmalıdır.

İkinci problem ise en uygun durum sırasının bulunmasıdır. Saklı Markov modelinin karakteri gereği durum sırası bilinmemektedir. Bu kısımda, saklı Markov modelinin "saklı" kısmını bulmak için bir girişimde bulunulmaktadır. Verilen gözlem dizisi  $O = (o_1 o_2 \dots o_T)$  ve model  $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$  için gözlemleri en iyi karşılayabilen durum sırası tespit edilmelidir.

Diğer ve en önemli problem ise model parametrelerinin hesaplanmasıdır. Saklı Markov modelinin parametreleri  $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$ , verilen gözlem dizisinin olasılığını  $P(O|\lambda)$  en büyütecek (maksimize edecek) şekilde ayarlanmalıdır. Bu kısım, aynı zamanda sınıflandırıcının eğitim sürecini oluşturur.

#### 3.3.3.1 Olasılık hesabı

Bir saklı Markov modeli ve bir gözlem dizisi verilir, gözlem dizisinden bu modele göre elde edilen olasılık hesaplanmak için en kestirme yol oluşturulabilecek tüm durum sıralarını tek tek hesaplamaktır.  $N$  durum için  $Q = (q_1 q_2 \dots q_T)$  şeklinde  $N^T$  durum sırası oluşturulabilir. Bu durumda, gözlem dizisi için olasılık aşağıdaki gibi hesaplanabilir:

$$\begin{aligned} P(O|\lambda) &= \sum_{\text{Tüm } Q\text{'lar}} P(O|Q, \lambda) P(Q|\lambda) \\ &= \sum_{q_1, q_2, \dots, q_T} \pi_{q_1} b_{q_1}(o_1) a_{q_1 q_2} b_{q_2}(o_2) \dots a_{q_{T-1} q_T} b_{q_T}(o_T) \end{aligned} \quad (3.8)$$

Ancak gözlem dizisinin olasılığının yukarıdaki gibi hesaplanması  $2T \cdot N^T$  işlem gerektirdiğinden verimli bir yöntem değildir. Bu yüzden, aynı olasılığın hesaplanması için **ileri-yön algoritması** (Forward Procedure) tercih edilmektedir.

Buna göre,  $t$  anına kadar olan kısmi gözlem serisinin  $t$  anında  $S_i$  durumunda olma olasılığını veren bir ileri-yön değişkeni  $\alpha_t(i)$  tanımlanmaktadır (3.9).

$$\alpha_t(i) = P(o_1 o_2 \dots o_T, q_t = S_i | \lambda) \quad (3.9)$$

Bu değişken aracılığıyla gözlem dizisinin olasılığı aşağıdaki adımlarla hesaplanmaktadır:

### 1. İklendirme

$$\alpha_1(i) = \pi_i b_i(o_1), \quad 1 \leq i \leq N. \quad (3.10)$$

### 2. Yineleme

$$\alpha_{t+1}(j) = \left[ \sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1}), \quad \begin{array}{l} 1 \leq t \leq T-1 \\ 1 \leq j \leq N \end{array} \quad (3.11)$$

### 3. Sonlandırma

$$P(O | \lambda) = \sum_{i=1}^N \alpha_T(i) \quad (3.12)$$

Algoritmanın işlem karmaşıklığı incelenirse,  $N^2 \cdot T$  işlem gerektirdiği görülebilir. Gözlem dizisinin uzunluğunun durum sayısından çok daha büyük olacağı düşünülürse, (3.8)'de verilen ifadeden daha kullanışlı bir yol olduğu söylenebilir.

Verilen gözlem dizisinin olasılığını, aynı şekilde **geri-yön algoritması** (Backward Procedure) kullanarak işlem yükünü artırmadan hesaplamak da mümkündür. Bunun için de, ileri-yön algoritmasında olduğu gibi, bir geri-yön değişkeni  $\beta_t(i)$  tanımlanır (3.13).

$$\beta_t(i) = P(o_{t+1} o_{t+2} \dots o_T | q_t = S_i, \lambda) \quad (3.13)$$

Buradaki ifade ise, verilen  $t$  anındaki durum  $S_i$  ve modele ( $\lambda$ ) göre,  $t + 1$  anından itibaren alınan kısmi gözlem dizisinin olasılığıdır.

Olasılıkların hesaplanması yine benzer adımlarla yapılmaktadır:

### 1. İklendirme

$$\beta_t(i) = 1, \quad 1 \leq i \leq N. \quad (3.14)$$

### 2. Yineleme

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j), \quad t = T-1, T-2, \dots, 1, 1 \leq i \leq N. \quad (3.15)$$

### 3. Sonlandırma

$$P(O | \lambda) = \sum_{i=1}^N \beta_1(i) \pi_i b_i(o_1) \quad (3.16)$$

Algoritma, ileri-yön algoritmasındaki gibi,  $N^2 \cdot T$  işlem gerektirmekte ve gözlem dizisinin olasılığının hesaplanması için kullanışlı bir yol teşkil etmektedir.

Gözlem dizisinin hesaplanmasına ek olarak, ileri-yön ve geri-yön algoritmalarında kullanılan  $\alpha_t(i)$  ve  $\beta_t(i)$  terimleri, diğer problemlerin çözümündeki algoritmalarda da kullanılmaktadır.

### 3.3.3.2 En uygun durum dizisi

İlk problemden farklı olarak, verilen gözlem dizisine göre en uygun durum sırasının bulunma problemi için kesin bir çözüm yoktur. Bunun nedeni, en iyilik (optimality) ölçütlerinin birden fazla olmasıdır. Buna dayanarak, problemin çözümü için birden fazla, farklı sonuç verebilecek yol kullanılabilirdiği söylenebilir.

En uygun durum sırasının bulunması için kullanılabilirdiği bir yol, her bir  $t$  ayrık zaman diliminde en olası durumları ( $q_t$ ) ayrı ayrı seçmektir. Bunun için,  $t$  anında,  $S_i$  durumunda olma olasılığını veren  $\gamma_t(i)$  olasılık değişkeni tanımlanmaktadır (3.17).

$$\begin{aligned} \gamma_t(i) &= P(q_t = S_i | O, \lambda) \\ &= \frac{P(O, q_t = S_i | \lambda)}{P(O | \lambda)} \\ &= \frac{P(O, q_t = S_i | \lambda)}{\sum_{i=1}^N P(O, q_t = S_i | \lambda)} \end{aligned} \quad (3.17)$$

Yukarıdaki ifade, önceki bölümde elde edilen yön değişkenleri  $\alpha_t(i)$  ve  $\beta_t(i)$  cinsinden şu şekilde yazılabilir:

$$\gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{\sum_{j=1}^N \alpha_t(j)\beta_t(j)} \quad (3.18)$$

Elde edilen olasılık değişkeni kullanılarak her  $t$  zamanı için en olası durum aşağıdaki gibi bulunur:

$$q_t^* = \arg \min_{1 \leq i \leq N} [\gamma_t(i)], \quad 1 \leq t \leq T. \quad (3.19)$$

Bu yöntem, beklenen doğru durum sayısını artırsa da, durum geçiş olasılıklarının ( $a_{ij}$ ) sıfır olması durumunda dahi uygun durum sırası bulacağından sorun yaratabilir.



