

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**MODEL TABANLI SINIFLANDIRMAYA VE KARMA ÖZNİTELİKLERE DAYALI
HİYERARŞİK YAŞ TAHMİNİ SİSTEMİNİN TASARIMI VE BAŞARIM
DEĞERLENDİRMESİ**

DOKTORA TEZİ

Bilgisayar Yük. Müh. Asuman GÜNAY

**HAZİRAN 2015
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :

Trabzon

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**Bilgisayar Mühendisliği Anabilim Dalında
Asuman GÜNAY Tarafından Hazırlanan**

**MODEL TABANLI SINIFLANDIRMAYA VE KARMA ÖZNİTELİKLERE DAYALI
HİYERARŞİK YAŞ TAHMİNİ SİSTEMİNİN TASARIMI VE BAŞARIM
DEĞERLENDİRMESİ**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 09 /06/2015 gün ve 1606 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

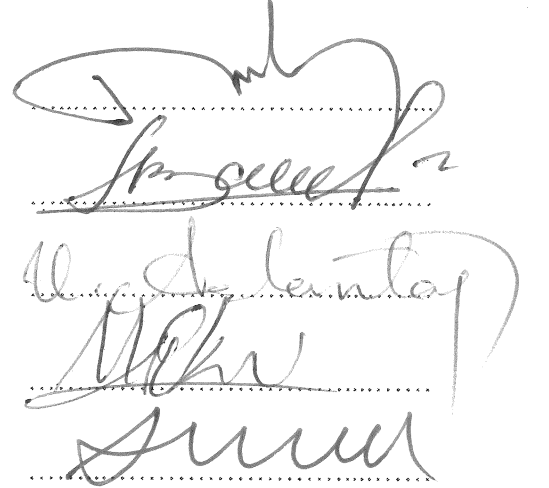
Başkan : Prof. Dr. Nevcihan DURU

Üye : Prof. Dr. Vasif V. NABIYEV

Üye : Prof. Dr. Veysel ASLANTAŞ

Üye : Prof. Dr. Murat EKİNCİ

Üye : Prof. Dr. Ali GANGAL



Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

Yüz görüntülerinden yaşın tahmini, adli tıp, güvenlik, çocukların korunması, suçluların ve kayıp çocukların tespiti, reklamcılık, pazarlama ve robot-insan etkileşimi gibi pek çok önemli uygulama alanına sahiptir. Kişinin yaşlanma sürecinin genetik özelliklerinden yaşam ve coğrafi koşullarına, yeme içme alışkanlıklarından duygusal ve stres durumuna kadar pek çok faktörden etkilenmesi ve bu nedenle kişiden kişiye büyük farklılık göstermesi, problemin çözümünü zorlaştırmaktadır. Öyle ki uzman kişiler bile yaş tahmini konusunda 10 yıla kadar hata yapabilmektedir. Yine de önemli uygulama alanları nedeniyle yaş grubunun ve kesin yaş etiketinin belirlenmesini sağlayan sistemlerin tasarımı büyük önem taşımaktadır. Bu tez çalışmasında, yeni yaklaşımlar ortaya konularak otomatik bir yaş tahmini sistemi tasarlanmıştır.

Çalışmalarında bilgilerini, desteğini ve tecrübelerini esirgemeyen değerli hocam, danışmanım Sayın Prof. Dr. Vasif V. NABİYEV'e sonsuz teşekkürlerimi bir borç bilirim. Doktora süresince fikirlerine başvurduğum jüri üyelerine ayrıca teşekkür ederim. Çalışma hayatımda beni destekleyen mesai arkadaşlarıma ve bölüm başkanım Sayın Öğr. Gör. Fatih ÜÇÜNCÜ'ye çok teşekkür ederim.

Tez çalışmam süresince manevi desteklerini esirgemeyen değerli arkadaşlarıma teşekkür ederim. Bu günlere gelmemde en büyük pay sahibi olan sevgili aileme, anlayış, sabır ve desteklerinden dolayı teşekkürlerimi sunarım.

Asuman GÜNAY

Trabzon 2015

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “Model Tabanlı Sınıflandırmaya ve Karma Özniteliklere Dayalı Hiyerarşik Yaş Tahmini Sisteminin Tasarımı ve Başarım Deđerlendirmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Vasif V. NABIYEV’in sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 26/06/2015

Asuman GÜNAY

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XIV
SEMBOLLER DİZİNİ.....	XVI
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Otomatik Yaş Tahmini Sistemleri	4
1.3. Öznitelik Çıkarma Yöntemleri.....	5
1.3.1. Geometrik Yapıya Dayalı Öznitelik Çıkarma.....	6
1.3.2. Aktif Görünüm Modelleri ile Öznitelik Çıkarma	7
1.3.3. Yaşlanma Örüntüsü Altuzayı ile Öznitelik Çıkarma	10
1.3.4. Topolojik Uzaya Gömmeye Dayalı Öznitelik Çıkarma.....	12
1.3.5. Dokuya Dayalı Öznitelik Çıkarma.....	14
1.3.6. Karma Öznitelik Çıkarma	16
1.4. Yaşın Tahmini.....	17
1.4.1. Yaş Gruplarına Sınıflandırma	18
1.4.2. Tek Aşamalı Yaş Tahmini	18
1.4.3. Hiyerarşik Sınıflayıcılar	19
1.5. Sistem Başarımını Değerlendirme Yöntemleri	19
1.5.1. Bir Kişiyi Dışarıda Bırak Yöntemi	20
1.5.2. n -katlı Çapraz Doğrulama Testi	20
1.5.3. Eğitim ve Test Kümelerinin Özne Kriterlerle Belirlenmesi	21
1.6. Performans Ölçütleri.....	21
1.6.1. Ortalama Mutlak Hata.....	21
1.6.2. Kümülatif Skor.....	22

1.6.3.	Sınıflandırma Doğruluğu	22
1.7.	Literatür Taraması.....	22
2.	YAPILAN ÇALIŞMALAR	54
2.1.	Giriş.....	54
2.2.	Yaş Gruplarının Belirlenmesi ve Yaş Tahmini Sistemi.....	55
2.3.	Görüntü Normalizasyonu	58
2.4.	Yaş Özniteliklerinin Çıkarılması	59
2.4.1.	Aktif Görünüm Modelleriyle Öznitelik Çıkarma.....	59
2.4.2.	Ayrık Kosinüs Dönüşümüyle Öznitelik Çıkarma	62
2.4.3.	Yerel İkili Örüntülerle Öznitelik Çıkarma	65
2.4.4.	Radon Dönüşümüyle Öznitelik Çıkarma	69
2.4.5.	Gabor Filtreleri ile Öznitelik Çıkarma	72
2.4.6.	Öznitelik Vektörlerinin Boyutunun Küçültülmesi	76
2.4.7.	Karma Özniteliklerin Çıkarılması	77
2.5.	Hiyerarşik Sınıflayıcı	79
2.5.1.	Yaş Gruplarına Sınıflandırma	79
2.5.1.1.	En Yakın Komşuluk Sınıflayıcısı ile Sınıflandırma	80
2.5.1.2.	Destek Vektör Makineleri ile Sınıflandırma.....	82
2.5.1.3.	Doğrusal Ayrıştırma Analizi ile Sınıflandırma.....	86
2.5.2.	Yaş Etiketinin Belirlenmesi	88
2.5.2.1.	Yaşlanma Fonksiyonu.....	89
2.6.	Model Tabanlı Yaş Tahmini Yaklaşımı.....	90
2.6.1.	Yaş Modelleri.....	92
2.6.1.1.	Görüntü Morfleme	92
2.6.1.2.	Yaş Modellerinin Üretilmesi.....	100
2.6.2.	Görüntü Önişleme	103
2.6.3.	Öznitelik Çıkarma.....	105
2.6.4.	Sınıflandırma.....	105
2.6.4.1.	Uzaklık Ölçütleri.....	106
2.6.4.2.	Borda Oylama Yöntemi ile Sınıflandırma Sonuçlarının Birleştirilmesi.....	106
3.	BULGULAR VE İRDELEME	109
3.1.	Giriş.....	109
3.2.	Veritabanları	109

3.2.1.	FG-NET Veritabanı.....	109
3.2.2.	MORPH Veritabanı.....	111
3.2.3.	PAL Veritabanı	111
3.3.	Öznitelik Çıkarma Yöntemleri ile Tek Aşamalı Yaş Tahmini Sonuçları	113
3.3.1.	AAM Öznitelikleriyle Yaş Tahmini Sonuçları	115
3.3.2.	DCT Öznitelikleriyle Yaş Tahmini Sonuçları	116
3.3.3.	Radon Öznitelikleriyle Yaş Tahmini Sonuçları	118
3.3.4.	LBP Öznitelikleriyle Yaş Tahmini Sonuçları	119
3.3.5.	Gabor Öznitelikleriyle Yaş Tahmini Sonuçları	120
3.3.6.	Öznitelik Çıkarma Yöntemlerinin Yaş Tahmini Başarımlarının Değerlendirilmesi.....	121
3.4.	Karma Özniteliklerle Tek Aşamalı Yaş Tahmini Sonuçları	124
3.5.	Hiyerarşik Sınıflayıcı ile Yaş Tahmini Sonuçları	131
3.5.1.	Yaş Gruplarına Sınıflandırma Sonuçları	131
3.5.2.	Yaş Grupları Altında Yaş Tahmini Sonuçları.....	137
3.6.	Yaş Modelleriyle Yaş Grubuna Sınıflandırma Sonuçları	141
3.7.	Oylamaya Dayalı Sınıflandırma Sonuçları	146
4.	SONUÇLAR	150
5.	ÖNERİLER.....	155
6.	KAYNAKLAR	157
7.	EKLER.....	169
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

MODEL TABANLI SINIFLANDIRMAYA VE KARMA ÖZNETELİKLERE DAYALI
HİYERARŞİK YAŞ TAHMİNİ SİSTEMİNİN TASARIMI
VE BAŞARIM DEĞERLENDİRMESİ

Asuman GÜNAY

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Vasif V. NABİYEV
2015, 168 Sayfa, 7 Ek Sayfa

Bu çalışmada, sınıflandırma ve yaş etiketinin belirlenmesi aşamalarından oluşan, yeni bir hiyerarşik yaş tahmini sistemi tasarlanmıştır. Sınıflandırma aşamasında kullanılan yaş gruplarını yöntemlerden ve veritabanlarından bağımsız olarak ortak bir ölçeğe getirmek ve böylece yapılan çalışmaların karşılaştırılmasını kolaylaştırmak amacıyla, gelişim psikoloğu Erik Erikson'un "insanın sosyal gelişim aşamaları" teorisi temel alınmıştır. Önerilen yaş grupları kullanılarak, mevcut yöntemlerle çıkarılan özneteliklerin, hem sınıflandırma hem de yaş etiketinin belirlenmesi aşamalarında karar seviyesinde birleştirilmesiyle, karma özneteliklere dayalı hiyerarşik bir yaş tahmini sistemi oluşturulmuştur. Bu sistem sayesinde, birbirinden çok farklı özelliklere sahip olan FG-NET, MORPH-I ve PAL veritabanlarında, sınıflandırma başarımı ve yaş tahmini aşamalarında, literatürle kıyaslandığında iyileşme sağlanmıştır. Çalışmada sınıflandırma aşamasında, literatürde ilk defa model tabanlı bir yaş tahmini yöntemi tasarlanmıştır. Bu amaçla, önerilen yaş gruplarının ortak özelliklerini temsil eden yaş modelleri morfleme yöntemi ile üretilmiş ve bu yaş modelleri üzerinden çeşitli uzaklık ölçütleri ile sınıflandırma gerçekleştirilmiştir. Daha sonra, uzaklık ölçütlerinin sonuçları oylamaya dayalı bir puanlama yöntemi ile birleştirilerek sınıflandırma doğruluğu artırılmıştır.

Anahtar Kelimeler: Yaş gruplarının belirlenmesi, Yaş tahmini, Karma öznetelikler, Hiyerarşik sınıflayıcı, Morfleme, Yaş modelleri, Oylamaya dayalı puanlama

PhD. Thesis

SUMMARY

DESIGN AND PERFORMANCE EVALUATION OF A HIERARCHICAL AGE
ESTIMATION SYSTEM USING MODEL BASED CLASSIFICATION
AND HYBRID FEATURES

Asuman GÜNAY

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Vasif V. NABIYEV
2015, 168 Pages, 7 Pages Appendix

In this study, a new hierarchical age estimation system consisting of age group classification and age estimation modules is designed. To fit a common basis for the age groups used in the classification phase regardless of the methods and databases, and thus to facilitate the comparison of the studies with each other, the boundaries of age groups are designated according to the developmental psychologist Erik Erikson's "stages of psychosocial development" theory. With the usage of these age groups and fusing the features that are extracted with existing feature extraction methods in decision level both in classification and age estimation phases, a hierarchical age estimation system based on hybrid features was established. The classification accuracy and the age estimation performance of this system outperforms the previous works when using the FG-NET, MORPH-I and PAL aging databases which have very different characteristics. In the study, a model-based age classification method is designed for the first time in the literature. For this purpose, age models representing the common characteristics of proposed age groups are produced using image morphing technique and classification is carried out with various distance metrics over these age models. Then classification accuracy is increased by combining the results of these metrics using a scoring method based on voting.

Key Words: Age group designation, Age estimation, Hybrid features, Hierarchical classifier, Morphing, Age models, Scoring based on voting

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Bir kişinin çeşitli yaşlardaki görüntüleri	2
Şekil 1.2. Önerilen yaş tahmini sisteminin genel şeması.....	3
Şekil 1.3. Yaş tahmini sistemlerinin genel yapısı	4
Şekil 1.4. Öznitelik çıkarma yöntemlerinin şematik gösterimi.....	5
Şekil 1.5. Kadın ve erkek yüz geometrisi	6
Şekil 1.6. AAM'in eğitiminde kullanılan örnek görüntüler, belirleyici noktalar, ortalama yüz şekli ve ortalama şekle eğritilen yüzler	8
Şekil 1.7. Yaşlanma örüntüsü vektörünün oluşturulması (Geng vd., 2006).....	11
Şekil 1.8. Tamamlanmış yaşlanma örüntüleri (Geng vd., 2006)	11
Şekil 1.9. Çeşitli algoritmaların topolojik uzay görünümüleri (Fu vd., 2007).....	13
Şekil 1.10. Çeşitli doku öznitelikleri çıkarma yöntemleri (a) Orijinal görüntü (b) Sobel filtreleri uygulanmış görüntüler (c) Canny kenar belirleme ile üretilen kenarlar (d) DCT öznitelikleri (e) LBP görüntüsü (f) LBP histogramı (g) 4 yön 3 ölçekli Gabor filtresi sonuçları.....	16
Şekil 1.11. Yaş tahmini yöntemlerinin şematik gösterimi	18
Şekil 2.1. Önerilen yaş grupları ile yaş tahmini sisteminin genel yapısı	57
Şekil 2.2. Görüntü normalizasyonu (a) Orijinal görüntüler (b) Normalize edilmiş görüntüler.....	58
Şekil 2.3. Orijinal görüntü ile parlaklık parametreleriyle yeniden üretilen görüntünün karşılaştırılması (a) Orijinal görüntü (b) PCA(%99) üretilen görüntü (c) b ve a'nın farkı (d) PCA(%98) ile üretilen görüntü (e) d ve a'nın farkı	61
Şekil 2.4. Yaş gruplarından örnek görüntüler ve DCT sonuçları (a) 4 yaş (b) 15 yaş (c) 34 yaş (d) 61 yaş (e) 87 yaş	64
Şekil 2.5. Bölgesel DCT öznitelik vektörlerinin üretilmesi.....	65
Şekil 2.6. LBP kodlarının üretilmesi	66
Şekil 2.7. (8, 1), (8, 2) ve (16, 2) LBP operatörleri.....	67
Şekil 2.8. 8x8 bölgeye ayrılmış yüz görüntüsü ve bölge ağırlıkları (siyah-0, gri-2, beyaz-4)	68

Şekil 2.9. LBP histogramının oluşturulması	69
Şekil 2.10. $f(x, y)$ görüntüsünün Radon dönüşümü	70
Şekil 2.11. Bir görüntünün Radon dönüşümünün üretilmesi algoritması.....	71
Şekil 2.12. Yaş gruplarından örnek görüntüler ve 0-180 derece için Radon dönüşümü sonuçları (a) 6 yaş (b) 18 yaş (c) 34 yaş (d) 54 yaş (e) 79 yaş.....	72
Şekil 2.13. Bir sinüs işaretinin Gauss fonksiyonu ile modülasyonu.....	73
Şekil 2.14. İki boyutlu Gabor filtresinin oluşturulması (a) 30° yönelimli bir sinüsoid (b) İki boyutlu Gaussian (c) İki boyutlu Gabor filtresi	73
Şekil 2.15. 4 ölçek ve 6 yön için üretilen 24 Gabor filtresi	75
Şekil 2.16. Gabor filtreleme işlemi	75
Şekil 2.17. Standart en yakın komşuluk sınıflayıcısı	80
Şekil 2.18. k NN sınıflayıcısı (a) $k=3$ (b) $k=5$	81
Şekil 2.19. Optimal SVM hiperdüzlemi	82
Şekil 2.20. SVM'de çekirdek hilesi (a) Lineer ayrıştırılmayan veriler (b) Çekirdek hilesi sonucu lineer ayrıştırılabilen veriler	84
Şekil 2.21. Farklı sınıflar için Gauss dağılımları	87
Şekil 2.22. Önerilen model tabanlı yaş grubuna sınıflandırma yönteminin genel yapısı.....	91
Şekil 2.23. Morfleme işlemi (a)Kaynak görüntü (d-f) Morfleme sürecinde üretilen ara görüntüler (g) Hedef görüntü.....	93
Şekil 2.24. Morfleme işleminde kullanılan (a) kontrol noktaları ve (b) bölgeler.....	94
Şekil 2.25. Bilineer interpolasyonda kullanılan noktalar.....	96
Şekil 2.26. Kaynak ve hedef görüntüler için tanımlanmış doğrular	97
Şekil 2.27. Bir doğru ile alan morfleme.....	98
Şekil 2.28. Bir doğru çifti ($PQ, P'Q'$) için alan morfleme algoritması.....	98
Şekil 2.29. İki doğru ile alan morfleme	99
Şekil 2.30. Birden fazla doğru çifti ($P_iQ_i, P'_iQ'_i$) için alan morfleme algoritması	100
Şekil 2.31. Morfleme yöntemiyle üretilen ortalama yüzler (a) Birinci kaynak resim (b) Geometrik tabanlı morfleme ile üretilen ortalama yüz (c) Alan morfleme ile üretilen ortalama yüz (d) İkinci kaynak resim	100
Şekil 2.32. Yaş modellerinin üretilmesi.....	102