Diğer ve tercih edilen yöntem ise, durum-geçiş olasılıklarını hesaba katarak yukarıdaki yöntemdeki en iyilik ölçütünü düzelten **Viterbi algoritmasıdır**. Viterbi algoritmasında, önceki yöntemden farklı olarak, verilen gözlem dizisi için "tek" uygun durum sırası bulunur. Bunun için öncelikle aşağıdaki gibi bir nicelik tanımlanmaktadır:

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P[q_1 q_2 \dots q_{t-1}, q_t = S_i, o_1 o_2 \dots o_t | \lambda] \quad (3.20)$$

Bu ifade, t anına kadar tek bir yol izlenerek elde edilen ve t anında  $S_i$  durumunda bulunan en yüksek olasılıklı durum sırasının olasılığını göstermektedir. (3.20)'deki ifade yinlendiğinde şu hale gelir:

$$\delta_{t+1}(j) = \left[ \max_i \delta_t(i) a_{ij} \right] \cdot b_j(o_{t+1}) \quad (3.21)$$

Algoritmada durum sırasına erişebilmek için en yüksek olasılıklı argümanın dizininin işlendiği bir matris  $[\psi_t(j)]$  tanımlanmıştır. Algoritma aşağıdaki adımlarla gerçekleştirilmektedir:

1. İklendirme:

$$\delta_1(i) = \pi_i b_i(o_1), \quad 1 \leq i \leq N. \quad (3.22)$$

2. Yineleme

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(o_t), \quad \begin{array}{l} 2 \leq t \leq T \\ 1 \leq j \leq N \end{array} \quad (3.23)$$

$$\psi_t(j) = \arg \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}], \quad \begin{array}{l} 2 \leq t \leq T \\ 1 \leq j \leq N \end{array} \quad (3.24)$$

3. Sonlandırma

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)] \quad (3.25)$$

$$q_T^* = \arg \max_{1 \leq i \leq N} [\delta_T(i)] \quad (3.26)$$

4. Geri iz sürme

$$q_t^* = \psi_{t+1}(q_{t+1}^*), \quad t = T-1, T-2, \dots, 1. \quad (3.27)$$

Viterbi algoritması ile en uygun durum sırasıyla birlikte bu durum sırasının olasılığı  $P^*$  da elde edilir. Böylece, ileri-yön algoritmasıyla da benzeşen algoritma, doğrudan bir gözlem dizisi için olasılık hesaplamak için de kullanılabilir. Ancak işlem, ileri-yön algoritmasından farklı olarak, yalnızca en iyi olasılıklı durum sırası için gerçekleştirilir.

### 3.3.3.3 Model parametrelerinin hesaplanması

Model parametrelerinin belli bir eniyileme ölçütüne göre ayarlanması için bilinen analitik bir yol yoktur. Ancak, **Baum-Welch algoritması** gibi bir beklenti-enbüyütme (expectation-maximization) algoritması vasıtasıyla, döngülü (iterative) olarak, olasılık  $P(O|\lambda)$  en büyüülecek şekilde model parametreleri  $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$  seçilebilir.

Algoritmada kolaylık sağlanması için öncelikle, daha önce verilen algoritmalarda olduğu gibi, bir olasılık değişkeni,  $\xi_t(i,j)$ , tanımlanır (3.28).

$$\xi_t(i,j) = P(q_t = S_i, q_{t+1} = S_j | O, \lambda) \quad (3.28)$$

Bu ifade, sistemin t anında  $S_i$  durumundayken, t + 1 anında  $S_j$  durumunda olma olasılığıdır. Bölüm 3.1.3.1’de elde edilen ileri-yön ve geri-yön olasılık değişkenlerinin tanımlarından faydalanılarak (3.28) şu şekilde tekrar yazılabilir:

$$\begin{aligned} \xi_t(i,j) &= \frac{P(q_t = S_i, q_{t+1} = S_j, O | \lambda)}{P(O | \lambda)} \\ &= \frac{\alpha_t(i) a_{ij} b(o_{t+1}) \beta_{t+1}(j)}{P(O | \lambda)} \\ &= \frac{\alpha_t(i) a_{ij} b(o_{t+1}) \beta_{t+1}(j)}{\sum_{k=1}^N \sum_{l=1}^N \alpha_t(k) a_{kl} b(o_{t+1}) \beta_{t+1}(l)} \end{aligned} \quad (3.29)$$

Bir önceki bölümde, t anında,  $S_i$  durumunda olma olasılığını veren  $\gamma_t(i)$  olasılık değişkenini de,  $\xi_t(i,j)$  cinsinden aşağıdaki gibi ifade etmek mümkündür:

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i,j) \quad (3.30)$$

Yeni parametreler  $\bar{\lambda} = (\bar{\mathbf{A}}, \bar{\mathbf{B}}, \bar{\mathbf{\Pi}})$ ,  $\gamma_t(i)$  ve  $\xi_t(i,j)$  değişkenleri kullanılarak, aşağıdaki formüllerle hesaplanabilirler:

( $S_i$  durumunun (t = 1) anında beklenen olma sıklığı (sayısı))

$$\bar{\pi}_{ij} = \gamma_1(i) \quad (3.31)$$

( $S_i$  durumundan  $S_j$  durumuna beklenen geçiş sayısı /  $S_i$  durumundan beklenen geçiş sayısı)

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (3.32)$$

( $v_k$  gözlem sembolünün  $S_j$  durumunda beklenen olma sayısı /  $S_j$  durumunda beklenen olma sayısı)

$$\bar{b}_j(k) = \frac{\sum_{t=1}^T \gamma_t(j)}{\sum_{t=1}^T \gamma_t(j)} \quad (3.33)$$


Baum-Welch algoritması aşağıdaki adımlarla ifade özetlenebilir:

1. Model parametreleri  $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$  için başlangıç değerleri atama
2.  $\gamma_t(i)$  ve  $\xi_t(i, j)$  değişkenlerin hesaplanması
3. Yeni model parametrelerinin  $\bar{\lambda} = (\bar{\mathbf{A}}, \bar{\mathbf{B}}, \bar{\mathbf{\Pi}})$  hesaplanması
4. Olasılık kontrolü ve durma kararı:  $P_{\text{yeni}} - P < \text{EŞİK}$  koşulu sağlanmıyorsa 2. adıma dönülür.

### 3.3.4 Saklı Markov modeli tipleri

Saklı Markov modelleri, durum-geçişlerine (durum-geçiş olasılıkları matrislerine) göre sınıflandırılabilir. Saklı Markov modelinin yer alacağı uygulamaya göre, durumlar arası geçişler için kısıtlandırmalar getirilebilir ya da serbest bırakılabilir. Bu bölümde, durum-geçişlerine göre iki saklı Markov modeli tipi üstünde durulmaktadır.

Bu bölüme kadar bahsedilen model tipi, durumlar arası her türlü geçişin serbest bırakıldığı ergodik ya da tam bağlı (fully connected) şeklinde isimlendirilen modeldir. Şekil 3.4'te (4 durum için) verilen bu modelin özelliği her  $a_{ij}$  katsayısının pozitif olmasıdır.



Şekil 3.4 Dört durumlu ergodik saklı Markov modeli

Şekil 3.4'te verilen (4 durumlu) ergodik modelin durum-geçiş olasılıkları matrisi de şu şekildedir:

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix} \quad (3.34)$$

Özellikle ses tanıma uygulamalarında sinyalin modellenmesi için tercih edilen saklı Markov model tipi ise soldan-sağa (left-right) modeldir (Bakis modeli). Bu modeldeki zaman dilimi ilerledikçe durum dizin numarasının da ilerlemesi (ya da aynı kalması), ses ya da görüntü gibi özellikleri zaman boyunca değişen sinyalleri modellemek için aranan özelliktir. Modelin en önemli özelliği, dizin numaraları içinde bulunan durumunkinden küçük olan durumlara geçiş olmamasıdır. Diğer bir ifadeyle:

$$a_{ij} = 0, \quad j < i \quad (3.35)$$


Bununla birlikte, durum sırasının her daim durum 1 (S<sub>1</sub>) ile başlaması gerektiğinden, başlangıç durum olasılıkları vektörü [ $\pi_i$ ] şu şekilde ifade edilebilir:

$$\pi_i = \begin{cases} 0, & i \neq 1 \\ 1, & i = 1 \end{cases} \quad (3.36)$$

Modelde ayrıca, durum geçişleri sırasında durumların dizin numaralarındaki değişikliklerin miktarı belirlenebilir. Bunun için de aşağıdaki gibi bir ifade kullanılabilir:

$$a_{ij} = 0, \quad j > i + \Delta i. \quad (3.37)$$

Buradaki  $\Delta_i$  atlama (skip) sayısıdır. Şekil 3.5'te, 4 durumlu soldan-sağa ve geçişlerde en fazla bir durumun atlanmasına izin verilen (bir-atlamalı) bir model verilmiştir.



Şekil 3.5 Dört durumlu soldan-sağa bir atlamalı saklı Markov modeli

Şekil 3.5'teki modelin durum-geçiş olasılıkları matrisi ise şu şekildedir:

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & 0 \\ 0 & a_{22} & a_{23} & a_{24} \\ 0 & 0 & a_{33} & a_{34} \\ 0 & 0 & 0 & a_{44} \end{bmatrix} \quad (3.38)$$

Bunların dışında, durumlar arası geçişler için farklı kısıtlamalar ya da izinler getirilerek farklı tiplerde modeller oluşturulabilir. Tahmin edilebileceği üzere, saklı Markov modeli tipinin, model parametrelerinin hesaplanmasında doğrudan bir etkisi yoktur. Yalnızca durum-geçiş olasılıkları matrisinde bazı elemanların sıfır olarak kalması ya da ilk durum bilindiğinden başlangıç durum olasılıkları vektörünün tekrar hesaplanmasına gereksinim olmaması sağlanır.

### 3.3.5 Çoklu gözlem dizileri

Saklı Markov modeline ilişkin üçüncü problem olan model parametreleri hesabının, sınıflandırıcının eğitim süreciyle ilgili bir problem olduğu aşikârdır. Ancak Baum-Welch algoritmasında model parametreleri  $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$ , yalnızca bir gözlem dizisi için hesaplanmaktadır. Oysaki sınıflandırıcı için saklı Markov modeli oluşturulurken eğitim kümesindeki tüm elemanların, yani birden fazla gözlem dizisinin, kullanılması gerekmektedir. Bu yüzden, model parametrelerinin hesaplanması (modelin eğitimi) için tüm gözlem dizilerinin kullanılabileceği formüller gereklidir.

K adet gözlem dizisinden oluşan bir eğitim kümesi,  $\mathbf{O}^{(k)} = (o_1^{(k)} o_2^{(k)} \dots o_{T_k}^{(k)})$  kümedeki k. gözlem dizisi olmak üzere, aşağıdaki şekilde ifade edilebilir:

$$O = [O^{(1)}, O^{(2)}, \dots, O^{(K)}] \quad (3.39)$$

$P_k$ ,  $k$ . gözlem dizisi için elde edilen olasılık ( $P(O^{(k)}|\lambda)$ ) olmak üzere, aşağıdaki ifadenin en büyütülmesi amaçlanmaktadır.

$$\begin{aligned} P(O | \lambda) &= \prod_{k=1}^K P(O^{(k)} | \lambda) \\ &= \prod_{k=1}^K P_k \end{aligned} \quad (3.40)$$

Bunun için, bölüm 3.1.3.3'te verilen (3.31), (3.32) ve (3.33) denklemlerinin aşağıdaki gibi düzenlenmesi gerekmektedir.

$$\begin{aligned} \bar{\pi}_i &= \sum_{k=1}^K \gamma_1^{(k)}(i) \\ &= \frac{\sum_{k=1}^K \alpha_1^{(k)}(i) \beta_1^{(k)}(i)}{\sum_{k=1}^K \sum_{j=1}^N \alpha_1^{(k)}(j) \beta_1^{(k)}(j)} \end{aligned} \quad (3.41)$$

$$\bar{a}_{ij} = \frac{\sum_{k=1}^K \frac{1}{P_k} \sum_{t=1}^{T_k-1} \alpha_t^k(i) a_{ij} b_j(o_{t+1}^{(k)}) \beta_{t+1}^k(j)}{\sum_{k=1}^K \frac{1}{P_k} \sum_{t=1}^{T_k-1} \alpha_t^k(i) \beta_t^k(j)} \quad (3.42)$$

$$\bar{b}_j(l) = \frac{\sum_{k=1}^K \frac{1}{P_k} \sum_{t=1}^{T_k-1} \alpha_t^k(i) \beta_t^k(j)}{\sum_{k=1}^K \frac{1}{P_k} \sum_{t=1}^{T_k-1} \alpha_t^k(i) \beta_t^k(j)} \quad (3.43)$$

Tahmin edilebileceği gibi, saklı Markov modelin soldan-sağa olması durumunda başlangıç durum olasılık vektörü değişmeyeceğinden, (3.41) ifadesine gerek kalmamaktadır.

### 3.4 Saklı Markov Modeli Vasıtasıyla Sınıflandırıcı Tasarlama

Parça bulucularla tespit edilen parça adaylarından oluşan katışımları sınıflayarak doğru üst vücut katışımı, dolayısıyla doğru parçaları bulabilmek için soldan-sağa atlama saklı Markov modeli kullanılmaktadır. Öznitelik vektöründen gözlem sembolü çıkarma işlemi ise çoktürel (heterojen) bir kodlama yöntemiyle gerçekleştirilmektedir. Eğitim

kümesinden bu şekilde çıkarılan gözlem vektörleriyle saklı Markov modelleri eğitilmekte ve her model için parametreler  $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$  elde edilmektedir. Verilen bir gözlem vektörünün sınıflandırılması da Viterbi algoritması ile gerçekleştirilmektedir.

### 3.4.1 Gözlem sembollerinin çıkarılması

Saklı Markov modellerine girdi olarak verilecek gözlem vektörlerini oluşturan semboller çoktörel bir yöntemle kodlanmaktadır. Buna göre öznitelik vektörlerine dönüştürülmüş eğitim kümesinde, öznitelik vektörünün her katmanı için yerel uç değerler (minimum ve maksimum) bulunmakta ve sıralanmaktadır. Bu noktaların arasına ve bu noktaların içinde en dışta bulunan değer dışındaki bölgeler için sembol ataması yapılmaktadır. Elde edilmek istenilen ayrık alfabenin büyüklüğüne göre göre, aralarında belli bir değerden küçük fark bulunan iki nokta tek bir notada birleştirilmektedir.

Gözlem vektörlerini oluşturan semboller “çiftli” ve “tekli” olmak üzere iki yöntemle kodlanmıştır.