Şekil 2.33. FG-NET ve PAL veritabanları için üretilen yaş modelleri (YG: Yaş Grubu).....	102
Şekil 2.34. Ön işleme aşamaları (a) Orijinal görüntü ve 68 kontrol noktası (b) Orijinal görüntüde Delaunay üçgenlemesi ise oluşturulan bölgeler (c) $\alpha = 0.5$ alınarak üretilen ara kontrol noktaları ve bölgeler (ortalama şekil) (d) Sağa yansıtılmış görüntüde Delaunay üçgenlemesi ise oluşturulan bölgeler (e) Sağa yansıtılmış görüntü ve 68 kontrol noktası (f) Orijinal görüntünün ortak şekle eğriltilmesi sonucu (g) Morfleme sonrası üretilen düz bakan yüz görüntüsü (h) Sağa yansıtılmış görüntünün ortak şekle eğriltilmesi sonucu.....	103
Şekil 2.35. Görüntü ön işleme (a) Orijinal görüntüler (b) Düz bakan yüz görüntüleri.....	104
Şekil 2.36. Borda sayısı ile puan hesaplama örneği.....	107
Şekil 3.1. FG-NET veritabanındaki görüntülerin yaş etiketlerine göre dağılımı.....	110
Şekil 3.2. MORPH-I veritabanındaki görüntülerin yaş etiketlerine göre dağılımı.....	111
Şekil 3.3. PAL veritabanındaki görüntülerin yaş etiketlerine göre dağılımı	112
Şekil 3.4. Veritabanlarından örnek görüntüler (a) FGNET (b) MORPH-I (c) PAL veritabanı	114
Şekil 3.5. DCT katsayı sayısının değişimine bağlı yaş tahmini başarımları.....	116
Şekil 3.6. Radon dönüşümündeki açının artım miktarına bağlı yaş tahmini başarımları.....	118
Şekil 3.7. LBP dönüşümündeki bölge sayısına bağlı yaş tahmini başarımları	120
Şekil 3.8. Öznitelik çıkarma yöntemlerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini başarımları.....	122
Şekil 3.9. Öznitelik çıkarma yöntemleri için CS grafikleri (a) FG-NET veritabanı (b) MORPH-I veritabanı (c) PAL veritabanı.....	122
Şekil 3.10. Karma özniteliklerin FG-NET ve PAL veritabanlarındaki yaş tahmini başarımları	126
Şekil 3.11. Karma özniteliklerin MORPH-I veritabanındaki yaş tahmini başarımları	127
Şekil 3.12. Karma öznitelikler için CS grafikleri (a) FG-NET veritabanı (b) PAL veritabanı (c) MORPH-I veritabanı	128
Şekil 3.13. Sınıflandırma yöntemlerinin AAM, LBP ve Gabor öznitelikleriyle sınıflandırma başarımları (a) FG-NET (b) MORPH-I (c) PAL veritabanı	132
Şekil 3.14. Hiyerarşik yaş tahmini sisteminin FG-NET, MORPH-I ve PAL veritabanları için CS grafikleri	139

Şekil 3.15. Yaş modellerine göre sınıflandırma başarımları (a) FG-NET veritabanı erkek örnekler (b) FG-NET veritabanı kadın örnekler (c) PAL veritabanı erkek örnekler (d) PAL veritabanı kadın örnekler.....	142
Şekil 3.16. FG-NET ve PAL veritabanlarında cinsiyete göre sınıflandırma başarımları.....	144
Şekil 3.17. Uzaklık ölçütlerinin yaş gruplarındaki sınıflandırma başarımları (a) FG-NET veritabanı erkek örnekler (b) FG-NET veritabanı kadın örnekler (c) PAL veritabanı erkek örnekler (d) PAL veritabanı kadın örnekler.....	145
Şekil 3.18. Uzaklık ölçütlerinin sınıflandırma başarımları (a) FG-NET veritabanı (b) PAL veritabanı	147
Şekil 3.19. Oylamaya dayalı sınıflandırma sonuçları (a) FG-NET veritabanı (b) PAL veritabanı	148
Ek Şekil 1. İnsan bedeni kanonu	170

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. Öznitelik çıkarma yöntemlerinin güçlü ve zayıf yönleri.....	17
Tablo 1.2. Yaş tahmini yöntemlerinin güçlü ve zayıf yönleri.....	20
Tablo 2.1. Yaş grubuna sınıflandırma çalışmalarında kullanılan yaş grupları	56
Tablo 2.2. SVM çekirdek fonksiyonları.....	85
Tablo 3.1. FG-NET veritabanının genel özellikleri.....	110
Tablo 3.2. MORPH-I veritabanının genel özellikleri	112
Tablo 3.3. PAL veritabanının genel özellikleri	113
Tablo 3.4. AAM özniteliklerinin FG-NET ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)	115
Tablo 3.5. Veri sıkıştırma mantığına dayalı DCT özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE).....	117
Tablo 3.6. Filtrelemeye dayalı DCT özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)	117
Tablo 3.7. Radon özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE).....	119
Tablo 3.8. LBP özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)	120
Tablo 3.9. Gabor özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE).....	121
Tablo 3.10. Öznitelik seviyesinde birleştirmeye dayalı karma özniteliklerin FG-NET ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE).....	124
Tablo 3.11. Karar seviyesinde birleştirmeye dayalı karma özniteliklerin FG-NET ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE).....	125
Tablo 3.12. Öznitelik ve karar seviyesinde birleştirilen AAM+LBP+Gabor ve LBP+Gabor özniteliklerinin FG-NET, PAL ve MORPH-I veritabanlarındaki yaş tahmini başarımları (MAE).....	126
Tablo 3.13. FG-NET veritabanı için tek aşamalı yaş tahmini sonuçlarının literatürle kıyaslaması	130
Tablo 3.14. MORPH-I veritabanı için tek aşamalı yaş tahmini sonuçlarının literatürle kıyaslaması	130

Tablo 3.15. PAL veritabanı için tek aşamalı yaş tahmini sonuçlarının literatürle kıyaslaması.....	130
Tablo 3.16. AAM+LBP+Gabor öznitelikleri ile FG-NET, MORPH-I ve PAL veritabanlarındaki sınıflandırma başarımları	133
Tablo 3.17. Sınıflandırma sonuçlarının literatürle kıyaslaması.....	135
Tablo 3.18. FG-NET, MORPH-I ve PAL veritabanlarında yaş gruplarına göre CA (%) değişimi.....	136
Tablo 3.19. FG-NET, MORPH-I ve PAL veritabanlarında AAM, LBP ve Gabor özniteliklerinin yaş tahmini başarımları (MAE)	137
Tablo 3.20. Karma özniteliklerin yaş grupları altındaki yaş tahmini başarımları (MAE).	137
Tablo 3.21. Hiyerarşik yaş tahmini sisteminin FG-NET, MORPH-I ve PAL veritabanları için yaş tahmini başarımları	138
Tablo 3.22. FG-NET veritabanı için hiyerarşik yaş tahmini sonuçlarının literatürle kıyaslaması	140
Tablo 3.23. MORPH-I veritabanı için hiyerarşik yaş tahmini sonuçlarının literatürle kıyaslaması	140
Tablo 3.24. PAL veritabanı için hiyerarşik yaş tahmini sonuçlarının literatürle kıyaslaması.....	140
Tablo 3.25. Model tabanlı yaş tahmini yönteminin sınıflandırma başarımları.....	148
Ek Tablo 1. Dişlerin yaşa göre sürtünme dereceleri (0-bozulma yok, 1-mine dış tabakasında bozulma var, 2-mine iç tabakasında bozulma var, 3- dentin kısmında bozulma var, 4-diş kanalı tahrip olmuş, 5-diş tacı bozulmuş, 6-diş tacı tümüyle tahrip olmuş)	169
Ek Tablo 2. FG-NET veritabanında yaş grupları için AAM, LBP ve Gabor özniteliklerinin yaş tahmini başarımları (MAE)	174
Ek Tablo 3. MORPH-I veritabanında yaş grupları için LBP ve Gabor özniteliklerinin yaş tahmini başarımları (MAE)	174
Ek Tablo 4. PAL veritabanında yaş grupları için AAM, LBP ve Gabor özniteliklerinin yaş tahmini başarımları (MAE)	174
Ek Tablo 5. Farklı boyutlardaki LBP ve Gabor özniteliklerinin, FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini başarımları (MAE)	175

SEMBOLLER DİZİNİ

2DLDA	: İki boyutlu LDA (2-Dimensional LDA)
AAM	: Aktif görünüm modelleri (Active Appearance Models)
AAS	: Görünüme ve yaşa özel sınıflayıcı (Appearance and Age Specific Classifier)
AGES	: Yaşlanma örüntüsü alt uzayı (Aging Pattern Subspace)
BIF	: Biyolojiden esinlenilmiş öznitelikler (Biologically Inspired Features)
CS	: Kümülatif skor (Cumulative Score)
CA	: Sınıflandırma doğruluğu (Classification Accuracy)
DCT	: Ayrık kosinüs dönüşümü (Discrete Cosine Transform)
ECOC	: Hata doğrulama çıktı kodları (error-correcting output code)
k NN	: k -en yakın komşuluk (k-Nearest Neighbour)
LARR	: Yerel olarak ayarlanabilen dayanıklı regresyon (Locally Adjusted Robust Regressor)
LBP	: Yerel ikili örüntüler (Local Binary Patterns)
LDA	: Doğrusal ayrıştırma analizi (Linear Discriminant Analysis)
LOPO	: Bir kişiyi dışarıda bırak (Leave One Person Out)
LPP	: Yerelliğin korunması izdüşümü (Locality Preserving Projection)
MAE	: Ortalama mutlak hata (Mean Absolute Error)
MFA	: Marjinal Fisher analizi (Marginal Fisher Analysis)
MLR	: Çoklu doğrusal regresyon (Multiple Linear Regression)
NN	: Yapay sinir ağları (Neural Networks)
NPP	: Komşuluğun korunması izdüşümü (Neighborhood Preserving Projection)
OLPP	: Ortogonal yerelliğin korunması izdüşümü (Orthogonal Locality Preserving Projection)
PCA	: Temel bileşenler analizi (Principal Component Analysis)
PFA	: Olasılıksal birleştirme yaklaşımı (Probabilistic Fusion Approach)
RMIR	: Güçlü çok durumlu regresyon (Robust Multi Instance Regressor)

- RUN : Kesin olmayan pozitif etiketlerden regresyon (Regression from Uncertain Nonnegative Labels)
- SFP : Uzaysal esnek parçaları (Spatially Flexible Patches)
- SVM : Destek vektör makineleri (Support Vector Machines)
- SVR : Destek vektör makineleri ile regresyon (Support Vector Regression)
- WAS : Ağırlıklı görünüme özel (Weighted Appearance Specific)

1. GENEL BİLGİLER

1.1. Giriş

Otomatik tanıma sistemlerine ihtiyacın artması ile birlikte, yüz görüntülerinin işlenmesi üzerine yapılan araştırmalar, son on yıllarda önemli ölçüde ilgi çekmeye başlamıştır. Yüz belirleme (Hjelmas ve Low, 2001), yüz tanıma (Turk ve Pentland, 1991), cinsiyet sınıflandırma (Makinen ve Raisamo 2008) ve yüz ifadelerinin tanınması (Shan vd., 2009) bu alanda pek çok araştırmacı tarafından araştırılan konu başlıklarıdır. Yüz görüntülerinden yaşın tahmini ise, diğerleriyle karşılaştırıldığında, bu alanda daha yeni bir araştırma konusudur ve 2000'li yıllardan sonra bu konuda ciddi araştırmalara başlanmıştır. Gerçek hayatta kullanılabilir çok sayıda uygulama alanına sahip olması, bu konuya olan ilgiyi arttırmaktadır. Örneğin yaş hedefli reklamcılık, elektronik ortamda tüketici ilişkilerinin yönetilmesi, güvenlik sistemlerinin tasarımı önemli uygulama alanlarıdır.

Yaşın tahmini adli tıp ve kriminolojide de büyük önem taşımaktadır. Adli tıpta kimlik tespiti aşamasında cinsiyet ve tahmini yaş, belirlenecek ilk özelliklerdir. Diğer yandan bu konu kapsamına giren, emekli olma ve askere alınma yaşlarının belirlenmesi, kimlik ya da pasaportların kişiye ait olup olmadığının tespiti, kaybolmuş kişilerin zamana bağlı olarak görüntülerinin tespiti vb. önem taşımaktadır. Yaşın doğru bir şekilde belirlenmesinin yanında kişinin geçmiş ve gelecekteki görüntülerinin yaklaşık olarak üretilmesi, özellikle kayıp çocukların ya da suçluların günümüzdeki görüntülerinin oluşturulması konusu dikkat çekicidir. Bu çalışmalar mevcut bir veritabanındaki resimlerin güncelleştirilmesi amacıyla da kullanılabilir. Böylece veritabanındaki resimler her zaman kişilerin güncel görüntülerini içerecektir. Bu çalışmaların yararlı olabileceği diğer bir alan yüz tanıma sistemleridir. Yüz tanıma sistemleri çok sayıdaki eğitim görüntüleri kullanılarak eğitilirler. Bu tür uygulamalarda, tanınacak kişi görüntüsündeki yaş etkilerinin ortadan kaldırılarak sisteme sunulması, sistem performansının zamana bağlı olarak kötüleşmesini engelleyecektir (Lanitis vd., 2002).

Yaşın belirlenmesinde genellikle antroposkopik (anthroposcopy) ve antropometrik (anthropometry) göstergelerden faydalanılmaktadır. Antroposkopik özelliklere örnek olarak, deri örtüsünün durumu, dişlerin değişimi ve sürtünme dereceleri verilebilir. Antropometrik özellikler ise genellikle kişinin boyu, ağırlığı, göğüs kafesinin çevre

uzunluğu gibi ölçümleri içermektedir. Bunlar dışında iskeleti oluşturan kemiklerin gelişimi, göğüs kafesinin ve kafatasının radyografik yapısı da yaşın belirlenmesinde etkin özellikler olarak kullanılmaktadır. Kişinin gelişiminde yaşa bağlı olarak çeşitli organları büyümektedir. Boy, göğüs kafesi, baldır dairesi, başın çevresi ve çeşitli kemiklerin boyutlarının ölçülmesi yaşın belirlenmesinde yardımcı olmaktadır. Büyüme ile birlikte yüz ölçülerinde de değişiklikler meydana gelmektedir. Dişlerin durumunun araştırılması ise özellikle bebeklik ve çocukluk dilimlerinin belirlenmesinde yardımcı olmaktadır. Dişlerin durumuna göre yaşın değişimi ile ilgili bilgiler Ek-1’de verilmiştir. Yaşın belirlenmesinde deri örtüsünün yapısından da faydalanılmaktadır. Yaş ilerledikçe deri elastikliğini kaybetmekte, derinin kuruması, önceki renginin değişmesi gibi değişiklikler görülmektedir. Yaklaşık 20’li yaşlarda alında, burun-dudak kısmında, 25 yaşında gözlerin dış açılarında, 30 yaşlarında gözlerin alt kısmında, 35 yaşında boyunda, 55 yaşında kulaklarda, yanaklarda ve dudaklarda kırışıklıklar oluşmaya başlar. Yaş ilerledikçe kırışıklıklar büyür ve derinleşir. Şekil 1.1’de bir kişinin çeşitli yaşlardaki görüntüleri görülmektedir.

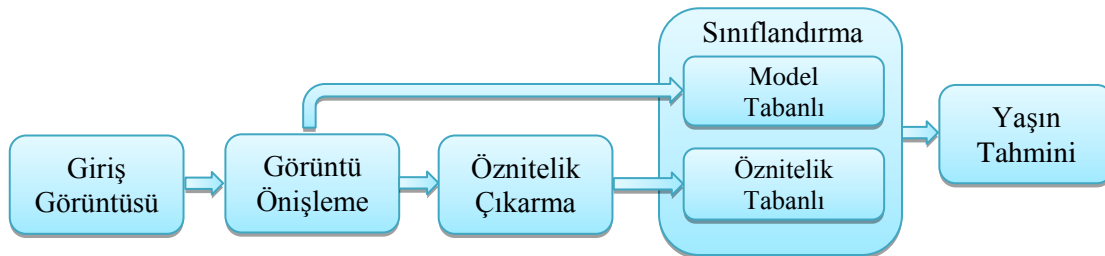


Şekil 1.1. Bir kişinin çeşitli yaşlardaki görüntüleri

Yüz görüntülerinden yaş tahmini yapmaya çalışan sistemler, temassız olarak sadece kişinin yüz görüntüsünü kullanarak yaşı tahmin etmeye çalışmaktadır. Yaşın tahmini, bir yüz görüntüsünün otomatik olarak bir yaş grubu ya da bir yaş etiketi ile ilişkilendirilmesi anlamına gelir. Her yaş etiketi ayrı bir sınıf olarak ele alındığında problem, çok-sınıflı bir sınıflandırma problemi olarak değerlendirilebilir. Yaş tahmini başarımını arttırmak için uygun yüz gösterimi yöntemlerine ihtiyaç duyulmaktadır. Aksi halde tanıma yapılacak uzayın yetersizliğinden dolayı, en güçlü sınıflayıcılar bile başarısız olabilir. Bu nedenle yaş tahmini sistemlerinin tasarımında yaşla ilişkili özniteliklerin iyi bir şekilde seçilmesi gerekmektedir. Fakat yüz görüntülerinin karakteristiği problemin çözümünü zorlaştırmaktadır. Görüntülerdeki aydınlatma, arka plan, poz, yüz ifadesi gibi etkenler tüm

yüz görüntüsü işleme sistemlerinin ortak problemleridir. Bunların yanında yüz üzerindeki gerçek yaşlanma etkileri kişiden kişiye farklıdır. Diğer bir ifade ile farklı kişilerin yaşlanmaları süresince yüzlerinde oluşan değişimler aynı değildir. Kişinin yaşlanma süreci, genetik özelliklerine, ırkına, yaşam koşullarına, yeme içme alışkanlıklarına, yaşadığı bölgenin iklimine göre farklılıklar göstermektedir (Albert vd., 2007). Güneşe maruz kalma, sigara içme alışkanlığı, aşırı kilo kaybı, duygusal stres, yüz ifadelerinin derecesi ve sıklığı, yaşlanma karşıtı ürün kullanımı, plastik cerrahi gibi etkenler de kişinin görünümünü değiştirmektedir (Gonzalez-Ulloa ve Flores, 1965). Bu nedenle yüz görüntülerinde doğrudan yaşı temsil eden öznitelik türlerinin belirlenmesi çok zordur. Bu ise yaş tahmini sistemlerinin performansını etkilemektedir. Öyle ki, gerçek yaş ile görünen yaş arasındaki farklılıklardan dolayı, yaşın belirlenmesinde tecrübeli uzmanların bile 10 yıla kadar hata yaptıkları bilinmektedir (Valinskiy, 1999). Yaş tahmini sistemlerinin oluşturulmasında zorluk oluşturan diğer bir etken ise iyi bir yaşlanma veritabanının olmayışıdır. Yaşlanma yavaş gerçekleşen bir süreç olduğundan, kişilerin kronolojik olarak, bebekliğinden yaşlılığına kadar farklı yaşlardaki görüntülerini içeren geniş bir veritabanının oluşturulması çok zordur. Yukarıda söz edilen tüm zorluklara ve kısıtlamalara rağmen, yaş tahmini konusuna olan ilgi, kritik ve önemli uygulama alanlarından dolayı artmaktadır.

Bu tez çalışmasında, yaş grupları Erik Erikson'un "insanın sosyal gelişim aşamaları" teorisine göre düzenlenmiş, bu yaş grupları üzerinden mevcut öznitelik çıkarma ve sınıflandırma yöntemleriyle, karma özniteliklere dayalı hiyerarşik bir sistem tasarlanarak yaş tahmini gerçekleştirilmiş ve ilk kez morflemeye dayalı model-tabanlı bir yaş tahmini yaklaşımı ortaya koyulmuştur.