$D1, D2, \dots$  ve  $R1, R2, \dots$  sırasıyla öznitelik vektörünü oluşturan birim uzaklık ve oran değerleri olmak üzere, “çiftli” kodlama dizilimi aşağıdaki gibi yapılmaktadır:

$$\left[ \left( \begin{array}{c} D1 \\ R1 \end{array} \right), \left( \begin{array}{c} D2 \\ R2 \end{array} \right), \dots \right] \quad (3.44)$$

Burada vücut parçalarının merkezleri arasındaki birim uzaklıklarla bu parçaların birbirine oranlarından çiftler oluşturulmakta ve semboller atanmaktadır. Böylece saklı Markov modeline verilecek gözlem vektörünün boyutu, bir gruplama için olasılık üretmede gereken işlem yüküyle beraber azaltılmaktadır. Ayrıca gözlem sembolü sayısının artmasıyla uzaklık - oran uyumundan uzak olan durumların olasılıkları azaltılarak ayırt edicilik artırılmaktadır.

Bazı örtülü parça durumlarındaki simetri eksikliği nedeniyle uzaklık - oran uyumunun fazlasıyla çeşitlenmesi sonucu olasılık değerlerindeki düşme yüzünden uzaklık - oran çiftleri oluşturulmadan, (3.44)'teki gibi, “tekli” bir kodlama da gerçekleştirilmektedir.

$$(D1, R1, D2, R2, \dots) \quad (3.45)$$

Parça örtülü duruma göre saklı Markov modellerinde uygulanan kodlamaların yöntemi (çiftli ya da tekli) test süreçleriyle belirlenmektedir. Ancak, başarı oranında belirgin bir düşüş ya da değişiklik olmuyorsa, daha avantajlı olduğu için “çiftli” kodlama yöntemi tercih edilmektedir.

### 3.4.2 Sınıflandırıcının eğitimi ve model parametrelerinin elde edilmesi

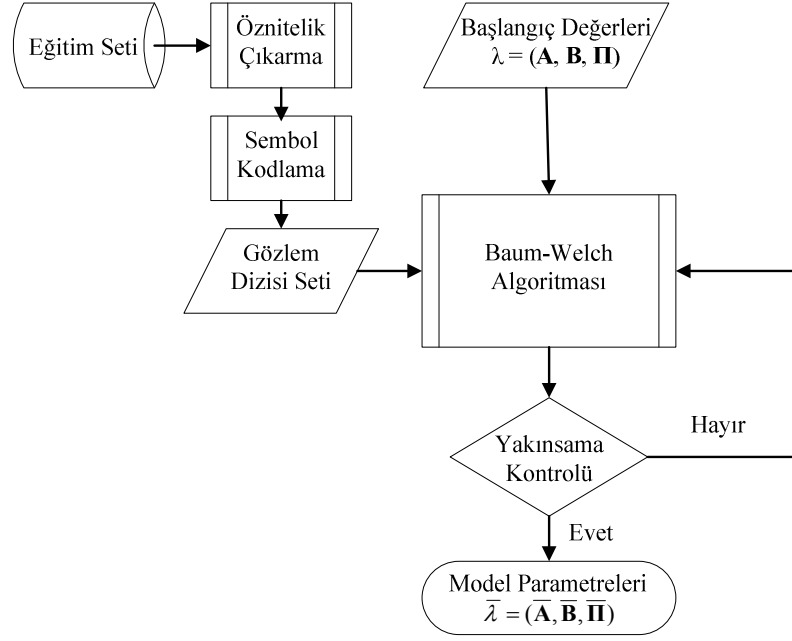
Eğitim kümesinden öznitelik vektörleri ve gözlem dizileri elde edildikten sonra, saklı Markov modellerini eğitmek için yapılması gereken Baum-Welch algoritması gibi bir beklenti-embüytme algoritması uygulayarak model parametrelerini ( $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$ ) elde etmektir. Bunun için, bölüm 3.3.5’te verilen (3.42) ve (3.43) ifadelerinden faydalanılmaktadır.

Çıkarılan öznitelik vektörlerinde elemanların dizilişi sabittir. Diğer bir ifadeyle, katışımdaki iki parça arasındaki bir birim uzaklık ya da oran değerinin, öznitelik vektöründeki yeri değişmemektedir. Bu yüzden sistemde soldan-sağa modeller kullanılmaktadır. Sistemde, gözlem dizilerinin elemanları çoğunlukla farklı niteliklerde olduğundan ve gözlem dizilerinin uzunluğu çok büyük olmadığından (çiftli kodlama için  $T \leq 7$ , tekli kodlama için  $T \leq 14$ ), durum sayısı da gözlem dizilerinin uzunluğuna eşit olacak şekilde verilmektedir ( $N = T$ ). Ayrıca, öznitelik vektörünün bazı elemanları (gövde-eller arası birim uzaklıklar), imgedeki insan pozuna göre bazen birbirine benzer nitelikte olabileceğinden soldan-sağa modelde 1 atlamaya izin verilmiştir.

Belirgin bir fark oluşturmamakla beraber, Baum-Welch algoritması uygulanırken, model parametrelerinden gözlem sembolü olasılıkları matrisinin ( $\mathbf{B}$ ) ilk değerlerinin tutarlı verilmesi, algoritmanın (döngünün) daha hızlı yakınsamasını ve daha doğru değerler elde edilmesini sağlamaktadır (Rabiner and Juang, 1993). Durum geçiş olasılıkları matrisinin ( $\mathbf{A}$ ) ilk değerleri için ise, bölüm 3.3.4’teki (3.38) ifadesindeki gibi, aynı satırda değerleri aynı ve toplamları 1 olan elemanları içeren  $N \times N$ ’lik bir matris oluşturulabilir. Soldan-sağa model kullanıldığından, başlangıç durum olasılıkları vektörü  $\mathbf{\Pi}$  bellidir ve eğitimde yer almasına gerek yoktur.

Bir saklı Markov modelinin eğitim süreci aşağıdaki gibi özetlenebilir:





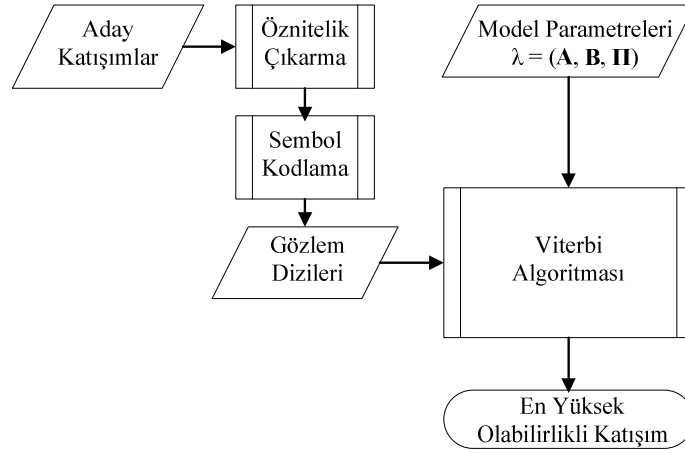
Şekil 3.6 Saklı Markov modelinin eğitilmesi

Beş farklı parça örtülü olma durumuna göre beş farklı saklı Markov modeli eğitilmekte ve (çiftli ve tekli kodlamaların her biri için) beş farklı model parametre grubu  $(\lambda_1, \dots, \lambda_5)$  elde edilmektedir.

### 3.4.3 Doğru katışımın bulunması

Saklı Markov modellerinin parametreleri hesaplandıktan sonra olasılık üreten bir algoritma ile her katışım için olabilirlik (likelihood) değerleri elde edilmektedir. Bunun için ileri-yön ile geri yön algoritması ya da Viterbi algoritması kullanılabilir. Bu çalışmada, çoğu örüntü tanıma probleminde olduğu gibi, bir gözlem dizisinde oluşturulabilecek tüm durum sıraları yerine, yalnızca o gözlem dizisi ile oluşturulabilecek en uygun durum sırası için olabilirlik değeri  $(P(O, \hat{Q} | \lambda))$  üreten Viterbi algoritması tercih edilmektedir.

Saklı Markov modeli tabanlı sınıflandırıcının genel yapısı aşağıdaki gibi ifade edilmiştir:



Şekil 3.7 Viterbi algoritması ile doğru katışımın bulunması

Şekil 3.7'de görüldüğü üzere, parça buluculardan elde edilen parça adaylarından tüm parça birleşimlerine göre eşlenerek oluşturulan her katışım için, ilgili saklı Markov modeli ile bir olasılık değeri üretilmektedir. (3.46)'da verildiği gibi,  $\lambda_j$  uygun model olmak üzere, en yüksek olasılığa sahip olan parça birleşimi doğru katışım olarak seçilmekte ve insan vücudunu oluşturan parçalar olarak işaretlenmektedir.

$$r = \underset{\text{Tüm Katışımlar}}{\arg \max} P(O_Q | \lambda_j) \quad (3.46)$$

### 3.5 Parça Örtülü Durumlara Göre Genel Bir Sınıflandırıcı Oluşturma

Parça bulucularla insan üst vücudunu oluşturan parçaların olası yer ve büyüklüklerinin tespitinden sonra aslında iki tane sınıflandırma problemi vardır. İlki, önceki bölümde bahsedilen doğru katışımın bulunmasıdır. Diğeri ise, hangi parçaların örtülü durumda olduğunun tespitidir. Bu iki problem birbiriyle bütünleşiktir; birinin çözümü, diğeriyle elde edilecek sonuca bağlıdır. Doğru katışımın bulunması için öncelikle örtülü olma durumunun bulunması gerekmektedir. Çünkü farklı parça örtülü durumlar için öznitelik vektörleri farklı şekillerde çıkarılmakta ve farklı modeller eğitilmektedir. Örtülü olma durumunun bulunabilmesi için de tüm modellerin ürettiği olabilirlik değerlerine ihtiyaç duyulmaktadır.

Tüm modellerle elde edilen olabilirlik değerlerini kullanarak örtülü olma durumunun tespit edilmesi için akla gelebilecek ilk yol, bu olabilirlik değerlerinden en büyüğünün seçilmesidir. Farklı modellerde üretilen olasılık değerleri farklı aralıklarda

olabileceğinden, olabilirlik değerlerinin belli ölçütlere göre düzelenmesi gerekmektedir. Buna göre iki ölçüt kullanılmaktadır. İlki, verilen olabilirlik değerini, her model için eğitim kümesinden elde edilen olabilirlik değerlerinin ortalamalarına bölerek düzgelemektir.  $P_i$ , i. model ile elde edilen olabilirlik değeri ve  $P_{iort}$ , i. model için eğitim kümesinden elde edilen olabilirlik değerlerinin ortalaması olmak üzere i. model için düzelenmiş olabilirlik değeri  $P_i^*$ , aşağıdaki gibi hesaplanabilir.

$$P_i^* = \frac{P_i}{P_{iort}}, \quad 1 \leq i \leq 5 \quad (3.47)$$

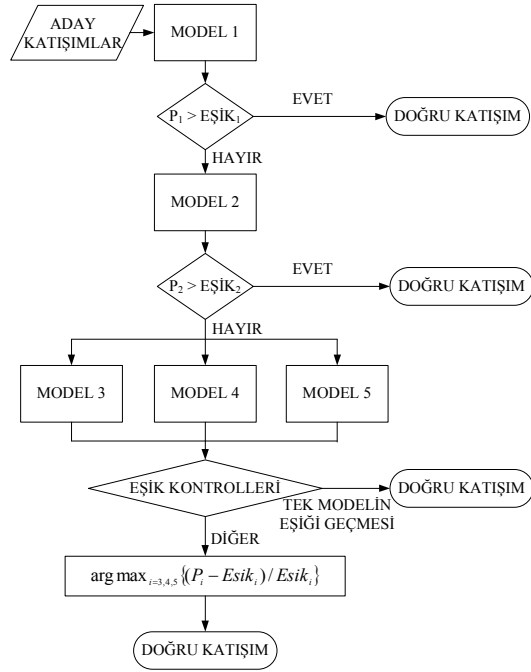
Diğeri de, verilen olabilirlik değerini, her model için eğitim kümesinden elde edilen olabilirlik değerlerinin en küçüklerinden çıkarıp, en büyük ve en küçük değerlerin farklarına bölmektir.  $P_i$ , i. model ile elde edilen olabilirlik değeri;  $P_{imin}$ , i. model için eğitim kümesinden elde edilen en küçük olabilirlik değeri ve  $P_{imax}$ , i. model için eğitim kümesinden elde edilen en büyük olabilirlik değeri olmak üzere i. Model için düzelenmiş olabilirlik değeri  $P_i^*$ , aşağıdaki gibi hesaplanabilir.

$$P_i^* = \frac{P_i - P_{imin}}{P_{imax} - P_{imin}}, \quad 1 \leq i \leq 5 \quad (3.48)$$

Bu şekilde elde edilen düzelenmiş olabilirlik değerleri arasından en büyüğü seçilerek örtülü durumun tespiti gerçekleştirilmektedir (3.49).

$$\arg \max_{1 \leq i \leq 5} (P_i^*) \quad (3.49)$$

Ancak, parça örtülü olma durumlarından bazıları, içerdiği parça türü bakımından diğerlerini de kapsadığından, imgede hangi parçaların örtülü olduğunun yani uygun modelin tespiti bu çalışmada, olabilirliklere dayalı sıradüzensel bir sınıflandırma süreciyle gerçekleştirilmektedir (Şekil 3.8).



Şekil 3.8 Genel sınıflandırıcı

Bu süreçte, eğitim setindeki verilerle, her modelin doğru katışımlar için üreteceği olabirlik değerleri için eşik değerleri belirlenmektedir. Katışımların içerdiği parça sayısına göre (parça örtülü durumlara göre) bir sıradüzen yaratılmaktadır. Öncelikle en çok parça içeren durumlardan başlayarak en yüksek olabirlikli katışımlar ve olabirlikleri tespit edilmektedir. Olabirlik değeri, o durum için belirlenen eşik değerinden büyükse parça örtülü durum tespit edilmiş olunmakta ve daha alttaki modellerle geçilmemektedir. Katışımlardaki parça sayılarının aynı olduğu durumlarda ise tüm modellerle olabirlik değerleri üretilmekte ve eşik değerinin geçilebildiği model seçilmektir. Saklı Markov modeli ile üretilen olasılık değerleri tutarlı olduğundan, genellikle yalnızca bir model için eşik değeri üzerine çıkılmaktadır. Yine de, birden fazla model için elde edilen olabirlik değerinin ilgili eşik değerini geçtiği ya da tüm modellerin olabirliklerinin ilgili eşik değerlerinin altında kaldığı durumlar için de ek bir algoritma hazırlanmıştır. Buna göre, olabirlik değerleriyle ilgili eşik değeri arasındaki farkın bu eşik değeriyle düzgelmesiyle elde edilen değerlerin en büyüğü seçilerek parça örtülü durumun tespiti gerçekleştirilmektedir.