Şekil 1.2. Önerilen yaş tahmini sisteminin genel şeması

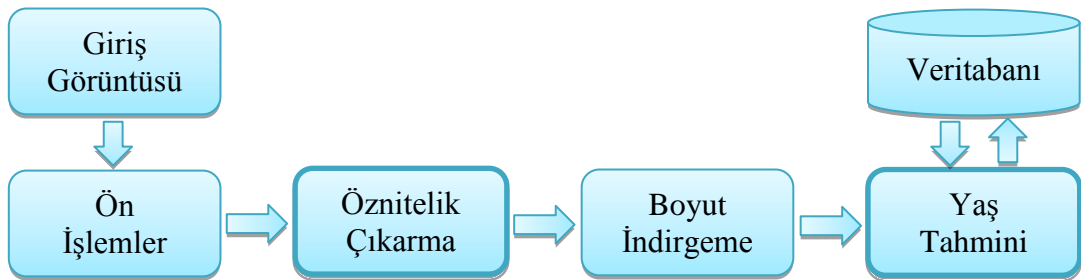
Önerilen yaş tahmini sisteminin genel şeması Şekil 1.2'de görülmektedir. Sistemin önileme aşamasında, öznitelik tabanlı sınıflandırma için görüntüler göz konumlarına göre

döndürölüp ölçeklenmekte, model tabanlı sınıflandırma için ise orijinal görüntüler sağa yansıtılmış görüntülerle birleştirilerek bakış açısı ve kafa pozunu düzeltilmektedir. Öznitelik tabanlı sınıflandırmada, çeşitli yöntemlerle çıkarılan öznitelikler, ayrı sınıflayıcıların eğitiminde kullanılmakta ve sınıflayıcıların sonuçlarının birleştirilmesi ile yaş grubu belirlenmektedir. Sınıflandırma aşamasında önerilen model tabanlı yaklaşım ise giriş görüntüsünün, morflemeye dayalı olarak üretilen yaş modelleri üzerinden sınıflandırılmasını sağlamaktadır. Yaş grubu belirlenen görüntünün yaş etiketi, yaşlanma fonksiyonları ile tahmin edilmektedir. Bu amaçla, çeşitli yöntemlerle çıkarılan öznitelikler yaşlanma fonksiyonlarının öğrenilmesinde kullanılmaktadır. Öğrenilen yaşlanma fonksiyonlarının sonuçlarının birleştirilmesi ile kişinin yaş etiketi belirlenmektedir.

Sonraki bölümlerde yaş tahmini sistemlerinin genel yapısı açıklanmakta ve literatürde yapılan çalışmalar incelenmektedir.

1.2. Otomatik Yaş Tahmini Sistemleri

Yüz görüntülerini otomatik olarak bir yaş grubu ya da bir yaş etiketi ile ilişkilendirmeye çalışan yaş tahmini sistemlerinin genel yapısı Şekil 1.3'te görülmektedir. Giriş görüntüleri ön işleme aşamasından geçtikten sonra, yaşla ilişkili öznitelikler çıkarılmakta ve çıkarılan öznitelik sayısını azaltmak için boyut indirgeme uygulanmaktadır. Son olarak yaş tahmini modülünde ise veritabanı ile kıyaslamalı olarak yaş belirlenmektedir.



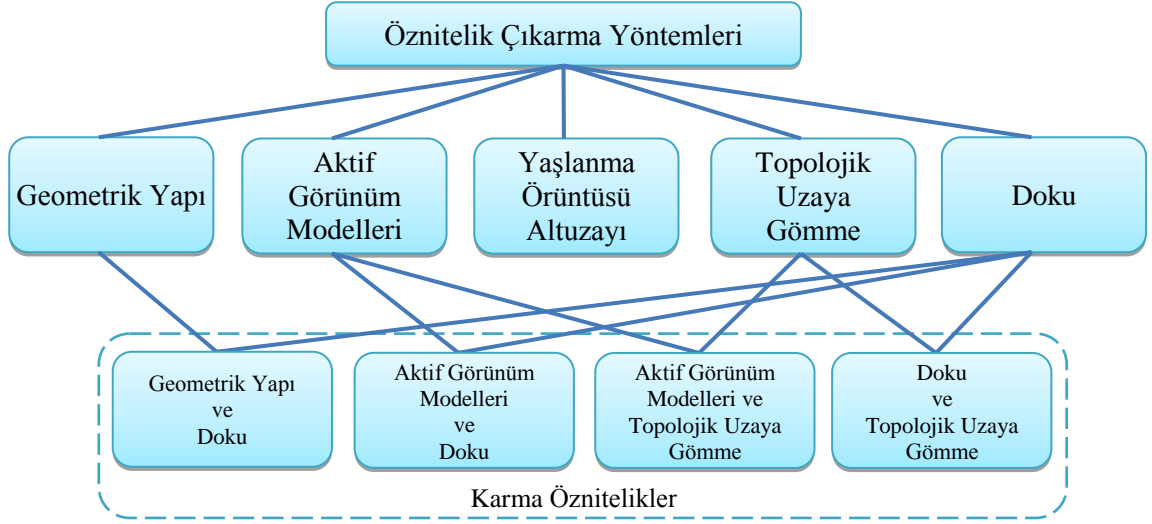
Şekil 1.3. Yaş tahmini sistemlerinin genel yapısı

Giriş görüntülerinin ön işleme aşaması tüm sistemlerde benzerlik göstermektedir. Boyut indirgeme aşaması ise bazı yöntemlerde uygulanmaktadır. Daha önce de söz edildiği

gibi, yaşın tahmini sistemlerindeki en önemli aşamalar, öznitelik çıkarma ve yaşın tahminidir. Konunun daha iyi anlaşılabilmesi için bu aşamalar ilerleyen bölümlerde daha detaylı olarak açıklanmaktadır.

1.3. Öznitelik Çıkarma Yöntemleri

Yüz görüntülerinden yaşlanma ile ilgili özniteliklerin çıkarılması, yaş tahmini sistemlerinin başarımında büyük önem taşımaktadır. Öznitelik çıkarma yöntemleri, yüz görüntülerinden, şekil tabanlı ve genel (global) ve yerel (local) doku tabanlı özniteliklerin çıkarılmasını sağlamaktadır.




Şekil 1.4. Öznitelik çıkarma yöntemlerinin şematik gösterimi

Şekil 1.4'te şematik olarak gösterilen bu yöntemler, geometrik yapıya dayalı yöntemler, aktif görünüm modelleri (Active Appearance Models - AAM), yaşlanma örüntüsü alt uzayı (Aging Pattern Subspace - AGES), topolojik uzaya gömme, yüz dokusunun çıkarılması ve karma yöntemler olarak sınıflandırılabilir. Bu yöntemlerle ilgili detaylı bilgiler, alt başlıklar içerisinde verilmektedir.

1.3.1. Geometrik Yapıya Dayalı Öznitelik Çıkarma

Geometrik yapıya dayalı olarak öznitelik çıkarma yöntemleri, insan yüzündeki belirleyici (landmark) noktalar arasındaki mesafeleri ve bu mesafelerin birbirlerine oranlarını hesaplamaktadır. Genel olarak insan vücudunun veya bir bölümünün ölçülerini ve orantılarını inceleyen bilim dalı antropometri olarak adlandırılır. Bu bilim dalının bir alt dalı olan yüz antropometrisi ise insan yüzündeki boyut ve orantıların ölçülmesi anlamına gelmektedir. Antropometri ile ilgili detaylı bilgi Ek-2’de verilmiştir.

Yetişkin bir insan yüzünde genel olarak doğruluğu kabul edilmiş belirli oranlar vardır (Parramon, 2000). Yetişkin kadın ve erkek yüz oranları Şekil 1.5’te görülmektedir. Bir gözün genişliği 1 birim olarak alınırsa iki göz arasındaki mesafe 1 birim, gözler ile şakak arasındaki mesafe ise $3/2$ birimdir. Göz yaşı kanallarından burun deliklerine kadar olan mesafe kadınlarda 1.3 birim, erkeklerde 1.5 birimdir. Fakat burun yapısı kişiden kişiye çok farklılıklar göstermektedir. Burun ile dudaklar arasındaki mesafe kadınlarda ve erkeklerde eşit olup 0.75 birimdir. Erkek dudağı kadın dudağından daha geniş, fakat daha incedir. Dudak genişliği ise 1.5, 2 birim arasında değişmektedir. Dudak ortasından çene altına kadar olan mesafe kadınlarda 1.3 erkeklerde 1.5 birim olup genelde burun ile aynı boydadır. Bu oranlar yetişkin insan yüzleri için geçerli olup, kişinin büyüme sürecinde farklılıklar göstermektedir.



Şekil 1.5. Kadın ve erkek yüz geometrisi

Farkas (1994), yüz antropometrisi için yaptığı kapsamlı incelemede, yüz antropometrisini, insan yüzünde bulunan 57 belirleyici noktadan alınan ölçümlerle tanımlamıştır. Bu ölçümler bebeklikten yetişkinliğe kadar farklı yaştaki çok sayıda insan

yüzünden elde edilmiştir. Çocuklar ve yetişkinler arasındaki bu oran farklılıkları yaş tahmini sistemlerinde kullanılmaktadır.

Geometrik özniteliklere dayalı yaş tahmini yaklaşımları sadece yüzün geometrik yapısını dikkate aldığından yalnız küçük yaşlardaki kişiler için iyi sonuç verebilir. Çünkü yetişkin bir insanın kafası ve yüz oranları yetişkinlik süresince çok fazla değişmemektedir. Yetişkin kişileri sınıflandırabilmek için yüzün doku bilgisine ihtiyaç duyulmaktadır.

1.3.2. Aktif Görünüm Modelleri ile Öznitelik Çıkarma


AAM, Cootes vd. (2001) tarafından önerilen, yüz görüntülerinin kodlanmasında kullanılan istatistiksel bir yüz modelidir. Yaş tahmini sistemlerinde AAM kullanılarak çıkarılan öznitelikler, yüz görüntülerinin hem şekil hem de parlaklık bilgisini içermektedir. Bu yöntemde, belirleyici noktalarla etiketlenmiş yüz görüntülerinden oluşan bir eğitim kümesinden, istatistiksel şekil ve parlaklık modelleri temel bileşenler analizine (Principal Component Analysis - PCA) dayalı olarak ayrı ayrı üretilmektedir.

Yüz görüntülerindeki şekil çeşitliliğini ifade eden istatistiksel şekil modelinin oluşturulması için, yüzün şekil bilgisini ifade eden belirleyici noktaların koordinatları kullanılmaktadır. Şekil 1.6'da örnek eğitim görüntüleri ve görüntülerin şekil bilgisini ifade eden belirleyici noktalar görülmektedir.

Bir eğitim örneği üzerindeki m adet noktanın koordinatlarının $2m \times 1$ boyutlu $\mathbf{x} = [x_1 \ y_1 \ \dots \ x_m \ y_m]^T$ vektöründe tutulduğu varsayılırsa, eğitim kümesindeki n örnek için şekil bilgisi, $2m \times n$ boyutlu $\mathbf{X} = [\mathbf{x}_i; \mathbf{x}_i \in R^D]_{i=1}^n$ matrisi ile temsil edilebilir. Eğitim kümesi için ortalama yüz şekil bilgisi ise aşağıdaki gibi tüm koordinatların ortalaması alınarak elde edilir.

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (1.1)$$

Daha sonra şekil verisine PCA uygulanarak, şekil bilgisinin dağılımını en iyi şekilde ifade eden temel bileşenler bulunmaktadır. Şekil bilgisini içeren \mathbf{X} matrisinin temel bileşenleri, denklem 1.2'de verilen $2m \times 2m$ boyutlu kovaryans matrisinin öz vektörleridir. \mathbf{S} 'nin en büyük d_s adet öz değerine karşılık gelen öz vektörlerin birleşiminden oluşan \mathbf{P}_s ,



Şekil 1.6. AAM'in eğitiminde kullanılan örnek görüntüler, belirleyici noktalar, ortalama yüz şekli ve ortalama şekle eğritilen yüzler

denklem 1.3'te verilen maksimizasyon probleminin çözümü ile elde edilir. Böylece $2m$ boyutlu veri uzayından, $d_s \leq 2m$ boyutlu parametre uzayına, doğrusal bir iz düşüm gerçekleştirecek $2m \times d_s$ boyutlu bir dönüşüm matrisi (\mathbf{P}_s) elde edilmiş olur. Herhangi bir görüntüye ait $d_s \times 1$ boyutlu şekil modeli parametreleri (\mathbf{b}_s) ise denklem 1.4 ile üretilir. Eğitim kümesindeki herhangi bir örneğe ait belirleyici nokta koordinatlarının yaklaşık olarak üretilmesi ise denklem 1.5 ile gerçekleştirilir.

$$\mathbf{S} = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (1.2)$$

$$\arg \max_{\mathbf{P}_s} |\mathbf{P}_s^T \mathbf{S} \mathbf{P}_s| \quad (1.3)$$

$$\mathbf{b}_s = \mathbf{P}_s^T \mathbf{x} \quad (1.4)$$

$$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{P}_s \mathbf{b}_s \quad (1.5)$$

Parlaklık modeli oluşturulmasında öncelikle tüm eğitim örnekleri, Şekil 1.6'da görüldüğü gibi eğitim kümesinden elde edilen ortalama yüz şekline eğritilerek (warping)

yüz görüntülerindeki şekil değişiklikleri elimine edilmektedir. Ortak şekle eğriltelen bir eğitim örneğinde yüz bölgesindeki k adet gri seviye değerlerinin $\mathbf{g} = [g_1 \dots g_k]^T$ vektöründe tutulduğu varsayılırsa, eğitim kümesindeki n örnek için parlaklık bilgisi, $k \times n$ boyutlu $\mathbf{G} = [\mathbf{g}_i; \mathbf{g}_i \in R^D]_{i=1}^n$ matrisi ile temsil edilebilir. Şekil modelinin oluşturulmasına benzer şekilde, öncelikle ortalama parlaklık bilgisi,

$$\bar{\mathbf{g}} = \frac{1}{n} \sum_{i=1}^n \mathbf{g}_i \quad (1.6)$$

ile elde edilir. Daha sonra denklem 1.7'de verilen $k \times k$ boyutlu \mathbf{S} kovaryans matrisinin öz değerleri ve öz vektörleri denklem 1.8'in çözülmesi ile belirlenir.

$$\mathbf{S} = \sum_{i=1}^n (\mathbf{g}_i - \bar{\mathbf{g}})(\mathbf{g}_i - \bar{\mathbf{g}})^T \quad (1.7)$$

$$\arg \max_{\mathbf{P}_g} |\mathbf{P}_g^T \mathbf{S} \mathbf{P}_g| \quad (1.8)$$

Belirlenen öz vektörlerden en büyük $d_g \leq k$ öz değere sahip olanlar birleştirilerek $k \times d_g$ boyutlu \mathbf{P}_g dönüşüm matrisi üretilir. Bu dönüşüm matrisi kullanılarak, eğitim kümesindeki görüntülere ait $d_g \times 1$ boyutlu parlaklık model parametreleri (\mathbf{b}_g) denklem 1.9 ile elde edilir. Denklem 1.10 ise herhangi bir yüz görüntüsüne ait parlaklık değerlerinin, parlaklık model parametreleri ile yeniden oluşturulmasını sağlamaktadır.

$$\mathbf{b}_g = \mathbf{P}_g^T \mathbf{g} \quad (1.9)$$

$$\mathbf{g} = \bar{\mathbf{g}} + \mathbf{P}_g \mathbf{b}_g \quad (1.10)$$

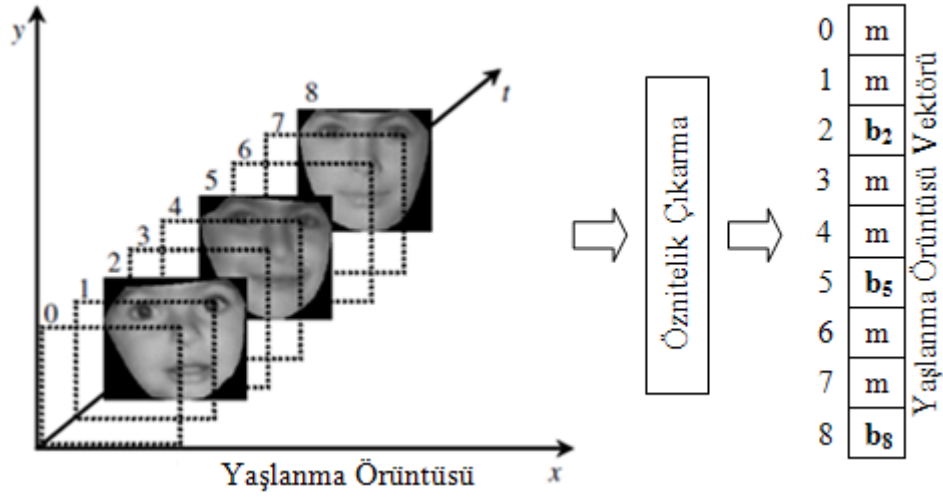
Bu aşamada bir görüntüye ait \mathbf{b}_s ve \mathbf{b}_g vektörleri, o görüntünün şekil ve parlaklık bilgisini içermektedir. Yüzün görünümünü ifade eden birleşik şekil-parlaklık model parametrelerinin (\mathbf{b}_c) üretiminde ise, şekil ve parlaklık değişiklikleri arasındaki olası bir korelasyonu ortadan kaldırmak için, şekil modeli parametreleri ve parlaklık modeli parametreleri tek bir vektörde birleştirilerek tekrar PCA uygulanmaktadır. Burada herhangi bir görüntüye ait şekil modeli parametreleri ve parlaklık modeli parametrelerinin $d_{sg} \times 1$

$(d_{sg}=d_s+d_g)$ boyutlu $\mathbf{b} = [\mathbf{b}_s^T \mathbf{b}_g^T]^T$ vektöründe tutulduğu varsayılırsa eğitim kümesindeki n örnek için şekil ve parlaklık bilgisi $d_{sg} \times n$ boyutlu $\mathbf{B} = [\mathbf{b}_i; \mathbf{b}_i \in R^D]_{i=1}^n$ matrisi ile temsil edilebilir. Ortalama şekil ve parlaklık bilgisi $\bar{\mathbf{b}} = \frac{1}{n} \sum_{i=1}^n \mathbf{b}_i$ ile elde edilir. Daha sonra $d_{sg} \times d_{sg}$ boyutlu $\mathbf{S} = \sum_{i=1}^n (\mathbf{b}_i - \bar{\mathbf{b}})(\mathbf{b}_i - \bar{\mathbf{b}})^T$ kovaryans matrisinin öz değerleri ve öz vektörleri $\arg \max_{\mathbf{P}_c} |\mathbf{P}_c^T \mathbf{S} \mathbf{P}_c|$ denkleminin çözülmesi ile belirlenir. Belirlenen öz vektörlerden en büyük $d_c \leq d_{sg}$ öz değere sahip olanlar birleştirilerek \mathbf{P}_c dönüşüm matrisi üretilir. Bu dönüşüm matrisi kullanılarak, eğitim kümesindeki görüntülere ait $d_c \times 1$ boyutlu birleşik şekil parlaklık model parametreleri ise $\mathbf{b}_c = \mathbf{P}_c^T \mathbf{b}$ ile elde edilir.

Sonuç olarak AAM ile üretilen \mathbf{b}_s , \mathbf{b}_g ve \mathbf{b}_c vektörleri, yaş tahmini sistemlerinde yaşlanma ile ilgili öznitelikler olarak kullanılmaktadır. AAM ile çıkarılan öznitelikleri kullanan yaş tahmini yaklaşımları, geometrik özniteliklere dayalı yaş tahmini yaklaşımlarıyla karşılaştırıldığında, yüzün hem şekil hem de parlaklık bilgisini kullandığından, sadece küçük yaşlarda değil, genel olarak tüm yaşlarda başarılı olabilmektedir. Fakat AAM'ler, yaşlı insanlar için yüzdeki kırışıklık bilgisini iyi bir şekilde kodlayamaz. Çünkü AAM yöntemi, görüntüdeki parlaklık değerlerini, doku örüntüsünü hesaplayacak uzaysal bir komşuluk dikkate almadan kodlar. Piksellerin parlaklık değerleri tek başına yerel doku bilgisini tanımlayamaz. Daha yaşlı yetişkinlerin yüzlerindeki kırışıklıkları ifade etmek için yerel bölgelerin incelenmesi gerekir. Diğer yandan, bu yaklaşımda her bir yaşlanma görüntüsü için ayrı bir yaşlanma fonksiyonu ve model parametreleri üretilmektedir.