## BÖLÜM 4

### DENEYSEL ÇALIŞMALAR


Tasarlanan sınıflandırıcının sınılanması çeşitli aşamalarda gerçekleştirilmektedir. Öncelikle, eğitim ve test için kullanılan verilerin güvenilirliği ve tutarlılığı doğrulanmaktadır. Beş farklı örtülü olma durumu için oluşturulmuş saklı Markov modeli tabanlı sınıflandırıcılar önce ayrı ayrı sınıp başarı oranları çıkarılmaktadır. Her sınıflandırıcı için en yüksek başarımın alındığı koşullar tespit edildikten sonra, bu koşullar göz önüne alınarak tüm örtülü durumlar (ve örtülü olmayan durum) için oluşturulmuş genel sınıflandırıcının sınılanması gerçekleştirilmektedir. Son kısımda ise, saklı Markov modeli, çok değişkenli Gauss dağılımı ve destek vektör makinesi tabanlı tasarlanmış bireysel ve genel sınıflandırıcıların doğruluk oranları karşılaştırılmaktadır.

#### 4.1 Eğitim ve Test Verileri

Sınıflandırıcıların eğitimi için MIT yaya veritabanı içinde bulunan 193 imge kullanılmıştır. İmgeler üzerinde kafa, gövde, üst kollar ve eller, dikdörtgenler ile işaretlenmekte ve dikdörtgenlerin imge içindeki konumları ve büyüklük bilgileri kullanılarak her bir imge için öznitelik vektörü ve gözlem dizisi oluşturulmaktadır. Gözlem dizileri, 5 saklı Markov modelinin her biri için önceki bölüm 3.4.1’de verilmiş olan kodlamalara göre oluşturulmuştur. İlgili gözlem dizileri ile her bir model için parametreler  $\lambda = (\mathbf{A}, \mathbf{B}, \mathbf{\Pi})$  tespit edilmektedir.

Testlerde ise, MIT yaya veri tabanından eğitimde kullanılmayan 30 imge ve internetten bulunan farklı boyutlardaki 20 imge olmak üzere toplam 50 imge kullanılmaktadır. Test imgelerindeki vücut parçaları destek vektör makinesi tabanlı parça bulucuların tespitlerine benzer şekilde işaretlenmekte ve her bir parça dikdörtgen ile çerçevelenmektedir. Bir imgede işaretlenen her üst vücut parçası için, bu imge içinde farklı konum ve büyüklüklerde olabilecek şekilde, ikişer tane sahte vücut parçası işaretlenmiştir. Böylece, altı üst vücut parçasının her biri için üçer tane olası konum ve büyüklük bilgisi oluşturulmuştur.

Geliştirilen sınıflandırıcıların güvenilirliğini sınamak için, doğru üst vücut parçalarının işaretlendiği bir imgede, parçalardan birinin konumu tanımlı olduğu bölge içinde dikey ve yatay olarak değiştirilmektedir. Şekil 4.1'de kafanın ve üst kol 1'in konumunun imgede kaydırıldığı alan, büyük noktalı karelerle, gerçek konumları siyah çerçevelerle ve en yüksek olabilirlik değeri ürettiği yerler de gri karelerle gösterilmektedir.



Şekil 4.1 Test resmi parça işaretleme ve test alanı belirleme: a) Üst kol 1, b) Kafa

Her bir model için sınama imgelerinin ve üzerine eklenen vücut parçalarının doğru dağıldığından emin olmak için, eğitim kümesindeki ve sınama kümesindeki vücut parçaları arasındaki uzaklıkların birim toplamı bir ölçüt olarak kullanılmakta ve bu ölçüye uzaklık toplamı (U.T.) adı verilmektedir. Her bir model için kullanılan simge sayısı, bir sınama imgesi için oluşturulan birleşim sayısı, eğitimde kullanılan vücut parçaları arası birim uzaklık toplamı ve sınamada kullanılan parçalar arası birim uzaklık toplamalarının değişim aralıkları Çizelge 4.1'de verilmektedir.

Çizelge 4.1 Sınıflandırıcılarda kullanılan veriler

Model	Sembol Sayısı	Katılım Sayısı	Eğitim U.T.	Sınama U.T.
1	99	729	13,8 – 26,6	7,0 – 198,3
2	8	243	15,5 – 30,5	6,9 – 245,2
3	36	81	11,0 – 31,4	4,5 – 167,3
4	42	81	10,9 – 17,2	4,2 – 137,2
5	9	81	10,8 – 24,2	5,3 -174,0

Burada, eğitim ve sınama kümesindeki veriler için birim uzaklık toplamı araklıklarının örtüşmesine dikkat edilmektedir. Diğer bir ifadeyle, eğitim kümesindeki elemanların birim uzaklık toplamı aralığı, sınama verilerindekilerin aralığının içinde olmalıdır.

## 4.2 Testler

Oluşturulan 5 sınıflandırıcının önce bireysel başarı oranları elde edilmektedir. Her sınıflandırıcının yüksek başarı elde ettiği yöntem ve parametreler dikkate alınarak yapılandırılan genel sınıflandırıcıda, aynı test verileriyle tekrar sınama yapılmaktadır. Elde edilen sonuçlar, aynı test verilerinden aynı şekilde çıkarılmış öznitelik vektörleriyle oluşturulan destek vektör makinesi tabanlı bir sınıflandırıcı vasıtasıyla elde edilen başarı oranları ile karşılaştırılmaktadır.

### 4.2.1 Bireysel testler

Her bir saklı Markov modelinin durum geçiş olasılıkları matrisi  $A$ , gözlem sembolü olasılıkları matrisi  $B$  ve başlangıç durum olasılıkları vektörü  $\Pi$ , bölüm 4.1’de tanımlanan eğitim verileri ile oluşturulmaktadır. Aynı bölümde verilen test verileri ile her bir sınıflandırıcı, bölüm 3.4.1’de verilen çiftli ve tekli sembol kodlamaların her ikisiyle de sınanmaktadır. Bir sınamanın başarılı sayılması için, bölüm 4.1’de bahsedilen, her üst vücut parçası için üçer tane oluşturulmuş aday parçalarla oluşturulan katışımlardan doğru parçaları içeren katışımın bulunması gerekmektedir. Başarım yüzdeleri Çizelge 4.2’de ayrı ayrı verilmektedir.

Çizelge 4.2 Başarım oranları

Model	Başarım (%)	
	Sembol Kodlama Yöntemi	
	Çiftli	Tekli
1	98	86
2	14	94
3	92	92
4	94	94
5	2	98

Çizelge 4.2’de görüldüğü gibi, gözlem sembollerinin farklı kodlamaları ile farklı parça örtülü olma durumlarında yüksek başarımlar elde edilmektedir. Buna göre 1., 3., ve 4. durumlar için çiftli, 2. ve 5. durumlar için de tekli sembol kodlamalarıyla yüksek başarımlar sağlanmaktadır. Saklı Markov modellerinin ürettiği olasılıklara dayalı genel sınıflandırıcı oluşturulurken, her parça örtülü durum için daha yüksek başarımları sağlayan sembol kodlama yöntemi seçilmektedir.