1.3.3. Yaşlanma Örüntüsü Altuzayı ile Öznitelik Çıkarma

AGES, yaşlanma sürecinin modellenmesinde bir kişinin farklı yaşlardaki görüntülerinin dizisini kullanan bir yöntemdir (Geng vd., 2006; Geng vd., 2007). Yaşlanma örüntüsü, aynı kişiden alınmış yüz görüntülerinin zamana bağlı olarak sıralanması ile oluşturulan görüntü dizisi olarak tanımlanır. Şekil 1.7'de örnek bir yaşlanma örüntüsü görülmektedir.



Şekil 1.7. Yaşlanma örüntüsü vektörünün oluşturulması (Geng vd., 2006)

Kişinin tüm yaşlarına ait görüntüleri elde edilebiliyorsa, buna karşılık gelen yaşlanma örüntüsü tamamlanmış, aksi halde tamamlanmamış yaşlanma örüntüsü olarak adlandırılır. AGES, beklenti enbüyütleme (Expectation Maximization) benzeri tekrarlamalı öğrenme algoritmasını kullanarak, tamamlanmamış yaşlanma örüntüsündeki eksik görüntülerin elde edilebilmesini sağlar. Şekil 1.8’de tamamlanmış yaşlanma örüntüleri görülmektedir. Beyaz kesikli çerçeve içerisine alınan görüntüler algoritma ile öğrenilen eksik görüntülerdir.



Şekil 1.8. Tamamlanmış yaşlanma örüntüleri (Geng vd., 2006)

AGES yönteminde yüz görüntülerinden öznitelikler AAM ile çıkarılmaktadır. AAM yönteminde eğitim kümesindeki tüm örnekler birlikte kullanılırken, AGES yönteminde yaşlanma örüntüsünü ifade etmek için aynı kişinin farklı yaşlardaki görüntüleri birlikte kullanılmaktadır. Dolayısı ise eğitim kümesindeki her bir birey için özel bir yaşlanma örüntüsü öğrenilmektedir.

Bu yöntemin uygulanmasındaki en büyük kısıtlama, aynı kişinin çeşitli yaşlarda ve benzer görüntüleme koşullarındaki görüntülerini içeren bir veritabanının oluşturulmasının zorluğudur. Diğer yandan, öznitelik çıkarma aşamasında AAM kullandığından, kişinin yaşlanma sürecindeki şekil ve parlaklık bilgisini içerir, fakat kırışıklık gibi yerel doku bilgisini iyi bir şekilde tanımlayamaz.

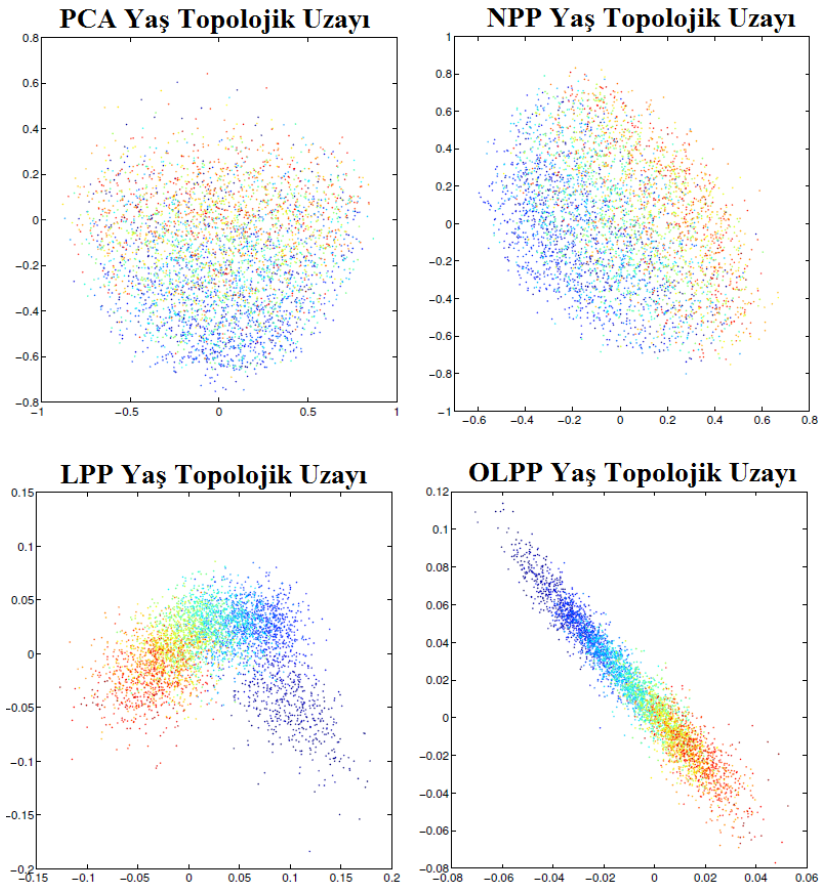
1.3.4. Topolojik Uzaya Gömmeye Dayalı Öznitelik Çıkarma

Bir önceki bölümde bahsedildiği gibi, aynı kişinin çeşitli yaşlardaki görüntülerini içeren bir veritabanının oluşturulması ve bundan dolayı her birey için özel bir yaşlanma örüntüsünün iyi bir şekilde öğrenilmesi zordur. Bunun yerine, farklı yaşlardaki birçok kişinin görüntüsünden, genel bir yaşlanma örüntüsü öğrenilebilir. Bu tip bir yaş örüntüsü öğrenme yöntemi, AGES ile karşılaştırıldığında, yüzdeki yaşlanma gösterimini daha esnek hale getirir. Ortak yaşlanma örüntüsünü öğrenmenin mümkün bir yolu, yaş topolojik uzayının (age manifold) öğrenilmesidir. Bu yöntemde, her bir yaş grubu için elde edilen çok sayıdaki resimden yaşlanma eğilimini öğrenmek için, verilerin daha küçük boyutlu bir topolojik uzaya gömülmesinden (manifold embedding) yararlanır. Dolayısı ile bir kişinin farklı yaşlardaki görüntülerine ihtiyaç duyulmaz. Her bir yaş etiketi için, o yaşı ifade eden pek çok farklı kişinin görüntüsü kullanılabilir. Bu esneklik geniş bir veritabanı oluşturulmasına da imkân sağlar.

Görüntü uzayının yaşlarına göre sıralanmış D boyutlu n örnekten oluşan $\mathbf{X} = [\mathbf{x}_i; \mathbf{x}_i \in R^D]_{i=1}^n$ görüntü kümesinden oluştuğu varsayalım. Burada \mathbf{x}_i , i . örneğe ait parlaklık değerlerini içeren vektördür. Görüntülerle ilişkilendirilen $\mathbf{l} = [l_i; l_i \in N]_{i=1}^n$ kümesi ise yaş etiketlerini içermektedir. Yaş topolojik uzayı öğrenmenin hedefi, verinin gerçek dağılımını ve geometrik yapısını yakalayan, daha küçük boyutlu bir gösterimin elde edilmesidir. Bu gösterim $\mathbf{Y} = [\mathbf{y}_i; \mathbf{y}_i \in R^d]_{i=1}^n$ $d \leq D$ ile gösterilsin. Böylece görüntü

uzayından topolojik uzaya haritalama, $\mathbf{Y} = \mathbf{P}^T \mathbf{X}$ 'i sağlayan $D \times d$ boyutlu \mathbf{P} matrisinin doğrusal ya da doğrusal olmayan yollarla öğrenilmesi anlamına gelir.

Verilerin daha küçük boyutlu bir uzaya gömülmesinde, gömülmüş verinin varyansını maksimize eden PCA, sınıflar arasındaki ayırt edici özellikleri ortaya çıkarmaya dayalı doğrusal ayırıştırma analizi (Linear Discriminant Analysis - LDA), veri kümesindeki komşuluk yapısını koruyan yerelliğin korunması izdüşümü (Locality Preserving Projection - LPP) (He vd., 2005) ve ortogonal yerelliğin korunması izdüşümü (Orthogonal Locality Preserving Projection - OLPP) (Cai vd., 2006) yöntemleri kullanılabilir. LPP eğitim örnekleri arasındaki ilişkiyi belirleyen bir ağırlık matrisi kullanır. Bu matriste birbirine yakın örnekler için ağırlık matrisine 1 değeri aksi halde 0 değeri yazılmaktadır. Diğer bir doğrusal boyut küçültme yöntemi olan komşuluğun korunması izdüşümü (Neighborhood Preserving Projection - NPP) ise her örneğin k komşusu üzerinden hesaplanan ağırlık katsayılarını kullanmaktadır (Pang vd., 2005). Şekil 1.9'da PCA, NPP, LPP ve OLPP algoritmalarının topolojik uzay görünüşleri verilmiştir.



Şekil 1.9. Çeşitli algoritmaların topolojik uzay görünüşleri (Fu vd., 2007)

Boyut küçültme yöntemlerinden PCA ve LPP danışmansız öğrenme algoritmalarıdır. Çünkü bu yöntemlerde görüntülerin sınıf etiketleri dikkate alınmamaktadır. Geometrik yapının yanında sınıf etiketlerinin de dikkate alınması ile performans artışı sağlanabilir. Bu amaçla LPP yönteminde oluşturulan örnekler arası ağırlık matrisinde, sadece birbirine yakın sınıflarda olan örneklere ağırlık ataması yapılarak, yöntemin sınıflar arasındaki ayırıcı gücü artırılabilir. Benzer şekilde yakın sınıf etiketlerine sahip olan örneklere daha büyük ağırlıklar verilerek denetimli bir öğrenme algoritması oluşturulabilir.

Diğer yandan ağırlık matrisinin üretilmesi sırasında, 20 ve 25 yaşlarındaki iki resmin farkıyla, 20 ile 40 yaşlarındaki iki resmin farkını, eşit şekilde değerlendiren yöntemlerdeki bu eksikliği gideren yöntemler geliştirilebilir. Yöntemde sınıf içi ve sınıflar arası dağılımlar çıkarılırken, farklı yaş etiketlerine sahip örneklerin farklı etkiye sahip olduğu ağırlık matrisleri üretilmektedir.

Genel olarak yaş topolojik uzayı yöntemleri, yaşlanma örüntülerinin öğrenilmesi için çeşitli boyut indirgeme yöntemleri kullanmaktadır. Geleneksel boyut indirgeme yöntemi olan PCA alt uzay gösteriminde herhangi bir yaş bilgisi kullanmadan sadece denetimsiz olarak çalışır. LPP, OLPP gibi yöntemlerin avantajı boyut indirgeme aşamasında yaş etiketlerini de dikkate alarak denetimli olarak gömme işlemi gerçekleştirmeleridir. AGES ile karşılaştırıldığında, yaş topolojik uzayı yöntemi her kişi için özel bir yaşlanma örüntüsü öğrenmeyi gerektirmez. Farklı kişilerin çeşitli yaşlardaki görüntülerinin kullanılabilmesine imkan sağlar. Bu yöntemlerin tek gereksinimi, alt uzayın öğrenilebilmesi için, eğitim kümesinin istatistiksel olarak yeterince geniş olması gerektiğidir.

1.3.5. Dokuya Dayalı Öznitelik Çıkarma

Dokuya dayalı öznitelik çıkarma yöntemleri genellikle yüz görüntülerinden yaşla ilişkili özniteliklerin çıkarılmasını sağlamaktadır. Bu öznitelikler yüzün bütününden çıkarılarak yüzün genel doku bilgisi elde edilebilir. Yerel doku bilgisinin üretiminde ise yüz görüntüsü bölgelere ayrılmakta ve her bölgeden çıkarılan doku öznitelikleri birleştirilmektedir. Bunun dışında, yaşlanma sürecinde doku yapısı daha çok değişen alın, göz bölgesi, göz kenarları, yanaklar, ağız kenarları gibi bölgeler belirlenip, bu bölgelerden çıkarılan doku öznitelikleri birleştirilerek kullanılabilir.

Yüz görüntülerindeki kırışıklık bilgisi yaşın belirlenmesinde önemli bir özniteliktir. Kırışıklık bilgisinin çıkarılmasında Sobel, Canny gibi kenar belirleme yöntemleri

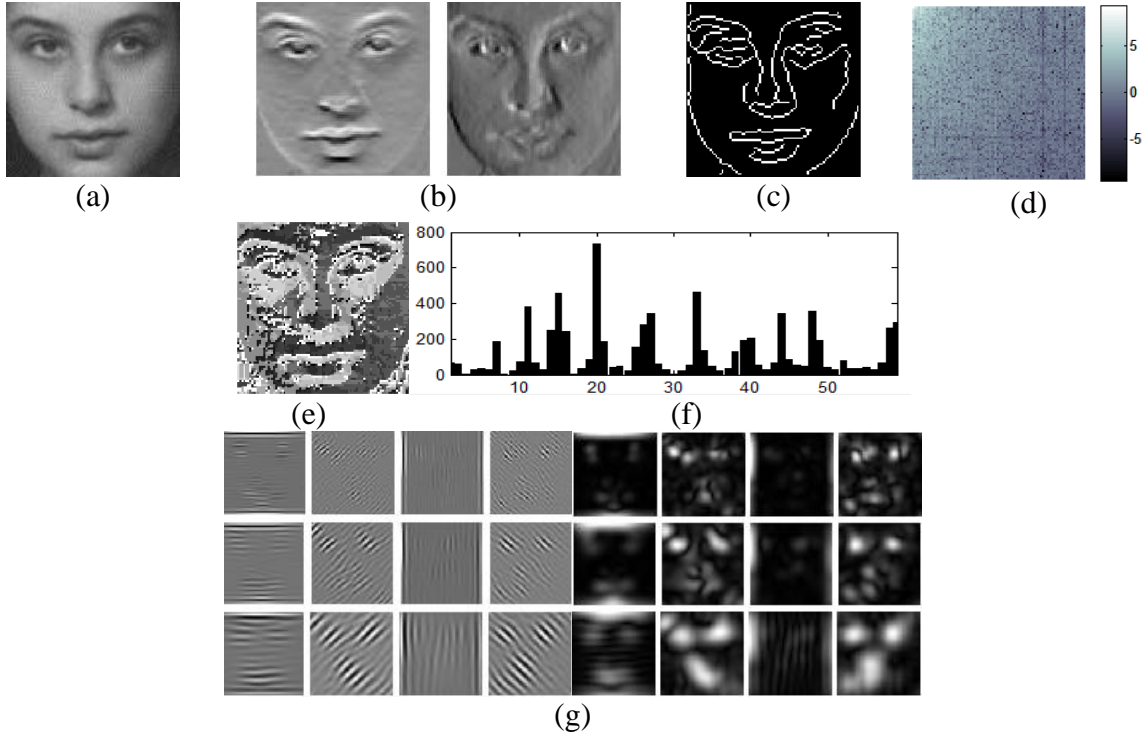
kullanılabilir. Bunların yanında çeşitli yön ve ölçekteki Gabor filtreleri kullanılarak da kırıksıklık bilgisi elde edilebilir.

Derinin genel doku bilgisi yaşın belirlenmesinde önemli bir parametredir. Bu amaçla doku bilgisinin çıkarılmasında yerel ikili örüntüler (Local Binary Patterns - LBP) kullanılabilir. LBP sayısal görüntünün doku ve şeklini tanımlayan çok güçlü bir yöntemdir (Ojala vd., 2002). Bu operatörün yüzdeki kenarlar, benekler, düz alanlar gibi mikro-örüntüleri ifade etmedeki başarısı, yöntemin yaş tahmininde de başarılı olabileceği düşüncesini uyandırmaktadır. Görüntünün daha verimli bir gösterimini oluşturmak için bölgesel LBP histogramları kullanılabilir.

Görüntülerdeki sapma ve poz değişikliklerinden dolayı oluşan problemlerin çözümünde, yüz görüntüsü yerel parçalara ayrılarak, parçalardan ayırık kosinüs dönüşümü (Discrete Cosine Transform - DCT) ile çıkarılan öznitelikler ve parça pozisyon bilgisi birlikte değerlendirilebilir. Diğer bir doku bilgisi çıkarma yönteminde insanın görsel nesne tanıma yönteminden esinlenilmektedir. Yöntemde Gabor filtreleri ile çıkarılan özniteliklere MAX işlemi uygulanarak, yaşlanma örüntüsündeki küçük geçişleri, dönmeleri ve ölçek değişimlerini elde etmek mümkündür.

Şekil 1.10'da yukarıda bahsedilen bazı doku bilgisi çıkarma yöntemlerinin örnek bir görüntü üzerindeki sonuçları görülmektedir. Bunların dışında yatay parlaklık değişimlerini içeren frekans bilgisini üretme, kırıksıklıkları ortaya çıkarmaya yönelik olarak orijinal görüntü ile düzleştirilmiş görüntünün farkını alma, Gaussian yüksek geçiren süzgeç uygulama, ayırık dalgacık dönüşümü, gradyan yönü histogramları (gradient direction histograms) gibi yöntemlerle de doku bilgisi çıkarılabilir.

Yukarıda açıklanan öznitelik çıkarma yöntemlerinin güçlü ve zayıf yönleri Tablo 1.1'de görülmektedir. Bunların haricinde yüz görüntülerinden karma öznitelikler çıkarılarak yaş tahmini yapılmaktadır. Karma öznitelikler yukarıda açıklanan yöntemlerin birleşimi ile öznitelik çıkarılmasını sağlamaktadır. Böylece bir yöntemin zayıf yönü diğer bir yöntemle kuvvetlendirilerek yaş tahmini performansını arttırılmaktadır.



Şekil 1.10. Çeşitli doku öznitelikleri çıkarma yöntemleri (a) Orijinal görüntü (b) Sobel filtreleri uygulanmış görüntüler (c) Canny kenar belirleme ile üretilen kenarlar (d) DCT öznitelikleri (e) LBP görüntüsü (f) LBP histogramı (g) 4 yön 3 ölçekli Gabor filtresi sonuçları

1.3.6. Karma Öznitelik Çıkarma

Karma öznitelik çıkarma yöntemleri önceki bölümlerde açıklanan öznitelik çıkarma yöntemlerini birlikte kullanan yöntemlerdir. Geometrik yapıya dayalı öznitelikler sadece yüzün geometrik yapısını dikkate aldığından, yetişkin kişilerin yaşının tahmininde yetersiz kalmaktadır. Bu nedenle bu öznitelikler, yüzdeki kırıksıklık bilgisini içeren özniteliklerle birleştirilerek sadece küçük yaşlar için değil, genel olarak tüm yaşlar için yaş tahmini yapılması sağlanır.

Yüzün hem şekil hem de parlaklık bilgisini içeren AAM öznitelikleri, genel olarak tüm yaşların tahmininde belirli ölçüde başarılı olmaktadır. Fakat bu yöntem görüntüdeki parlaklık değerlerini herhangi bir komşusuyla olan ilişkisini dikkate almadan kodladığı için, görüntülerdeki doku bilgisini tanımlayamaz. Bu nedenle AAM ile çıkarılan genel şekil ve parlaklık öznitelikleri, yerel doku öznitelikleriyle desteklenerek, yaş tahmini performansı arttırılabilir.

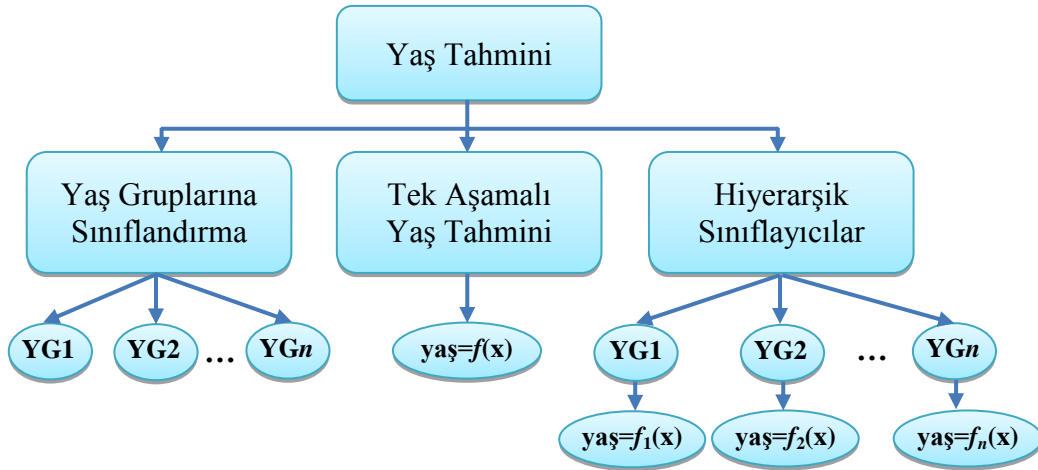
Tablo 1.1. Öznitelik çıkarma yöntemlerinin güçlü ve zayıf yönleri

Yöntem	Güçlü Yönleri	Zayıf Yönleri
Geometri	<ul style="list-style-type: none"> • Yüzün geometrik yapısını dikkate alır • Küçük yaşlar için ayırt edicidir 	<ul style="list-style-type: none"> • Yüzün doku bilgisini içermez. • Yetişkinler için ayırt edici değildir
AAM	<ul style="list-style-type: none"> • Yüzün şekil ve parlaklık bilgisini içerir. • Genel olarak tüm yaşlar için ayırt edicidir. 	<ul style="list-style-type: none"> • Yüzün doku bilgisini içermez. • Yaşlı yetişkinler için ayırt edici değildir.
AGES	<ul style="list-style-type: none"> • Her kişi için ayrı bir yaşlanma örüntüsü öğrenilir. • Yüzün şekil ve parlaklık bilgisini içerir. • Genel olarak tüm yaşlar için ayırt edicidir. 	<ul style="list-style-type: none"> • Uygun bir veritabanı olmadığından uygulanması zordur. • Yüzün doku bilgisini içermez. • Yaşlı yetişkinler için ayırt edici değildir.
Topolojik Uzay	<ul style="list-style-type: none"> • Çeşitli kişilerden genel yaşlanma örüntüsü öğrenilir. • Esnek bir yapıya sahiptir. • Farklı kişilerin resimleri kullanılabilir. • Boyut indirgeme sağlar. 	<ul style="list-style-type: none"> • Alt uzayı öğrenebilmek için veritabanı yeterince büyük olmalıdır. • Genellikle resimlerin parlaklık değerleri kullanılır.
Doku	<ul style="list-style-type: none"> • Yüzün dokusal özelliklerini ortaya koyar. • Genel ve yerel doku bilgisi elde edilebilir. 	<ul style="list-style-type: none"> • Yüze ait herhangi bir geometrik bilgi içermez.

Bunların dışında AAM ile çıkarılan özniteliklerin ya da dokuya dayalı çıkarılan özniteliklerin boyutunun indirgenmesinde, topolojik uzaya gömme yöntemlerinden faydalanılabilir. Böylece örnekler arasındaki geometrik ilişki belirlenip, çıkarılan özniteliklerin daha ayırt edici bir uzaya taşınması sağlanabilir.

1.4. Yaşın Tahmini

Yüz görüntülerinden yaşın belirlenmesi konusunda yapılan çalışmalarda, öznitelik çıkarma aşaması kadar önemli bir aşama da yaşın tahmin edilmesi aşamasıdır. Yaşın tahmini genellikle üç şekilde yapılmaktadır. Şekil 1.11’de görüldüğü gibi yaşın tahmini, yaş grubuna sınıflandırma, tek aşamalı yaş tahmini ve hiyerarşik sınıflayıcılar ile gerçekleştirilebilir. Bu yöntemler alt başlıklarda daha detaylı olarak açıklanmaktadır.



Şekil 1.11. Yaş tahmini yöntemlerinin şematik gösterimi

1.4.1. Yaş Gruplarına Sınıflandırma

Yaş grubuna sınıflandırma yöntemlerinde herhangi bir görüntünün, sınırları daha önceden belirlenmiş yaş gruplarından birine sınıflandırılması hedeflenmektedir. Burada amaç kişinin kesin yaşını tahmin etmek değil, hangi yaş aralığında olduğunu bulmaktır. Bu yöntemlerde yaş gruplarının sınırlarının belirlenmesi önemlidir. Görüntüler bebek, çocuk, yetişkin, yaşlı gibi yaş gruplarına sınıflandırılacağı gibi, 0-10, 11-20, ... gibi sınırları kesin yaş etiketleriyle belirlenmiş çok sayıdaki yaş grubuna da sınıflandırılabilir. Yaş grupları oluşturulduktan sonra, herhangi bir test görüntüsünün bu yaş gruplarından birine sınıflandırılmasında yapay sinir ağları (Neural Networks – NN), destek vektör makineleri (Support Vector Machines - SVM), LDA, şablon eşleme (template matching), k -en yakın komşuluk (k -Nearest Neighbour - k NN) gibi sınıflayıcılar kullanılır.

1.4.2. Tek Aşamalı Yaş Tahmini

Tek aşamalı yaş tahmini yöntemleri, bir görüntüye ait kesin yaş etiketinin belirlenmesini sağlamaktadır. Burada eğitim kümesindeki tüm görüntülerin öznelilikleriyle yaş etiketleri arasında bir yaşlanma fonksiyonu öğrenilmektedir. Yaşlanma fonksiyonu kişinin yaşı ile yüz öznelilikleri arasındaki ilişkiyi tanımlamaktadır. Bu ilişki bir kez kurulduğunda, daha önceden görülmemiş bir kişinin yaşı, özneliliklerine bağlı olarak tahmin edilebilmektedir. Yaşlanma fonksiyonunun öğrenilmesinde çoklu lineer regresyon

(Multiple Linear Regression - MLR), NN, SVM, destek vektör makineleri ile regresyon (Support Vector Regression - SVR), görüntünün en yakın k komşusunun yaş ortalamasının alınması gibi yöntemler kullanılmaktadır.

1.4.3. Hiyerarşik Sınıflayıcılar

Hiyerarşik yaş tahmini yöntemleri, yaş grubuna sınıflandırma ve kesin yaşın belirlenmesi yöntemleri birleştirilerek yaş tahmini başarımını arttırmaktadır. Öncelikle yüz görüntüleri belirlenen yaş gruplarına sınıflandırılır. Daha sonra her yaş grubu için sadece o yaş grubundaki görüntüler kullanılarak farklı bir yaşlanma fonksiyonu öğrenilir. Farklı yaş gruplarındaki yüz görüntüleri farklı özelliklere sahip olduğundan, tüm yaş grupları için tek bir yaşlanma fonksiyonu oluşturmak yerine, her yaş grubu için ayrı bir yaşlanma fonksiyonunun üretilmesi daha doğru bir yaş tahmini sağlar.

Hiyerarşik yöntemlerde herhangi bir sınıflayıcı ile regresyon yöntemi birlikte kullanılır. Örneğin sınıflandırma aşamasında SVM, yaşın tahmininde ise SVR kullanılabilir. Başka bir hiyerarşik sınıflayıcı, test örneğinin en yakın k komşusunu belirleyip, bu k komşusunu kullanarak regresyon yöntemi ile yaşlanma fonksiyonu üretip yaşı tahmin edebilir. Sınıflandırma ve yaşın belirlenmesi aşamasında tek bir sınıflayıcı ya da regresyon yöntemi kullanmak yerine, çok sayıdaki sınıflayıcının ve regresyon yöntemlerinin sonuçlarının birlikte değerlendirilmesi sistem başarımını arttırabilir. Tüm yaş grupları için aynı yöntemle yaşlanma fonksiyonu üretmek yerine, eğitim aşamasında her yaş grubu için en iyi sonucu veren yaşlanma fonksiyonu üretme yöntemi belirlenip test aşamasında kullanılabilir.

Yukarıda detaylı olarak açıklanan yaş tahmini yöntemlerinin her birinin güçlü ve zayıf yönleri mevcuttur. Bunlar Tablo 1.2'de özet olarak verilmiştir.

1.5. Sistem Başarımını Değerlendirme Yöntemleri

Sistem başarımının değerlendirilmesinde, eğitim ve test örneklerinin belirlenmesi gerekmektedir. Bu amaçla yaş tahmini sistemlerinde, bir kişiyi dışarıda bırak (Leave One Person Out - LOPO), n -kat çapraz doğrulama (n -fold Cross Validation) ya da eğitim ve test örneklerinin öznel kriterlerle belirlenmesi yöntemleri kullanılmaktadır.

Tablo 1.2. Yaş tahmini yöntemlerinin güçlü ve zayıf yönleri

Yöntem	Güçlü Yönleri	Zayıf Yönleri
Yaş grubuna sınıflandırma	<ul style="list-style-type: none"> Görüntülerin hangi yaş aralığında olduğu belirlenir. 	<ul style="list-style-type: none"> Kişinin detaylı yaşı belirlenemez. Yaş gruplarının sınırları öznel olarak belirlenmektedir. Farklı yaş grupları için yöntemin sonucu iyi ya da kötü sonuç verebilir.
Tek aşamalı yaş tahmini	<ul style="list-style-type: none"> Görüntülerin yaş etiketi belirlenir. Tek bir tahmin edici ile tüm görüntülerin yaşı tahmin edilir. 	<ul style="list-style-type: none"> Farklı yaş gruplarının öznitelikleri arasındaki farklılıklar dikkate alınmaz.
Hiyerarşik sınıflayıcı	<ul style="list-style-type: none"> Farklı yaş gruplarının öznitelikleri arasındaki farklılıklar dikkate alınır. Her yaş grubu için o yaş grubuna özel bir yaşlanma fonksiyonu oluşturulur. 	<ul style="list-style-type: none"> Yaş grubunun belirlenmesi aşamasındaki hata, detaylı yaş tahminini etkileyecektir.

1.5.1. Bir Kişiyi Dışarıda Bırak Yöntemi

LOPO tekniğinde veritabanındaki bir kişiye ait olan tüm yaş görüntüleri test kümesi olarak belirlenip, geriye kalan tüm örnekler eğitim kümesi olarak kullanılır. Bu işlemler veritabanındaki tüm kişiler için tekrarlandığında her bir kişi bir kez test örneği olarak kullanılmış olur. Böylece sistem gerçek uygulamalara benzer şartlarda test edilmiş olmaktadır. Tüm kişiler için elde edilen başarımların ortalaması alınarak sistemin genel başarımları hesaplanmaktadır.

1.5.2. n -katlı Çapraz Doğrulama Testi

n -kat çapraz doğrulama yönteminde veritabanındaki görüntülerden rastgele olarak seçilen bir kısım resim eğitim kümesi, geri kalanlar test kümesi olarak kullanılmaktadır. Bu işlem n kez tekrar edilip ortalaması alınarak başarımlar hesaplanmaktadır. Örneğin 5 katlı çapraz doğrulama testinde örneklerin $1/5$ 'i test kümesi $4/5$ 'i eğitim kümesi olarak kullanılır ve başarımlar hesaplanır. Bu işlem 5 kez tekrarlanarak elde edilen başarımların ortalaması, sistemin genel başarımları olarak hesaplanır.

1.5.3. Eğitim ve Test Kümelerinin Öznel Kriterlerle Belirlenmesi

Bu yöntemde veritabanındaki görüntülerin belirli bir kısmı eğitim kümesi olarak, geri kalan kısmı test kümesi olarak kullanılmaktadır. Bazı yöntemlerde ise veritabanındaki bütün resimler yerine, öznel kriterlere göre seçilmiş belirli sayıdaki eğitim ve test örnekleri ile yöntemin başarısı değerlendirilmektedir.

1.6. Performans Ölçütleri

Yaş tahmini alanında, farklı yöntemler, veri tabanları ve sistemler kullanıldığından hem ortalama mutlak hata (Mean Absolute Error - MAE) hem de kümülatif skor (Cumulative Score – CS) ölçütleri kullanılmaktadır. Örneğin, çeşitli yaşlarda yeterli sayıda görüntü içeren büyük bir eğitim veritabanında sıralı etiketler mevcut ise, performansın değerlendirilmesinde CS iyi bir teknik olabilir. Fakat veritabanındaki yaş dağılımı dengeli değilse, çok sayıda eksik veri ve yaş görüntüsü varsa, sistemin MAE ile değerlendirilmesi daha uygun olmaktadır. Görüntüyü herhangi bir yaş grubuna sınıflandırmaya çalışan yöntemlerin performansı ise sınıflandırma doğruluğu (Classification Accuracy - CA) ile ölçülmektedir.

1.6.1. Ortalama Mutlak Hata

MAE ölçütü, test kümesindeki görüntüler için sistem tarafından tahmin edilen yaş etiketleri ile gerçek yaş etiketleri arasındaki mutlak hata değerlerinin ortalaması alınarak hesaplanmaktadır. Yaş tahmini sistemlerinin performansının değerlendirilmesinde en çok kullanılan ölçüt aşağıdaki denklemle ifade edilmektedir.

$$MAE = \frac{\sum_{i=1}^{N_t} |\hat{y}_i - y_i|}{N_t} \quad (1.11)$$

Denklemde \hat{y}_i , i . test örneği için tahmin edilen yaş değerini, y_i aynı örneğe karşılık gelen gerçek yaş değerini, N_t ise toplam test örneğini ifade etmektedir.

1.6.2. Kümülatif Skor

CS ölçütü, j yıla kadar hata toleransı ile sistem başarısını değerlendirmektedir. Diğer bir ifade ile en fazla j yıl hata yapacak şekilde yaş tahmin edilebilen test örneği oranının hesaplanmasını, aşağıdaki denklemlerle sağlamaktadır.

$$CS(j) = \frac{N_{e \leq j}}{N_t} \times 100\% \quad (1.12)$$

Denklemlerde $N_{e \leq j}$ yaş tahmin sisteminin j yıla kadar hata toleransı tanındığında, doğru olarak yaşını tahmin ettiği test örnek sayısını ifade etmektedir. N_t ise toplam test örneği sayısıdır.

1.6.3. Sınıflandırma Doğruluğu

CA ölçütü, doğru olarak sınıflandırılan test örnek sayısının, toplam test örnek sayısına oranıdır ve aşağıdaki denklem kullanılarak hesaplanmaktadır.

$$CA = \frac{N_d}{N_t} \times 100\% \quad (1.13)$$

Denklemlerde N_d , doğru olarak sınıflandırılan test örnek sayısını, N_t ise test kümesindeki toplam örnek sayısını ifade etmektedir.

1.7. Literatür Taraması

Yüz görüntülerinden yaş tahmini alanında literatürde yapılan çalışmalar bu bölüm altında incelenmektedir. Bu çalışmalar, kullandıkları öznelik çıkarma yöntemlerine göre sınıflandırılarak aşağıda verilmiştir.

- Geometrik özneliklere dayalı yaş tahmini çalışmaları: Yüz görüntülerinden yaşın sınıflandırılması konusundaki ilk çalışma Kwon ve Lobo (1999) tarafından yayınlanmıştır.

Çalışmada, düz bakan (frontal view) yüz görüntülerinden 6 çeşit geometrik öznitelik çıkarılmış ve bu öznitelikler bebekleri yetişkinlerden ayırmak amacıyla kullanılmıştır. 47 yüz görüntüsünden oluşan küçük bir veritabanında yapılan deneylerde, sistemin bebekleri yetişkinlerden ayırma performansı %68'in altındadır. Geometrik öznitelikler yetişkin yüzlerin sınıflandırılmasında yetersizdir. Bu nedenle Kwon ve Lobo (1999), yüz görüntülerindeki alın, göz kenarları ve yanak bölgelerinden aktif şekil modelleri (Active Contour Models) (Kass vd., 1988) ile çıkardıkları kırışıklık bilgisini kullanarak, yetişkinlerin genç ve yaşlı olarak sınıflandırılmasını sağlamıştır. Bu aşamada kullanılan test örnek sayısı sadece 15'tir.

Geometrik öznitelikleri kullanarak sınıflandırma gerçekleştiren başka bir çalışmada, yüz görüntülerinin bebek ya da yetişkin olarak sınıflandırılması hedeflenmiştir (Shen ve Ji, 2008). Bu amaçla, gözle burun delikleri arasındaki mesafenin, gözbebekleri arasındaki mesafeye oranı ile hesaplanan, tek bir geometrik öznitelik kullanılmıştır. Bu geometrik özniteliğin bebekler ve yetişkinler için istatistiksel değerlendirilmesi yapılmış ve elde edilen veriler Gauss dağılımları ile modellenmiştir. Bir giriş görüntüsünün herhangi bir sınıfa ait olma olasılığı bu dağılımların ortalama ve standart sapma değerleri kullanılarak hesaplanmış ve görüntü daha büyük olasılığa sahip olan sınıfa sınıflandırılmıştır. İnternette toplanan 79 bebek ve 100 yetişkin görüntüsü için yapılan değerlendirmede yöntem bebekleri %75.9, yetişkinleri ise %71 CA ile sınıflandırmaktadır. Gözlerle ağız arasındaki mesafeye bağlı olarak görüntüleri sınıflandıran diğer bir çalışmada, görüntüler çocuk (0-12), genç (13-18), yetişkin (19-59) ve yaşlı yetişkin (60-69) yaş gruplarına NN ile sınıflandırılmıştır (Nithyashri ve Kulanthaivel, 2012). FG-NET veritabanından alınan görüntüler üzerinde yapılan deneylerde, eğitim ve test kümelerindeki görüntü sayıları ve değerlendirme yöntemi belirtilmemiş, %94.28 CA rapor edilmiştir. Izadpanahi ve Toygar (2012) ise yüz üzerindeki 17 belirleyici noktanın koordinatlarını kullanarak ürettikleri 6 çeşit geometrik özniteliği, görüntülerin 0-2, 3-7, 8-19, 20-39 ve 40-60 yaş gruplarına sınıflandırılmasında kullanmıştır. Sınıflandırma NN ile gerçekleştirilmiştir. FG-NET veritabanından 650 ve İran yüz veritabanından (Iranian Face Database) 204 düz bakan, gözlük, bıyık ve sakal içermeyen yüz görüntüsü seçilerek yapılan deneylerde, yöntemin 0-2 yaş grubunu diğer yaş gruplarından %98 CA ile ayırdığı ifade edilmiştir. 3-7, 8-19, 20-39 ve 40-60 yaş grupları için sırasıyla %96.21, %89.40, %80.80 ve %83.11 CA elde edilirken, sistemin ortalama CA'sı ise %90 olarak belirtilmiştir.