#### 4.2.2 Genel sınıflandırıcı ile yapılan test

Bölüm 3.5’te verilen sıradüzensel genel sınıflandırıcı, önceki bölümde belirlenen, her sınıflandırıcı için uygun olan kodlama yöntemi kullanarak oluşturulmaktadır. Kullanılan sınıflandırıcı verileri bir önceki bölümdekilerle aynıdır. Ancak bu kez, bir parça örtülü durum için sınıflandırma başarısı, hem parça örtülü durumun doğru tespit edilmesi, hem de doğru parçaları içeren katışımın bulunması olarak tanımlanmaktadır. Çizelge 4.3’te her parça örtülü durum için genel sınıflandırıcının başarı yüzdesi verilmektedir.

Çizelge 4.3 Sıradüzensel genel sınıflandırıcı için başarımlar oranları

Parça Örtülü Durum	Başarımlar (%)
1	96
2	94
3	90
4	94
5	96

Çizelge 4.3’te verilen sonuçların Çizelge 4.2’dekilerden daha düşük olması, ilgili sınıflandırıcı tarafından doğru olarak tespit edilebilen bazı katışımlar için elde edilen olabirlik değerlerinin nispeten küçük olması nedeniyle genel sınıflandırıcının başarısız olmasını sonucudur.

Sıradüzensel bir sınıflandırma yöntemi yerine bölüm 3.5’te verilen sıradüzensel olmayan yöntemler (ortalama ile düzgeleme ve uç noktalara göre düzgeleme) kullanılarak elde edilen sonuçlar da Çizelge 4.4’te verilmektedir.



Çizelge 4.4 Sıradüzensel olmayan genel sınıflandırıcılar için başarımlar oranları

Parça Örtülü Durum	Başarımlar (%)	
	Düzgeleme yöntemi	
	Ortalama	Uç noktalar
1	0	10
2	0	20
3	92	90
4	94	94
5	90	92

Çizelge 4.4'te görüldüğü üzere, parça sayısının daha fazla olduğu modeller için, parça örtülü durumun doğru olarak tespit edilmesi pek mümkün görünmemektedir. Bu açıdan sıradüzensel süreç, parça örtülü durumun bulunmasında, dolayısıyla doğru katışımın ve doğru üst vücut parçalarının bulunmasında uygulanması gerekli bir algoritmadır.

### 4.3 Farklı Yöntemlerle Oluşturulan Sınıflandırıcıların Karşılaştırılması

Önceki bölümlerde başarı yüzdeleri verilmekte olan ve bu çalışmanın konusu olan sınıflandırıcı saklı Markov modeli temelli yapılandırılmıştır. Üst vücut parçalarının olası konum ve büyüklükleri için parça bulucularla elde edilen adaylarla oluşturulan katışımın için olabirlik değerleri üretimi, örüntü tanıma uygulamalarında kullanılabilen herhangi bir yöntemle de gerçekleştirilebilmektedir. Olabirlik değerleri üretmede kullanılabilir basit metotlardan biri olan çok değişkenli Gauss dağılımı, Gauss karışım modeli (Gaussian Mixture Model, GMM) ve sürekli saklı Markov modelinin temelini teşkil eden bir yöntemdir. Destek vektör makineleri ise, temelde evet/hayır cevabı almak için kullanılmakta da olsa, olabirlik değeri elde edilebilecek bir yöntemdir. Bu bölümde, bu üç yöntemle geliştirilen sınıflandırıcılar ile üst vücut parçalarını içeren katışımın bulunması uygulamasındaki getiri ve götürüleri tartışılmaktadır.

Katışımından çok değişkenli Gauss dağılımı ile olabirlik değeri elde edilmesi, diğer yöntemlere nazaran çok basit bir şekilde gerçekleştirilmektedir. Öncelikle eğitim kümesinde, öznitelik vektörlerine dönüştürülmüş veri ile ortalama vektörü  $\mu$  ve kovaryans matrisi  $\Sigma$  çıkarılmaktadır. Öznitelik haline getirilmiş bir katışım ( $\mathbf{x} \in \mathcal{R}^N$ )

için olabirlik üretilmesi için, çok deęişkenli Gauss daęılımı denklemini uygulamak yeterlidir (4.1)

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{N/2} |\boldsymbol{\Sigma}|^{1/2}} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})\right) \quad (4.1)$$

Destek vektör makineleri, temelde ikili sınıflandırma problemini çözmek için geliştirilmiştir. Bu yüzden, doğru katışımın bulunması için destek vektör makinesi tabanlı sınıflandırıcı eğitilirken negatif veri, yani vücut parçalarının tümünün doğru olmadığı katışımlarla oluşturulan veri, kullanılması gerekmektedir. Saklı Markov modeli ve çok deęişkenli Gauss daęılımı da aynı şekilde sınıflandırma problemlerinin çözümünde kullanılabilir. Ancak, bu çalışmada olduğu gibi bir ikili sınıflandırma problemi için eğitim sürecinde negatif verilere ihtiyaç duyulmamaktadır.

Bölüm 4.1'teki tanımlanan eğitim verileri ve negatif veri olarak sanal (sahte) parçalar kullanılarak üç farklı yöntem ile oluşturulan sınıflandırıcıların aynı test verileriyle sınanmasıyla elde edilen başarı oranları Çizelge 4.5 ve Çizelge 4.6'da verilmiştir.

Çizelge 4.5 Bireysel sınıflandırıcılar için başarı oranları

Parça örtülü durum	Başarı (%)		
	Yöntemler		
	Saklı Markov modeli	Çok deęişkenli Gauss daęılımı	Destek vektör makinesi
1	98	98	92
2	94	98	94
3	94	98	98
4	92	98	86
5	98	94	96
Ortalama	95,2	97,2	93,2

Çizelge 4.6 Genel sınıflandırıcılar için başarımları oranları

Parça örtülü durum	Başarımları (%)		
	Yöntemler		
	Saklı Markov modeli	Çok değişkenli Gauss dağılımı	Destek vektör makinesi
1	96	90	86
2	94	82	78
3	94	54	96
4	90	96	78
5	96	96	80
Ortalama	94	83,6	83,6

Çizelge 4.5'te görüldüğü üzere modellerin bireysel olarak başarımları oranları çok değişkenli Gauss dağılımı için daha yüksektir. Ancak bu, çok değişkenli Gauss dağılımının daha başarılı bir sınıflandırma yöntemi olduğu anlamına gelmemektedir. Çünkü parça örtülü durum varsa, bu durumun hangi örtülü durum olduğu bilinmeksizin belirlenen katışım insan vücudu olmayan parçalardan bir ya da birkaçını içeriyor olabilir. Çok değişkenli Gauss dağılımı tabanlı geliştirilen sınıflandırıcılarla, bireysel olarak daha yüksek başarımları elde edilmiş olsa da, doğru olmayan katışımlarda da yüksek olabilirlik değerleri üretildiği için parça örtülü durumların tespit edilmesinde saklı Markov modeli kadar başarılı olunamamaktadır (Çizelge 4.6). Destek vektör makinesi için ise, gerek bireysel olarak, gerekse genel sınıflandırıcı ile elde edilen başarımları oranları saklı Markov modelinden daha düşüktür. Buna dayanarak saklı Markov modelinin daha güvenilir olabilirlik değerleri üretilen bir yöntem olduğu söylenebilir.

## BÖLÜM 5

### SONUÇLAR

Yapılan çalışmada, imgedeki insan üst vücut parçalarının olası konum ve büyüklüklerinin bulunup insan modeli oluşturacak şekilde birleştirilmesi için bir yöntem önerilmektedir. İki aşamalı olarak gerçekleştirilen süreçte, sınıflandırıcıların son çıktısı insan üst vücut parçalarının yerleri ve büyüklükleri bilgisini içerdiğinden doğru vücut parçalarıyla beraber insan pozu da bulunmuş olmaktadır. Bu yönüyle yöntem, uzun vadede, görüntüden hareket tanıma çalışmaları için bir ön aşama teşkil etmektedir.

Parçaların ön tespiti için destek vektör makinesi tabanlı parça bulucular kullanılmaktadır; çünkü olası olmayan parça konum ve büyüklüklerini elemek için karmaşık olmayan bir ikili sınıflandırıcıya ihtiyaç duyulmaktadır. Böylece, bu aşamaya daha az işlem yükü düşmektedir. Yöntemin asıl amacı da, insan üst vücudunun bulunması işleminin ikinci aşama olan doğru parça birleşiminin tespit edildiği kısımda gerçekleştirerek toplam işlem yükünü azaltmaktır. Destek vektör makinesi ile yapılandırılmış parça bulucular, sade yapılarıyla bu amaca hizmet edecek uygun sınıflandırıcılardır.

İnsan üst vücut parçalarının olası konum ve büyüklüklerini teşkil eden aday imge parçalarından doğru olanların bulunması, bu aday parçaların tümü kullanılarak oluşturulan katışımlardan doğru olanın bulunmasıyla gerçekleştirilmektedir. Katışımları oluşturan parçaların birbirine göre birim uzaklık ve büyüklük bilgileriyle öznitelik vektörleri çıkarılmaktadır. Bu sayede, adayların birbiriyle uygun oranda olmadığı katışımların elenebilmesi ve sınıflandırmanın imgedeki insan vücutlarının büyüklük ölçütünden bağımsız olarak gerçekleştirilebilmesi sağlanmaktadır. Doğru katışımın bulunması için saklı Markov modeli temelli oluşturulan sınıflandırıcılar kullanılmaktadır. Saklı Markov modeli, tutarlı olabilirlikler üretebildiği ve eğitim için negatif verilere gereksinim duymadığı için, bu gibi ikili sınıflandırmalarda avantajlı bir yöntemdir. İmgede, kameranın bakış açısına göre, insan üst vücudunu oluşturan bazı parçaların örtülü kalma durumları düşünülerek, ikinci aşamada birden fazla model oluşturulmaktadır. Farklı parça örtülü durumlar için oluşturulan beş farklı modelden uygun olanının seçilmesinde standart çoklu sınıflandırma yöntemleri, parça sayısının

fazla olduđu modellerin para sayısının daha az olduđu bazı modelleri kapsamayı nedeniyle başarılı olamamaktadır. Bu nedenle, olabilirliklere dayalı sıradüzensel bir genel sınıflandırıcı kullanılmakta, böylece ilk kısımda örtülü durumdaki paraların yerine bulunabilecek yanlış para adaylarının doğru katışımla birlikte doğru para olarak nitelendirilmesi engellenmektedir.

İnsan üst vücudunu teşkil eden doğru paraların oluşturulduđu katışımın bulunması için tasarlanan sınıflandırıcılarla, gerek bireysel olarak, gerekse genel bir sınıflandırıcı olarak bir araya getirildiklerinde, başarılı sonuçlar elde edilebilmektedir. Çalışmada önerilen yöntem olan saklı Markov modelinin para örtülü durumlardaki sınıflama performansının, olabilirlik üretebilen sınıflandırma yöntemlerinden çok deđişkenli Gauss dağılımı ve destek vektör makinesi ile karşılaştırılıp bu problem için doğru bir seçim olup olmadığı tartışılmaktadır. İmgedeki insan üst vücudunu, hangi paralarının örtülü olduđu ya da olmadığı bilgisiyle birlikte tespit edilmesinde diđer yöntemlere göre daha yüksek başarı oranları elde edilen saklı Markov modelinin bu konudaki sınıflandırmada daha uygun bir yöntem olduđu doğrulanmaktadır.

Çalışmada, insan üst vücut paralarının yalnızca önden görünüşleri üzerinde durulmuştur. Yöntem, imgede farklı açılarda gözlemlenebilen diđer duruşlara genişletilebilir. Böylece, görüntüden hareketen çıkarma uygulamalarında daha verimli olarak kullanılabilen bir hale gelecektir.

## KAYNAKLAR DİZİNİ

- Ben-Arie, J., Sivalingam, D., and Rajaram, S., 2003, Probabilistic labeling of human body parts, IASTED International Conference on Circuits, Signals and Systems, (IASTED'03), 275-280.
- Burges, C.J.C., 1998, A tutorial on support vector machines for pattern recognition, *Data Mining and Knowledge Discovery*, 2, 2, 121-167.
- Elzein, H., Lakshmanan, S., and Watta, P., 2003, A motion and shape-based pedestrian detection algorithm, *IEEE Intelligent Vehicles Symposium*, 500–504.
- Ioffe, S., and Forsyth, D., 2001, Probabilistic methods for finding people, *International Journal of Computer Vision*, 43, 1, 45–68.
- Lee H.K. and Kim, J.H., 1999, An HMM based threshold model approach for gesture recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21, 10, 961-973.
- Lee, J.J., Kim, J., and Kim, J.H., 2000, Data-driven design of hmm topology for on-line handwriting recognition, *International Journal of Pattern Recognition and Artificial Intelligence*, 15, 107-121.
- Liu, N., Lowell, B.C., Kootsookos, P.J., and Davis, R.I.A., 2004, Understanding HMM training for video gesture recognition, *TENCON 2004, 2004 IEEE Region 10 Conference*, 567-570.
- Micilotta, A.S., Ong, E.J., and Bowden, R., 2005, Detection and tracking of humans by probabilistic body part assembly, *British Machine Vision Conference*, 1, 429-438.
- Mori, G., Ren, X., Efros, A., and Malik, J., 2004, Recovering Human Body Configurations: Combining Segmentation and Recognition, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'04)*, 326-333.
- Müller, K.R., Mika, S., Rätsch, G., Tsuda, K., and Schölkopf B., 2001, An introduction to kernel-based learning algorithms, *IEEE Neural Networks*, 12, 2, 181-201.
- Navaratnam, R., Thayananthan, A., Torr, P.H.S., and Cipolla, R., 2005, Hierarchical part-based human body pose estimation, *British Machine Vision Conference*, 1, 479-488.
- Nefian, A.V. and Hayes, M.H., 1999, An embedded HMM-based approach for face detection and recognition, *IEEE International Conference on Acoustics, Speech, and Signal Processing*, 6, 3553-3556.

- Oren, M., Papageorgiou, C., Sinha, P., Osuna, E., and Poggio, T., 1997, Pedestrian detection using wavelet templates, *Computer Vision and Pattern Recognition*, 193-199.
- Platt, J., 2000, Probabilistic outputs for support vector machines and comparison to regularize likelihood methods, *Advances in Large Margin Classifiers*, 61-74.
- Rabiner, L.R. and Juang, B.H., 1993, *Fundamentals of speech recognition*, Prentice Hall, New Jersey, 507 p.
- Starner T. and Pentland, A., 1998, Real-time American language recognition, *IEEE Trans, On Pattern Analysis and Machine Intelligence* , 20, 1371-1375.
- Triggs, B., Ronfard, R., Schmid, C., 2002, Learning to parse pictures of people, In *Proc. of ECCV*, 4, 700-707.
- Zhao, L., and Thorpe, C., Stereo- and Neural Network-Based Pedestrian Detection, 1999, *Proceedings of the IEEE Intelligent Transportation Systems Conference* 1, 3, 148-154.