Kwon ve Lobo (1999) gibi yüzün geometrik özniteliklerini ve kırışıklık bilgisini birlikte kullanarak yaş tahmini gerçekleştiren başka çalışmalar da yapılmıştır (Horng vd., 2001; Dehshibi ve Bastanfard 2010; Kalansuriya ve Dharmaratne, 2013; Liang vd., 2013; Liu vd., 2014). Horng vd. (2001) yüz görüntülerini, bebekler (0-2), genç yetişkinler (3-39), orta yaşlılar (40-59) ve yaşlılar (≥ 60) olmak üzere 4 yaş grubuna sınıflandırmak için 2 geometrik özniteliği ve 3 kırışıklık bilgisini kullanmıştır. Geometrik özniteliklerden birincisi, göz-ağız arası mesafenin gözler arası mesafeye oranı, ikincisi ise göz-burun arası mesafenin burun-ağız arası mesafeye oranıdır. Kırışıklık bilgisinin üretilmesi aşamasında ise, önce görüntüdeki alın, göz kenarları ve yanak bölgelerinden Sobel operatörü ile kenar bilgisi çıkarılmış, bu kenar bilgisi kullanılarak kırışıklık yoğunluğu, kırışıklık derinliği ve ortalama deri değişimi gibi doku öznitelikleri tanımlanmıştır. Çalışmada kullanılan iki NN'den birincisi geometrik özniteliklerle eğitilerek bebeklerin sınıflandırılmasını sağlamaktadır. Bir giriş görüntüsünün bebek olmadığına karar verildiğinde, kırışıklık bilgileriyle eğitilen ikinci NN kullanılarak, görüntünün diğer üç sınıftan hangisine sınıflandırılacağına karar verilmektedir. 230 resimden oluşan bir veritabanı üzerinde yapılan deneylerde sistemin CA'sı %81.58 olarak bildirilmiştir. Bu çalışmanın sınıflandırma başarımı iyi olmasına rağmen bazı eksiklikler söz konusudur. Öncelikle kullanılan veritabanındaki yüz görüntülerinin kesin yaşları bilinmediğinden, yaşlar subjektif olarak belirlenmiştir. Diğer yandan yöntemin öznitelik çıkarma algoritması görüntü boyutuna bağlıdır. Boyuttaki herhangi bir değişim sistem performansını büyük ölçüde etkileyebilir. Son olarak yöntemdeki yaş grupları iyi bir şekilde düzenlenmemiştir. Dehshibi ve Bastanfard (2010) yüz görüntülerinden çıkardıkları 7 geometrik özniteliği ve 3 kırışıklık bilgisini bir NN ile birlikte kullanarak, yüz görüntülerinin 4 yaş grubuna sınıflandırılmasını sağlamıştır. Kırışıklık bilgisi, alın, göz kenarı ve yanak gibi kırışıklık bölgelerinden Canny kenar bulma yöntemi ile elde edilmiştir. İran yüz veritabanından seçilen 498 resimden 298'i eğitim, 200'ü test aşamasında kullanılarak yapılan değerlendirmede, sistemin yüz görüntülerini, sınırları ≤ 15 , 16-30, 31-50 ve > 50 olarak belirlenen yaş gruplarına, %86.64 CA ile sınıflandırdığı rapor edilmiştir. Kalansuriya ve Dharmaratne (2013) ise FERET ve FG-NET veritabanlarından seçtikleri yüz görüntülerini, sınırları 8-13, 14-25, 26-45 ve 46-63 olarak belirlenen yaş gruplarına sınıflandırmak için 2 geometrik öznitelik ve 6 kırışıklık bilgisi kullanmıştır. Geometrik öznitelikler, gözler arası mesafenin göz-burun arası mesafeye oranı ve gözler arası mesafenin göz-ağız arası mesafeye oranıdır. Kırışıklık bilgisi ise, alın, göz kenarları ve yanak olmak üzere üç

bölgeden Sobel yöntemi ile elde edilen kenar bilgisi kullanılarak hesaplanan, kırışıklık yoğunluğu ve kırışıklık derinliğidir. Sınıflandırmada kullanılan NN, 550 görüntüden çıkarılan özniteliklerle eğitilmiştir. Test aşamasında sistem performansını değerlendirmek için 200 görüntü kullanılmış ve %74.38 CA elde edilmiştir.

Geometrik öznitelikleri ve kırışıklık bilgisini kullanarak hiyerarşik bir yaş tahmini yaklaşımı oluşturan Liang vd. (2013), yüz görüntülerini önce yaş gruplarına sınıflandırmış, daha sonra her yaş grubu altında kesin yaşın belirlenmesini sağlamıştır. Yaş grubuna sınıflandırmada geometrik öznitelikler ve alın, göz kenarları ve yanak bölgelerinden Canny kenar belirleme yöntemi ile çıkarılan kırışıklık bilgisi, kesin yaşın tahmininde ise geometrik öznitelikler ve LBP ile üretilen doku bilgisi kullanılmıştır. Görüntüler, sınırları 0-9, 10-19, 20-29, 30-39 ve 40-69 olarak belirlenmiş 5 yaş grubuna ardışık *k*NN (sequential *k*NN) ile sınıflandırılmıştır. Kesin yaşın belirlenmesinden ise sıralamalı *k*NN (ranking *k*NN) kullanılmıştır. FG-NET veritabanında yapılan deneylerde LOPO yöntemi ile 5.37 yıl MAE başarı elde edilmiştir.

Liu vd. (2014), çalışmalarında şekil-tabanlı ve doku-tabanlı olmak üzere iki ayrı sınıflayıcı oluşturarak, yüz görüntülerini bebek, çocuk ve yetişkin yaş gruplarına sınıflandırmayı hedeflemiştir. Çalışmada, yüzün büyüme sürecinde değişen dairesellik bilgisi ve çenenin göz merkezleriyle birleştirilmesiyle oluşan üçgenin çene köşesindeki açı değeri şekil öznitelikleri olarak kullanılmıştır. Yüzün büyümesi esnasında şekli yuvarlaktan ovale değişirken çene açısı ise küçülmektedir. Eğitim kümesindeki her yaş grubu için bu öznitelikler çıkarılmış ve her grubun şekil öznitelikleri için birleşik Gauss dağılım modelleri oluşturulmuştur. Bir test örneğinin sınıflandırılmasında, bu modeller en büyük olasılık sınıflayıcısı ile birlikte kullanılarak karar verilmiştir. Doku tabanlı sınıflayıcı ise, gradyan yönü piramidi ile öznitelik çıkarma, öznitelik seçme ve SVM ile sınıflandırma aşamalarından oluşmaktadır. Eğitim örneği aşamalı olarak küçültülerek her adımda gradyan yönü öznitelikleri çıkarılmakta ve birleştirilmektedir. Bu şekilde üretilen öznitelik vektörünün boyutu çok büyük olduğundan ayırt edici gücü daha fazla olanların seçilmesinde varyans analizi yöntemi kullanılmıştır. Çalışmada son olarak bu iki sınıflayıcı birleştirilerek hiyerarşik bir yaş tahmini sistemi oluşturulmuştur. Burada öncelikle şekil tabanlı sınıflayıcı ile test örneğinin üç sınıftan birine kesin olarak sınıflandırılıp sınıflandırılmayacağına karar verilmekte, sınıflandırılmayan görüntüler doku tabanlı sınıflayıcıya gönderilmektedir. Deneylerde FG-NET veritabanı için sınırları 0-3, 4-19 ve 20-59 olan yaş grupları, MORPH veritabanı içinse sınırları 16-19, 20-59 ve 60-77 olan yaş

grupları oluşturulmuştur. 5-kat çapraz doğrulama testi ile FG-NET veritabanında şekil öznitelikleri için ayrı ayrı yapılan değerlendirmelerde sırasıyla %73.3 ve %70.7 CA elde edilmiştir. Doku tabanlı sınıflayıcının FG-NET veritabanındaki CA'sı %91.4, MORPH veritabanındaki CA'sı ise %90.3 olarak belirtilmiştir. Hiyerarşik sınıflayıcı ile elde edilen CA'lar ise FG-NET veritabanı için %95.1, MORPH veritabanları için %93.7'dir.

- AAM özniteliklerine dayalı yaş tahmini çalışmaları: AAM öznitelikleri ile yaş tahmini gerçekleştiren ilk çalışma Lanitis vd.'ne (2002) aittir. Çalışmada AAM özniteliklerinin, yüzün yaşlanmasını ifade etmek için bir yaşlanma fonksiyonu ile birlikte kullanılması önerilmiştir. Yaş değişimini açıklayan $Age=f(b)$ fonksiyonunda Age kişinin gerçek yaşını, b AAM'den öğrenilmiş model parametrelerini içeren vektörü, f ise yaşlanma fonksiyonunu ifade etmektedir. Yaşlanma fonksiyonu kişinin yaşı ile yüz görüntüsünün parametrik gösterimi arasındaki ilişkiyi tanımlamaktadır. Bu ilişki bir kez kurulduğunda, daha önceden görülmemiş bir kişinin yaşı, kodlanmış gösterimine bağlı olarak tahmin edilebilmekte ya da herhangi bir yaştaki görüntüsü oluşturulabilmektedir. Lanitis vd. (2002), yüz şekil modelinin eğitiminde, her eğitim örneğinden alınan 50 belirleyici noktanın koordinatlarını, parlaklık modelinin eğitiminde ise her örnekten alınan 3600 parlaklık değerini kullanmıştır. Sonuçta üretilen birleşik şekil-parlaklık modelinde, eğitim kümesindeki değişimin %95'ini ifade etmek için 50 model parametresi yeterli olmaktadır. Çalışmada yaşın tahmini ise bir regresyon problemi olarak ele alınmış, yaşlanma fonksiyonu için doğrusal, karesel (quadratic) ve kübik fonksiyonlar olmak üzere üç yöntem araştırılmıştır. Bu çalışma aynı zamanda yaşlanmadan doğan değişikliklerden etkilenmeyen yüz tanıma sistemlerinin tasarımında kullanılmıştır. Deneyler 1 ile 30 yaş aralığındaki 60 kişiden alınmış 500 yüz görüntüsünden oluşan bir veritabanında gerçekleştirilmiştir. Bu görüntüler yaşlanma fonksiyonunun ve kişinin herhangi bir yaştaki görünümünün oluşturulmasında kullanılmıştır. Eğitim kümesinde olmayan kişiler için yaşlanma fonksiyonu oluşturmada 4 yöntem incelenmiştir. Bunlar tüm kişilerin aynı yaşlanma sürecine sahip olduğunu varsayan genel yaşlanma fonksiyonu, benzer kişilerin benzer şekilde yaşlandığını varsayan görünüme özel yaşlanma fonksiyonu, test görüntüsünün eğitim kümesindeki yaşlanma görüntülerine benzerliğini dikkate alan ağırlıklı görünüme özel (Weighted Appearance Specific - WAS) yaşlanma fonksiyonu ve kişinin yaşam profilini (cinsiyet, sağlık durumu, ekonomik durum vb.) de dikkate alan ağırlıklı kişiye özel yaşlanma fonksiyonudur. Bu 4 yöntemin yaş tahminindeki performansı incelendiğinde LOPO yöntemi ile sırasıyla 6.21, 7.43, 5.04 ve 4.33 yıl MAE elde

edilmiştir. Yaşlanma etkilerine karşı dayanıklı bir yüz tanıma sistemi oluşturulması konusunda yapılan deneylerde ise, yaşlanma etkilerinin ortadan kaldırılması ile birlikte, ağırlıklı kişiye özel yaşlanma fonksiyonu kullanımının, yüz tanıma performansını %63'ten %71'e çıkardığı görülmüştür. Eğitim ve test kümeleri yer değiştirildiğinde ise yüz tanıma başarısı %51'den %66'ya yükselmiştir.

Lanitis vd. (2004) daha önceki çalışmalarında oluşturdukları yaş gösterimi yöntemlerini, yaş tahmini için farklı sınıflayıcılarla birlikte kullanmıştır. 0 ile 35 yaşları arasındaki 40 kişiden alınmış 400 görüntüden oluşan bir veritabanı kullanılarak, tek aşamalı yaş tahmininde, karesel yaşlanma fonksiyonu, Mahalanobis uzaklığına dayalı en yakın komşuluk sınıflayıcısı, çok katmanlı algılayıcı (Multilayer Perceptrons) ve özdüzenleyici haritalar (Self Organizing Maps) için deneyler yapılmış ve bu yöntemler için sırasıyla 5.04, 5.65, 4.78 ve 4.9 yıl MAE değerleri elde edilmiştir. Diğer yandan sınıflandırma işleminin tek bir sınıflayıcı yerine farklı sınıflayıcılarla gerçekleştirildiği üç farklı hiyerarşik yaş tahmini yöntemi önerilmiştir. Bunlar yaşa özel sınıflayıcılar, görünüme özel sınıflayıcılar ve görünüme ve yaşa özel sınıflayıcılar (Appearance and Age Specific - AAS) olarak sıralanmaktadır. AAS yönteminde, eğitim kümesindeki görüntüler önce görünümüne bağlı olarak, 0-10, 11-20, 21-35 yaş gruplarına ayrılmakta, daha sonra her bir grup içinde yaşın belirlenmesi için, yaşa özel sınıflayıcılar eğitilmektedir. AAS ile hiyerarşik yaş tahmininde, karesel regresyon fonksiyonu ile 3.82 yıl, en yakın komşuluk sınıflayıcısı ile 4.92 yıl ve çok katmanlı algılayıcılarla 4.38 yıl MAE sonuçları elde edilmiştir. Fakat bu sonuçlar küçük yaş aralığına sahip küçük bir veritabanını ifade etmektedir.

Daha sonraki yıllarda AAM özneliklerini farklı sınıflayıcılarla kullanarak yaş tahmini gerçekleştiren başka çalışmalar yapılmıştır (Luu vd., 2009; Liu vd., 2012; Wang vd., 2009a; Kohli vd., 2013). Luu vd. (2009) ve Liu vd. (2012) AAM özneliklerini SVM ile birlikte kullanarak yaş tahmini gerçekleştirmiştir. Her iki çalışmada da giriş görüntüleri 68 belirleyici nokta ile temsil edilmiş ve AAM ile şekil ve parlaklık bilgisini içeren öznelik vektörleri üretilmiştir. Luu vd. (2009) öznelik vektörlerini SVM'nin eğitiminde kullanarak, görüntüleri öncelikle çocuk (0-20 yaş) ya da yetişkin (21-69 yaş) yaş gruplarına sınıflandırmıştır. Daha sonra çocuk olarak sınıflandırılan yüzler, SVR kullanılarak üretilen büyüme-gelişme fonksiyonu $f_1(x)$ 'e, yetişkin olarak sınıflandırılan yüzler ise yine SVR ile üretilen yetişkin-yaşlanma fonksiyonu $f_2(x)$ 'e giriş olarak verilmiş

ve kişinin kesin yaşı belirlenmiştir. FG-NET veritabanındaki 802 resim eğitim, 200 resim test aşmasında kullanıldığında 4.37 yıl MAE sonucu elde edilmiştir. Liu vd. (2012) ise bu öznitelikleri kullanarak görüntüleri SVM ile 5 yaş grubuna sınıflandırmıştır. Yaş grupları, bebek (0-2), çocuk (3-10), genç (11-18), yetişkin (19-39) ve orta yaşlı-yaşlı (40-69) olarak belirlenmiştir. FG-NET veritabanından seçilmiş 125 test örneği ile yapılan değerlendirmede %79.2 CA elde edilmiştir.

Wang vd. (2009a) yaş tahmini problemini Bayes kestirim problemi olarak ele almıştır. Yüz görüntüleri 68 belirleyici nokta ile etiketlenerek, AAM öznitelikleri çıkarılmıştır. Bir görüntünün yaşının hesaplanması, sonsal (posterior) olasılığın maksimizasyonu ile formüle edilmiştir. Deneylede FG-NET veritabanından 778 düz bakan yüz görüntüsü seçilmiş, görüntülerin 2/3'ü eğitimde, geri kalanı testte kullanılmış ve 4.45 yıl MAE değeri elde edilmiştir.

Kohli vd. (2013) ise yüz görüntülerinden AAM ile çıkardıkları öznitelikleri, görüntülerin çocuk-genç (0-21) ve yetişkin (22-69) yaş gruplarına sınıflandırılması için kullanmıştır. Sınıflandırma aşamasında tek bir sınıflayıcı yerine, farklı parametre ve ölçütler kullanan sınıflayıcı topluluğu kullanılarak FG-NET veritabanı için %84 CA elde edilmiştir. Her bir yaş grubu içerisinde kesin yaşın tahmini için tek bir yaşlanma fonksiyonu yerine değişik türde yaşlanma fonksiyonları birlikte kullanılmış ve bu fonksiyonlardan elde edilen sonuçların ortalaması kişinin yaşı olarak belirlenmiştir. Deneylede 800 resim eğitim aşamasında 202 resim ise test aşamasında kullanılarak 3.85 yıl MAE ile yaş tahmini gerçekleştirilmiştir.

Bazı çalışmalarda ise yüzün genel öznitelikleri AAM ile çıkarılıp, farklı yöntemlerle üretilen yerel doku öznitelikleriyle birleştirilerek daha etkin yaş tahmini sistemlerinin geliştirilmesi hedeflenmiştir (Chen vd., 2011; Choi vd., 2011; Guo vd., 2011). Chen vd.'nin (2011) çalışmalarında AAM ile çıkarılan genel yüz öznitelikleri, LBP ile çıkarılan yerel doku öznitelikleriyle birleştirilmiştir. Bu öznitelik vektörlerinin belirli seviyelerde korelasyona sahip olması mümkün olduğundan, yaş tahmininde kullanılacak öznitelikler en küçük açısız regresyon (Least Angle Regression) yöntemi ile seçilmiştir. Yaşın tahmini ise SVR ile gerçekleştirilmiştir. PAL veritabanı üzerinde yapılan deneylerde 10-kat çapraz doğrulama yöntemi ile 6.18 yıl MAE sonucu elde edilmiştir. Görüntülerin sadece AAM öznitelikleriyle temsil edilmesi sonucu yöntemin başarısı 6.47 yıl MAE iken, yalnız yerel doku öznitelikleri kullanıldığında sistem başarısı 7.70 yıl MAE'dir. Choi vd. (2011) yaşın tahmininde AAM, LBP ve Gabor özniteliklerinin birleşiminden oluşan karma öznitelikleri

kullanmıştır. Yüzün genel öznelikleri AAM ile, yerel öznelikleri ise LBP ve Gabor filtreleri ile elde edilmiştir. LBP deri bilgisinin çıkarılmasında, Gabor filtreleri ise kırışıklık bölgelerindeki kırışıklık bilgisinin çıkarılmasında kullanılmıştır. Yaşın tahmini ise hiyerarşik bir sınıflayıcı ile gerçekleştirilmiştir. Hiyerarşik sınıflayıcıda, test görüntüleri öncelikle SVM ile dört yaş grubuna sınıflandırılmış, daha sonra o yaş grupları için SVR ile oluşturulan yaşlanma fonksiyonları kullanılarak yaş tahmini yapılmıştır. Deneyler BERC, FG-NET ve PAL veritabanları üzerinde yapılmış ve yalnız genel öznelıklar kullanıldığında sırasıyla 5.46 yıl, 4.53 yıl ve 4.88 yıl MAE sonuçları elde edilmiştir. Genel ve yerel öznelıklar birlikte kullanıldığında ise MAE değerleri sırasıyla 4.68, 4.32 ve 4.65 yıla düşmüştür. Guo vd. de (2011) karma öznelıklarle birlikte hiyerarşik bir sınıflayıcı kullanarak yaş tahmini gerçekleştirmiştir. Görüntülerden AAM ile şekil modeli parametreleri üretilmiştir. Doku öznelıklarının çıkarılmasında, öncelikle görüntüleme Radon dönüşümü uygulanmış, Radon görüntülerindeki frekans bilgisi iki boyutlu DCT ile elde edilmiştir. Sınıflandırma aşamasında yüz görüntüleri sınırları 0-14, 15-29, 30-49 ve 50-69 olarak belirlenmiş yaş gruplarına üç SVM sınıflayıcısı ile sınıflandırılmıştır. Burada görüntüler aşamalı olarak önce 15 yaşa, daha sonra 30 yaşa ve en son 50 yaşa göre sınıflandırılmaktadır. 15 yaşa göre ve 50 yaşa göre sınıflandırma yapan sınıflayıcılarda şekil öznelıkları kullanıldığında %86.5 ve %84.6 CA elde edilmiştir. 30 yaşa göre sınıflandırma yapan sınıflayıcı ise doku öznelıkları kullanıldığında %98.8 CA ile en iyi sonucu vermiştir. Yaş grubu belirlendikten sonra her yaş grubu içerisinde SVR ile yaş tahmini gerçekleştirilmiştir. Kesin yaşın tahmininde 0-14 ve 15-29 yaş grupları için şekil öznelıkları, diğer yaş grupları içinse şekil ve doku öznelıklarının birleşimi kullanılmıştır. FG-NET veritabanındaki görüntülerden 802'si eğitim aşamasında, 200'ü test aşamasında kullanıldığında 4.18 yıl MAE sonucu elde edilmiştir.

Yan vd. (2007a), yaş tahmini için regresyon probleminin çözümünde yarı-kararlı programlama (Semi-Definite Programming) yöntemini kullanmıştır. Burada kesin olmayan pozitif etiketlere sahip eğitim örneklerinden regresyon fonksiyonunun otomatik olarak (Regression from Uncertain Nonnegative Labels- RUN) öğrenilmesi hedeflenmiştir. FG-NET veritabanındaki görüntüler 200 AAM parametresi ile temsil edilmiş, YGA veritabanındaki görüntüler ise göz konumlarına göre hizalanarak 64x64 boyutuna ölçeklenerek piksel parlaklıkları kullanılmıştır. FG-NET veritabanında LOPO yöntemi ile 5.78 yıl MAE sonucu elde edilmiştir. YGA veritabanında ise, 1000 resim eğitim, 3000 resim test için kullanıldığında, kadın ve erkek yüzleri için sırasıyla 9.79 ve 10.36 yıl MAE

sonucuna ulařılmıştır. Yarı-kararlı programlama verimli bir araç olmasına rağmen hesaplama yükü oldukça fazladır. Eğitim kümesinin boyutu büyük ise yarı-kararlı programlama ile sonuç üretmek zor olabilir. Bu nedenle Yan vd. (2007b) regresyon problemini çözmek ve optimizasyon sürecini hızlandırmak için beklenti-enbüyültme algoritmasını kullanmış ve YGA veritabanı için 6.95 yıl, FG-NET veritabanı için 5.33 yıl MAE sonucuna ulařmıştır.

Yaş verisi arasındaki gizli anlamsal benzerliğin keşfedilmesi için bir uzaklık ölçütü öğrenme yöntemi, Xiao vd. (2009) tarafından araştırılmıştır. Öğrenilecek uzaklık ölçütünün hedefi, yerel komşulukların korunmasını, yakın olmayan veriler arasındaki uzaklığın arttırılmasını sağlamaktır. Giriş verisinin yapısı ya da dağılımı hakkında herhangi bir varsayım olmaksızın bu işlemin yarı-kararlı programlama ile yapılabileceği gösterilmiştir. Bunun yanında düşük seviyeli öznitelik uzayı yüksek seviyeli anlam uzayına lineer dönüşüm ile haritalanabilmektedir. Yaşın tahmini ise *k*NN regresyon ile gerçekleştirilmiştir. FG-NET veritabanından AAM ile çıkarılan öznitelikler için LOPO stratejisi ile yapılan deneylerde, rasgele seçilmiş 400 eğitim örneğinden öğrenilen uzaklık ölçütü ile 4.93 yıl MAE değeri elde edilmiştir.

Long (2009) ise, regresyon problemleri için genel bir uzaklık ölçütünün öğrenilmesinde, uzaklık ölçütünün güvenilirliğini arttırmak için veri ile birlikte yaş etiketlerinin kullanılmasını önermiştir. Bir optimizasyon probleminin çözülmesi ile öğrenilen ölçütü, verinin dağılımı ve yapısı hakkında herhangi bir önbilgiye sahip olunmadan, az sayıdaki örnekten verideki esas değişim eğilimi bulunmaktadır. Ek olarak test verisi basit lineer bir dönüşüm ile bu ölçüte iz düşürülebilmektedir. Çalışmada 300 örnekle öğrenilen ölçüt, Gauss süreçli regresyon (Gaussian Process Regression) ile kullanılmıştır. FG-NET veritabanındaki görüntüler 200 AAM parametresi ile ifade edildiğinde, LOPO yöntemi kullanılarak 5.08 yıl MAE sonucu elde edilmiştir.

- AGES yöntemine dayalı yaş tahmini çalışmaları: AGES ile öznitelik çıkarıp yaş tahmini gerçekleştiren çalışma sayısı, yöntemin uygulanmasındaki zorluklardan dolayı azdır. Geng vd. (2006) tarafından önerilen yöntem, öğrenme ve yaş tahmini aşamalarından oluşmaktadır. Öğrenme aşamasında her bir yüz görüntüsü önce Lanitis vd.'nin (2004) çalışmalarına benzer şekilde AAM yöntemi ile kodlanmıştır. Fakat AGES yönteminin farkı, yaşlanma örüntüsünü ifade etmek için aynı kişinin farklı yaşlardaki görüntülerinin birlikte kullanılmasıdır. Lanitis vd. (2004) görüntüleri kodlamada 50 AAM parametresi kullanmış iken, Geng vd. (2006) her bir yüz görüntüsünü kodlamak için 200 AAM

parametresi kullanmıştır. Yaşlanma örüntüsü alt uzayının öğrenilmesinde, verinin dağılımını olabildiğince yakalayan bir alt uzay gösterimi elde etmek için PCA yöntemi kullanılmaktadır. Fakat her yaşlanma örüntüsü içinde bazı eksik görüntüler mevcuttur. Bu görüntülerin tamamlanmasında beklenti enbüyültme benzeri tekrarlamalı bir öğrenme yöntemi kullanılmaktadır. Eksik yaş görüntüleri için başlangıç değerleri, mevcut yüz görüntülerinin ortalamasıdır. Öğrenme algoritması ise eldeki yaş görüntüleri ve yeniden üretilen yüz görüntüleri arasındaki hatayı küçültmeyi hedeflemektedir. Yaşın tahmin edilmesi aşamasında test görüntüsü için eğitim kümesinde uygun bir yaşlanma örüntüsünün ve bu yaşlanma örüntüsünde uygun bir pozisyonun bulunması gerekir. Bulunan bu pozisyon, test görüntüsü için tahmin edilen yaş olarak belirlenir. Bu amaçla test görüntüsü yaşlanma örüntüsündeki tüm mümkün pozisyonlara yerleştirilerek, yeniden üretme hatası en küçük olan pozisyon seçilir. Test görüntüsü uygun olmayan bir pozisyona yerleştirildiğinde yeniden üretilen yüzlerin hayalete benzeyen çarpık yüzler olduğu görülmüştür. AGES yöntemini değerlendirmek için FG-NET veritabanı kullanılmış, LOPO yöntemi ile 6.77 yıl MAE rapor edilmiştir.

Geng vd. (2007) diğer bir çalışmalarında ise, yaşlanma örüntüsü alt uzayının öğrenilmesinde LDA kullanmış ve bu yöntemin FG-NET ve MORPH veritabanlarındaki yaş tahmini başarımını değerlendirmiştir. MORPH veritabanı sistemin eğitiminde yetersiz olduğu için, sistemin eğitimi FG-NET veritabanı kullanılarak gerçekleştirilmiştir. FG-NET veritabanı sadece Kafkas kökenli kişilerin resimlerini içerdiğinden, MORPH veritabanındaki Kafkas kökenli kişilere ait 433 resim seçilerek test aşamasında kullanılmıştır. FG-NET veritabanında LOPO yöntemi ile 6.22 yıl MAE elde edilirken, MORPH veritabanında ise 8.07 yıl MAE başarısı sağlanmıştır. Standart AGES ile MORPH veritabanı için MAE değeri 8.83 yıldır.

- Topolojik uzaya gömmeye dayalı yaş tahmini çalışmaları: Topolojik uzaya gömmeye dayalı yaş tahmini çalışmaları, her birey için özel bir yaşlanma örüntüsü öğrenmek yerine, farklı yaşlardaki birçok kişinin görüntüsünden genel bir yaşlanma örüntüsü öğrenmeyi hedeflemektedir. Bu alanda çok çeşitli çalışmalar yapılmış ve yöntemler geliştirilmiştir. Ueki vd. (2006), yüz görüntülerini yaş gruplarına sınıflandırma probleminin çözümünde, iki boyutlu LDA (2-Dimensional LDA - 2DLDA) ve LDA kullanarak, küçük boyutlu bir öznitelik uzayı üretmiştir. Daha sonra her yaş grubu için, beklenti enbüyültme algoritmasını kullanarak bir Gauss modeli oluşturmuştur. Yaş grubuna sınıflandırma işlemi ise, test görüntüsünün tüm Gauss modellerine uydurulması ve

olasılıkların karşılaştırılması ile gerçekleştirilmiştir. Deneylede, yaşları 3 ile 85 arasında değişen 5500 farklı Japon örnekten alınan, 12008 kadın ve 14214 erkek görüntüsü içeren WIT-DB (Waseda Human-Computer Interaction Technology DataBase) veritabanı kullanılmıştır. Görüntülerdeki yüz bölgesi seçilerek 32x32 boyutuna ölçeklenmiştir. Veritabanındaki 6000 kadın ve 6000 erkek görüntüsü eğitim aşamasında, geri kalan görüntüler test aşamasında kullanıldığında, 5-yıl aralıklı yaş grupları için kadın yüzleri %43, erkek yüzleri ise %50 CA ile sınıflandırılmaktadır. 10-yıl aralıklı yaş gruplarına sınıflandırmada, kadın ve erkekler için sırasıyla %63 ve %72, 15-yıl aralıklı yaş gruplarına sınıflandırmada ise %74 ve %82 CA elde edilmiştir. Çalışma sonuçları, öznelilik çıkarma yöntemi olarak önerilen 2DLDA+LDA'nın, PCA ve LDA'ya göre daha iyi olduğunu göstermektedir.

Fu vd. (2007) çalışmalarında verilerin küçük boyutlu uzaya gömülmesinde, PCA, NPP, LPP, OLPP yöntemlerini kullanmıştır. Görüntülerin daha küçük boyutlu bir uzayda gösterimi elde edildikten sonra yaşın tahmini MLR problemi olarak tanımlanmış ve verilere karesel bir yaşlanma fonksiyonu uydurulmuştur. Deneyle, yaş aralığı 0-93 arasında değişen, 800'ü kadın, 800'ü erkek olmak üzere 1600 farklı kişiden alınmış 8000 resimden oluşan YGA veritabanında yapılmıştır. Görüntülerdeki yüz bölgesi belirlenerek kesilmiş ve 60x60 boyutuna ölçeklenmiştir. Görüntülerin yarısı eğitim aşamasında kalanı test aşamasında kullanıldığında, OLPP yöntemiyle kadınlar ve erkekler için sırasıyla yaklaşık olarak 7.8 yıl ve 8.0 yıl MAE sonuçları elde edilmiştir. Sonuçlar OLPP'nin LPP'ye göre daha kararlı ve düşük varyansa sahip olduğunu, bu nedenle yaş topolojik uzayını diğer yöntemlere göre daha iyi ifade ettiğini göstermiştir. Fu ve Huang (2008), aynı zamanda konformal gömme analizinin (Conformal Embedding Analysis) yaş tahmininin doğruluğunu arttırmak için kullanılabileceğini göstermiştir. Burada verilerin küçük boyutlu uzaya gömülmesinde sınıflar arasındaki ayırt edici özneliliklerin ortaya çıkarılması için LDA'dan yola çıkılarak, aynı sınıf içerisindeki örneklerin birbirine yakınlığı ve farklı sınıf içerisindeki örneklerin birbirine yakınlığı iki farklı ağırlık matrisi ile belirlenmiştir. Yöntemde aynı sınıf içindeki örnekler için G_s ve farklı sınıftaki örnekler için G_d grafları oluşturulmuştur. i ve j düğümleri arasında bir bağlantı oluşması için bu örneklerin birbirinin k komşusundan biri olması gerekmektedir. Oluşan her bağlantı için, örnekler arasındaki uzaklığa göre bir ağırlık değeri hesaplanarak W_s ve W_d ağırlık matrisleri üretilmiştir. İki örnek arasındaki uzaklık ise kosinüs açısı ile hesaplanmıştır. Verilerin daha küçük boyutlu alt uzay gösterimi elde edildikten sonra yaşın tahmini yine

karesel bir yaşlanma fonksiyonu ile gerçekleştirilmiştir. Bu yöntemle YGA veritabanındaki kadın ve erkek görüntüleri için yaklaşık olarak 5.5 yıl ve 6.0 yıl MAE sonuçları elde edilmiştir.

Guo vd. (2008a) yaş tahmini problemini hem sınıflandırma hem de regresyon problemi şeklinde ele alarak, hangisinin yaş tahmininde daha iyi olduğu sorusuna cevap aramıştır. FG-NET veritabanındaki resimler 200 AAM parametresi ile ifade edilmiş, YGA veritabanındaki resimler ise göze göre hizalanıp 60x60 boyutuna ölçeklenmiştir. OLPP ile küçük boyutlu gösterimi elde edilen veriler üzerinde SVM ile sınıflandırma, SVR ile regresyon yapılmıştır. SVM ile yapılan sınıflandırmada FG-NET veritabanında LOPO yöntemi ile 7.16 yıl, YGA veritabanında 4-kat çapraz doğrulama yöntemi ile kadın ve erkek örnekler için sırasıyla 5.55 yıl ve 5.52 yıl MAE elde edilmiştir. SVR ile yapılan regresyon analizinde ise MAE'ler FG-NET veritabanında 5.16 yıl, YGA veritabanında kadın ve erkek örnekler için sırasıyla 7.00 yıl ve 7.47 yıldır. Deneylerden elde edilen sonuçlara göre SVM, YGA veritabanında SVR'ye göre daha iyi sonuçlar verirken, FG-NET veritabanında daha kötü sonuçlar vermektedir. Buradan, sınıflandırma tabanlı yaş tahmininin, regresyon tabanlı yaş tahminine göre, farklı durumlarda daha iyi ya da daha kötü sonuçlar verebileceği sonucuna ulaşılmıştır. SVR ile elde edilen yaş tahmini sonuçları incelendiğinde ise, yöntemin genel yaş trendini tahmin ettiği fakat yaşları doğru bir şekilde tahmin edemediği görülmüştür.

Sistem başarımını arttırmanın en iyi yolunun, sınıflandırma ve regresyon yöntemlerinin iyi yönlerini birleştirmek olduğunu düşünen Guo vd. (2008b), yerel olarak ayarlanabilen dayanıklı regresyon (Locally Adjusted Robust Regressor - LARR) olarak adlandırdıkları yöntemi önermiştir. LARR'daki temel düşünce öncelikle eğitim kümesindeki tüm yaş verisini kullanarak SVR ile genel bir regresyon yapmaktır. Daha sonra bu regresyon sonucu merkezde olacak şekilde yerel bir yaş aralığında, yukarı ve aşağı yönde farklı yaş değerlerini tarayarak daha iyi bir sonuca ulaşmaktır. Bu kısımda SVM kullanılmaktadır. Yöntem yaş tahmini performansını önemli derecede arttırmaktadır. Bu birleşim ile YGA veritabanında kadınlar için 5.25 yıl erkekler için 5.30 yıl, FG-NET veritabanında ise 5.07 yıl MAE başarı elde edilmiştir.

LARR yöntemi, sınıflayıcı için yerel arama aralığını otomatik olarak belirleyememekte, deneme yanılma yöntemi ile farklı aralıkları tarayıp, kullanıcının sonuçlardan en iyisini seçmesini beklemektedir. Yerel arama aralığının veriye göre otomatik olarak belirlenmesi amacıyla, Guo vd. (2008c) olasılıksal birleştirme yaklaşımını

(Probabilistic Fusion Approach - PFA) önermiştir. PFA'daki düşünce regresyon ve sınıflandırma için üretilen istatistiksel olasılıkların art arda birleştirilmesine dayalı bir karar kuralı oluşturmaktır. Bu amaçla birinci aşamada kullanılan SVR'nin sonuçları, üretilen değer merkezde olacak şekilde bir düzgün dağılım ile ifade edilmiştir. Böylece her biri eşit olasılığa sahip sonlu sayıda yaş etiketi elde edilmiş olur. Bu aralık içerisinde SVM ile yapılan sınıflandırmada ise her yaş etiketi için bir olasılık değeri üretilmiştir. Bu olasılık değerleri, ikili karşılaştırmaların meydana gelme sayılarının toplanması ile hesaplanmıştır. Bu olasılıklı sonuçların çarpılması ile elde edilen en büyük değere göre yaş belirlenmiştir. PFA yöntemi ile YGA veritabanında kadın ve erkekler için sırasıyla 5.11 ve 5.12 yıl, FG-NET veritabanında ise 4.97 yıl MAE sonucuna ulaşılmıştır.

Ueki vd. (2008) yüz görüntülerinden yaşın tahmin edilmesi amacıyla, LPP'ye dayalı yeni bir boyut küçültme yöntemi önermiştir. Boyut küçültme yöntemlerinden PCA ve LPP danışmansız öğrenme algoritmalarıdır. Çünkü bu yöntemlerde görüntülerin sınıf etiketleri dikkate alınmamaktadır. Geometrik yapının yanında sınıf etiketlerinin de dikkate alınması ile performans artışı sağlanabilir. Bu amaçla LPP yönteminde oluşturulan ağırlık matrisinde, sadece birbirine yakın sınıflarda olan örneklere ağırlık ataması yapılarak yöntemin sınıflar arasındaki ayırıcı gücü artırılabilir. Bu yöntem yerel ölçeklemeli (local scaling) LPP olarak adlandırılmıştır. Diğer yandan sınıf uzaklığı ağırlıklı (class distance weighted) LPP yönteminde, yakın sınıf etiketlerine sahip olan örneklere daha büyük ağırlıklar verilerek denetimli bir öğrenme algoritması oluşturulmuştur. Deneysel olarak 14440 Japon kökenli yüz görüntüsünün parlaklık değerleri yerine gradyan yönü gösterimi kullanılmıştır. Veritabanının %10'u ile eğitilen yöntemin yaş tahminindeki başarısı ise k NN sınıflayıcısı kullanılarak belirlenmiştir. Herhangi bir test örneğinin $k=16$ en yakın komşusunun yaşlarının ortalaması o test örneğinin yaşı olarak hesaplanmıştır. Elde edilen sonuçlar, sınıf uzaklığı ağırlıklı LPP yönteminin, kadınlar için 6.54 yıl ve erkekler için 5.92 yıl MAE değerleriyle, PCA, LPP ve yerel ölçeklemeli LPP yöntemlerine göre çok daha iyi olduğunu göstermiştir.

Ma vd. (2008), ise yerel Fisher ayrıştırma analizinden (Local Fisher Discriminant Analysis) esinlenerek, sınıf uzaklığına dayalı ayrıştırma analizi (Class Distance Based Discriminant Analysis) olarak adlandırdıkları yeni bir yöntem önermiştir. Yöntemde sınıflar arası dağılım matrisi oluşturulurken, yakın sınıflardaki örnek çiftlerine daha büyük ağırlıklar verilmiştir. Çünkü yakın sınıflardaki örnekler birbirine daha çok benzemekte ve yanlış sınıflandırılan örnekler genellikle yakın sınıflara sınıflandırılmaktadır. Sınıf içi

dağılım matrisinin oluşturulmasında ise tüm örnek çiftleri kullanılmıştır. Aynı sınıfta bulunan örnek çiftleri arasındaki Öklid uzaklığı ne kadar büyük ise o örnek çiftlerine o kadar küçük ağırlıklar verilmiştir. Diğer yandan farklı sınıflarda bulunan örnek çiftleri için sınıf uzaklığı ne kadar büyük ise o kadar küçük ağırlık ataması yapılmıştır. Bu şekilde sınıf içi yerel yapının korunması sağlanmıştır. Giriş yüz görüntüleri 32x32 boyutuna ölçeklenip açıklanan yöntemle alt uzaya gömülmüş ve k NN ile sınıflandırma gerçekleştirilmiştir. 25-40 yaş aralığında 1600 resimden oluşan bir veritabanı üzerinde yaptıkları deneylerde, 3-kat çapraz doğrulama yöntemi ile 4.37 yıl MAE değeri elde edilmiştir.

Geng ve Miles (2009), yaş görüntülerini hem kimlik hem de yaşa bağlı olarak, 3. derece tensör şeklinde organize etmiştir. Veri toplamadaki zorluklar nedeniyle eğitim kümesindeki her bir kişi için yaşlanma örüntüsü eksik kalmaktadır. Bu eksik değerlere sahip vektörler üzerinde, çoklu doğrusal alt uzay analizi (Multilinear Subspace Analysis) algoritmalarıyla, yaşlanma örüntüsü tekrarlamalı olarak öğrenilebilir ve verilen bir test görüntüsünün yaşının tahmininde kullanılabilir. Tensörler bir dizi vektör uzayında çoklu doğrusal iz düşümlerdir. Bunlar, sabitler (0.derece tensör), vektörler (1.derece tensör) ve matrislerin (2.derece tensör) yüksek derecede genelleştirilmiş halidir. Bu çalışmada 3 boyutlu uzaydaki eksenler, kişi, yaş ve öznitelik olarak ifade edilebilir. FG-NET veritabanında yapılan deneylerde yüz öznitelikleri, 200 AAM parametresi ile ifade edilmiş ve LOPO yöntemi ile 5.36 yıl MAE ile yaş tahmini gerçekleştirmiştir.

Yan vd. (2009) yaş görüntülerinin kişiden bağımsız gösterimi için eşzamanlı alt topolojik uzaya gömme (Synchronized Submanifold Embedding) yöntemini önermiştir. Yöntem yaş tahmininde genelleştirme imkânını yükseltmek için, hem yaş etiketlerini hem de kişinin poz bilgisini kullanmaktadır. Farklı kişilerden alınmış benzer pozlardaki örneklerin, küçük boyutlu uzaydaki gösterimlerinin de benzer olması gerekir. Böylece farklı nesnelere ait alt topolojik uzayları, bu veri çiftlerinin hizalanması ile eşzamanlı hale getirilebilir. Yöntemin temel amacı, farklı kişilere ait alt topolojik uzayların kesin poz etiketlerine bağlı olarak hizalanabildiği, küçük boyutlu gösterimin elde edilebilmesidir. FG-NET veritabanındaki görüntüler 200 AAM parametresi ile ifade edilmiştir. Kişilerin poz bilgisi olarak kafanın eğimi, sapma açısı kullanılmıştır. Veritabanındaki resimler 10 yaş aralıklı 7 yaş grubuna ayrılmış ve her bir yaş grubu için ayrı ayrı sonuçlar üretilmiştir. Bu sonuçların ortalaması alındığında yöntem FG-NET veritabanında LOPO yöntemi ile 5.21 yıl MAE başarı sağlamıştır.

Lu ve Tan (2010; 2013) yüz görüntülerinin küçük boyutlu gösterimini elde etmek için normalliğin korunması (Ordinary Preserving) topolojik uzayını kullanmıştır. Mevcut yöntemler öznelik çıkarırken, 20 ve 25 yaşlarındaki iki resmin farkı ile 20 ile 50 yaşlarındaki iki resmin farkını eşit şekilde değerlendirmektedir. Bunu önlemek için LDA ve marjinal Fisher analizi (Marginal Fisher Analysis -MFA) örnek alınarak normalliğin korunmasına dayalı LDA ve MFA yöntemleri önerilmiştir. Yöntemde sınıf içi ve sınıflar arası dağılımlar çıkarılırken, farklı yaş etiketlerine sahip örneklerin farklı etkiye sahip olduğu ağırlık matrisleri üretilmiştir. Öznelik çıkarımı yapıldıktan sonra yaş tahmini, karesel fonksiyon kullanan MLR problemi olarak tanımlanmıştır. MORPH veritabanından seçilen beyaz ve siyah ırktan 20000 kişi için deneyler yapılmıştır. Görüntüler göze göre hizalanıp 32x32 boyutuna ölçeklenmiştir. Beyaz kökenli örneklerin yaş aralığı 21-70, Siyah kökenli örneklerin yaş aralığı ise 16-77'dir. Örneklerden 5000'i eğitimde diğerleri test aşamasında kullanılmıştır. Normalliğin korunmasına dayalı LDA yöntemi beyaz ve siyah kökenli örnekler için sırasıyla 5.62 yıl ve 4.32 yıl MAE sonucu üretirken, normalliğin korunmasına dayalı MFA yöntemi 5.24 yıl ve 4.18 yıl MAE sonucunu vermiştir. Lu ve Tan (2011) diğer bir çalışmada yüz görüntülerinden çıkardıkları şekil ve parlaklık özneliklerinin birleştirilmesinde kanonik korelasyon analizini (Canonical Correlation Analysis) kullanmayı önermiştir. Yöntem çok boyutlu iki değişken arasındaki doğrusal ilişkinin ölçülmesini sağlamaktadır. Öznelikler birleştirildikten sonra öznelik vektörünün boyutu PCA ve LDA ile küçültülmüş, MLR ile yaş tahmini yapılmıştır. Şekil öznelikleri yüz üzerindeki 68 belirleyici noktanın koordinatlarıdır. Doku bilgisi ise ortak şekle eğriltelen görüntülerin piksel parlaklık değerleridir. Bu öznelik vektörleri tek başlarına ve birleştirilerek kullanıldığında sistemin yaş tahmini performansı değerlendirilmiş ve birleştirilmiş öznelik vektörünün yaş tahmininde daha başarılı olduğu görülmüştür. FG-NET veritabanı kullanılarak yapılan deneylerde sistemin yaş tahmini başarısı, birleştirilmiş öznelik vektörüne PCA uygulandığında 6.20 yıl, LDA uygulandığında ise 5.75 yıl MAE'dir.

Fang vd. (2010), öznelik tabanlı ayrıştırıcı altuzay gösterimini 2. dereceden regresyon fonksiyonu ile modelleyerek yaş tahmininde kullanmıştır. Yüz görüntüleri ortak bir şekle dönüştürüldükten sonra, doku özneliklerini çıkarmak için LBP kullanılmıştır. LBP histogramlarında uzaysal bilgi kaybedildiğinden 2 boyutlu LBP görüntüleri doğrudan ayırt edici alt uzaya iz düşürülmüştür. Bu aşamada LBP görüntülerindeki bazı gürültüleri yok etmek ve veri boyutunu küçültmek için PCA uygulanmıştır. Bu verilere OLPP

uygulanmış ve elde edilen küçük boyutlu öznitelikler 2. dereceden regresyon fonksiyonu ile modellenmiştir. Deneylede, FG-NET veritabanından seçilen 0-30 yaş aralığındaki 855 resim için LOPO stratejisi kullanılarak NN ile 4.27 yıl, 2. dereceden regresyon ile 3.64 yıl MAE elde edilmiştir.

Tonchev vd. (2011) yüz görüntülerini, sınırları 0-16 ve 17-69 olarak belirlenen çocuk ve yetişkin yaş gruplarına sınıflandırmak amacıyla, veri boyutunu, PCA ve spektral regresyon kullanarak indirgemıştır. SVM ile yapılan sınıflandırma sonucunda FG-NET veritabanı için LOPO yöntemiyle %77.73 CA elde edilmiştir. Luu vd. (2011a) ise karma yüz özniteliklerini ve doğrusal olmayan boyut indirgeme yöntemi olan çekirdek spektral regresyonu (Kernel Spectral Regression) kullanarak gelişmiş bir yaş tahmini yöntemi önermiştir. Önışleme aşamasında kırışıklıklar, altörnekleme dışı hat belirleme dönüşümü (nonsampled contourlet transform) ile belirginleştirilerek genç-yaşlı ayrımının yapılması sağlanmıştır. Daha sonra düzgün yerel üçlü örüntülerle (uniform local ternary pattern) çıkarılan yerel öznitelikler, AAM ile çıkarılan genel özniteliklerle birleştirilerek, karma öznitelikler oluşturulmuştur. Sınıf içi uzaklıkların azaltılması, sınıflar arası uzaklıkların artırılması ve öznitelik vektör boyutunun küçültülmesi için çekirdek spektral regresyon kullanılmıştır. Yaşın tahmini aşamasında ise yüz görüntüleri öncelikle SVM ile iki yaş grubuna sınıflandırılmış, daha sonra her yaş grubu altında eğitilmiş SVR'lerle kesin yaş belirlenmiştir. FG-NET veritabanındaki 802 görüntü eğitim, 200 görüntü test için kullanıldığında 4.22 yıl MAE elde edilirken, LOPO değerlendirme yöntemi ile 6.17 yıl MAE sonucuna ulaşılmıştır. PAL veritabanından seçilen 293 eğitim, 150 test örneği için 7.17 yıl MAE elde edilmiştir.

Chao vd. (2013) yüz öznitelikleri ve yaş etiketleri arasındaki ilişkiyi daha iyi bir şekilde belirlemek amacıyla, uzaklık ölçütü öğrenme (distance metric learning) ve boyut indirgeme yöntemlerini birleştirmiştir. AAM ile çıkarılan özniteliklerin düzenlenmesi için, denetimli bir uzaklık ölçütü öğrenme algoritması olan anlamlı bileşen analizinin (Relevant Component Analysis), yaş etiketlerine duyarlı olan (label sensitive) yeni bir çeşidi önerilmiştir. Boyut indirgeme aşamasında ise yine yaş etiketlerine duyarlı LPP ve MFA yöntemleri geliştirilmiştir. Kişini yaşı ise k NN ve SVR yöntemlerinin birleştirilmesi ile tahmin edilmiştir. Burada öncelikle test örneğinin k en yakın komşusu bulunmuş, daha sonra bu örnekler üzerinde SVR ile yaş tahmini yapılmıştır. FG-NET veritabanı üzerinde 4-kat çapraz doğrulama testi uygulandığında, yaş etiketlerine duyarlı LPP ve MFA yöntemleriyle sırasıyla 4.38 yıl ve 4.44 yıl MAE sonucuna ulaşılmıştır.

Zhan vd. (2011) birbiriyle çakışmayan alt uzay gösterimini öğrenmek için, negatif olmayan matris çarpanlarına ayırma (non negative matrix factorization) yöntemini kullanmıştır. Çalışmada yaşlanmaya bağlı görünüş değişikliklerini vurgulamak için her bir yaş etiketi ya da yaş grubu için ayrı bir alt uzay öğrenilmektedir. Herhangi bir test görüntüsünün yaş ya da yaş grubu ise, örneğin bu alt uzaylara iz düşürülmesinden sonra, yeniden oluşturulma hatalarına bağlı olarak belirlenmektedir. FG-NET veritabanındaki görüntülerin sınırları 0-5, 6-11, 12-17, 18-29 ve 30-44 olarak belirlenen yaş gruplarına sınıflandırılmasında, 50 kişiye ait görüntüler eğitimde, 32 kişiye ait görüntüler test aşamasında kullanarak yaklaşık olarak %58 CA elde edilmiştir. 0-19, 20-29, 30-39, 40-69 yaş grupları içine elde edilen CA ise %60.9'dur.

Wu vd. (2012), çalışmalarında yüzün şekil bilgisini kullanan bir yaş tahmini yöntemi önermiştir. Yüzde yaşlanmaya bağlı şekil değişiklikleri, yüz özniteliklerinde hafif sapmalar ve yüz çevresi şeklinde aşamalı değişimler olarak kendini göstermektedir. Bu nedenle yüz şeklini ifade eden belirleyici nokta koordinatları, Grassman topolojik uzayında noktalar olarak modellenmiştir. Bu topolojik uzayda yaşın tahmini regresyon problemi olarak ele alınmış ve SVR ile yaş tahmini gerçekleştirilmiştir. FG-NET veritabanında yapılan deneylerde LOPO değerlendirme yöntemi ile 5.89 MAE sonucu elde edilmiştir.

- Doku özniteliklerine dayalı yaş tahmini çalışmaları: Yüz görüntülerinden dokuya dayalı öznitelikleri çıkararak yaş tahmini yapan çalışmalarda çok çeşitli yöntemler kullanılmıştır. Bazı çalışmalarda tek bir doku özneliği kullanılırken bazılarında birkaç farklı yöntemle çıkarılan doku öznitelikleri birleştirilerek yaş tahmini gerçekleştirilmiştir. Doku özniteliklerini, şekil öznitelikleri ile birleştirerek yaş tahmini gerçekleştiren çalışmalar da mevcuttur.

Hayashi vd. (2002) yüz görüntülerinden sayısal şablonlu Hough dönüşümü (Digital Template Hough Transform) ile çıkardıkları kırışıklık bilgisini kullanarak bir yaş tahmini sistemi oluşturmuştur. Sistemde 10 yaş aralıklı çok-gruplu sınıflandırma şeması üzerinden yaşın tahmin etmesi hedeflenmiştir. Bu nedenle her bir yaş grubu için kırışıklık bilgisi üretilerek, bütün yaş gruplarının kırışıklık yoğunluğunu içeren bir arama tablosu (LookUp Table) elde edilmiştir. Sisteme sunulan bir kişinin yaş grubunun belirlenmesi aşamasında, test görüntüsünde tespit edilen kırışıklıklar afin dönüşüm ile ortalama insan yüzüne iz düşürülmüş ve kırışıklık yoğunluğuna göre arama tablosu ile karşılaştırma yapılarak karar verilmiştir. 15-64 yaş aralığında 150'si kadın, 150'si erkek olmak üzere 300 Japon kökenli kişinin görüntülerinden oluşan HOIP (Human and Object Interaction Processing

Organization) veritabanında yapılan deneylerde, kadın ve erkekler için yaşlanma örüntüsü farklı olduğundan, öncelikle cinsiyet belirleme işlemi uygulanmıştır. Böylece yaş tahmini performansının artırılması hedeflenmiştir. Önerilen yöntemin cinsiyet belirlemede %83, yaş tahmininde ise %27 başarılı olduğu bildirilmiştir.

Iga vd. (2003) yaşın ve cinsiyetin belirlenmesinde yüz görüntülerinden çıkardıkları 6 çeşit özneliği kullanmıştır. Özneliklerden birincisi, 37 noktadan oluşan bir grafa oturtulan yüz resmi üzerindeki her bir nokta etrafındaki yoğunluğu ve tekrarlamaları ölçen Gabor öznelikleridir. Gabor öznelikleri 37 noktaya 8 yön x 5 ölçek olmak üzere 40 Gabor filtresi uygulanarak elde edilmiştir. Diğer öznelikler sırasıyla, 37 noktanın koordinatları kullanılarak hesaplanan ve yüzdeki yerleşimi ifade eden, göz genişliği, gözler arası mesafe, bölgeler arası bağıl uzaklıklar gibi geometrik öznelikler, yüzdeki leke ve kırıklılık bilgisini içeren doku öznelikleri, yanak ve dudak bölgesindeki renk bilgisi, saç bilgisi ve bıyık bölgesinden yine Gabor filtreleri ile çıkarılan doku öznelikleridir. Sınıflandırma aşamasında önce cinsiyet daha sonra yaş belirlenmiştir. HOIP veritabanındaki görüntüler için cinsiyet belirlemede SVM sınıflayıcısı ile %93.1 CA elde edilmiştir. Yaş tahmini için veritabanındaki görüntüler 10 yaş aralıklı 5 gruba ayrılmış, cinsiyete dayalı iki SVM sınıflayıcısı oluşturulmuştur. Sistemin yaş grubuna sınıflandırma için CA'sı %58.4'tür.

Fukai vd. (2007) yüz görüntülerini göz merkezlerine göre hizalayarak normalize edip 180x225 boyutuna ölçeklemiş ve medyan filtresi ile gürültüleri azaltmıştır. Görüntülerdeki öznelikler hızlı Fourier dönüşümü (Fast Fourier Transform) ile çıkarılmış, öznelik seçimi genetik algoritma ile yapılmıştır. Yaşın tahmini ise HOIP veritabanı üzerinde, denetimli özdüzenleyici haritalar ile gerçekleştirilerek 6.8 yıl MAE sonucu elde edilmiştir. Fukai vd. (2010) daha sonraki bir çalışmalarında yaşın ve cinsiyetin belirlenmesi için normalize edilmiş yüz görüntülerinden çeşitli özneliklerin çıkarılması yöntemini önermiştir. Bunlar göz alanı, burun ağız genişliği, yüz çevresi gibi şekil özneliklerini, yatay olarak yüz görüntüsünün gri seviye değişimlerini içeren frekans özneliklerini, kırıklılık bilgisini içeren deri özneliklerini ve yanak ve dudak bölgesinden elde edilen renk özneliklerini içermektedir. Çıkarılan öznelikler NN'lerin eğitiminde kullanılarak yaşın ve cinsiyetin tahmini gerçekleştirilmiştir. HOIP veritabanındaki 252 kişi için LOPO stratejisi kullanılarak yapılan deneylerde 4.65 yıl MAE sonucu elde edilmiştir.

Txia ve Huang (2009), yaşla ilgili özneliklerin çıkarılacağı bölgelerin belirlenmesinde AAM kullanan yeni bir yaş tahmini yöntemi önermiştir. Yöntemde

öncelikle Adaboost ile göz konumları bulunmuş ve yüz görüntüleri göz merkezlerine göre normalize edilmiştir. AAM modeli, yüz üzerindeki 28 belirleyici noktanın konumlandırılmasında kullanılmıştır. Bu noktaların konumları kullanılarak alın, göz altı, göz kenarları, ağız kenarları, çene bölgeleri belirlenmiştir. Bu bölgelere Sobel filtresi uygulanarak kenar bilgisi çıkarılmıştır. Her bölgenin ortalama kenar parlaklık değeri Gauss dağılımı ile modellenerek kırıksıklık öznitelikleri üretilmiştir. Kırıksıklık bilgisinin dışında saç bölgesinden çıkarılan saç rengi de yaş özniteliği olarak kullanılmıştır. MORPH veritabanındaki Kafkas kökenli kişiler için sınırları 21-30, 31-40, 41-50 ve 51-60 olarak belirlenen 4 yaş grubu oluşturulmuştur. Sınıflandırma SVM ile gerçekleştirilmiştir. Her sınıf için 30 görüntü kullanılarak eğitilen sistem, 131 görüntü ile test edildiğinde CA'sının %72.52 olduğu görülmüştür.

Chen vd. (2010) görüntü tabanlı bir yaş grubu sınıflandırma yöntemi önermiştir. Yüz görüntüleri 52 belirleyici nokta ile etiketlendikten sonra ortak şekle eğritilerek görüntülerdeki boyut, pozisyon ve dönme gibi etkenlerden oluşan farklılıklar ortadan kaldırılmıştır. Yüz öznitelikleri olarak gri seviye değerleri ve Sobel operatörü ile elde edilen kenar bilgisi kullanılmıştır. FG-NET ve FERET veritabanlarından seçilen 180 görüntünün yarısı eğitim aşamasında, kalanı test aşamasında kullanılarak yapılan deneylerde, SVM ile çocuk, yetişkin ve yaşlı yaş gruplarına sınıflandırma gerçekleştirilmiştir. Yöntemin CA'sı gri seviye değerleri için %81.1, kenar bilgisi içinse %87.8 olarak rapor edilmiştir.

Choi vd. (2010) yaşlanmayla ilgili özniteliklerin çıkarılmasında AAM'in tek başına kullanılmasının deri ve kırıksıklık gibi yerel özniteliklerin temsilinde yetersiz kaldığını düşünmüş ve yerel özniteliklerin çıkarılmasında farklı yöntemleri kullanmıştır. Sobel filtresi, orijinal ve düzleştirilmiş görüntü farkı, ideal yüksek geçiren süzgeç, Gauss yüksek geçiren süzgeç, Haar ve Daubechies ayrık dalgacık dönüşümü ile çıkarılan özniteliklerin yaş tahminindeki başarısı kıyaslanmıştır. Yaşın tahmini ise SVR ile gerçekleştirilmiştir. BERC ve PAL veritabanları üzerinde 5-kat çapraz doğrulama yöntemi ile yapılan deneylerde Gauss yüksek geçiren süzgeç ile üretilen özniteliklerin, BERC veritabanı için 6.85 yıl, PAL veritabanı için 8.44 yıl MAE ile en iyi sonucu verdiği görülmüştür.

Hajizadeh ve Ebrahimnezhad (2011) yönlü gradyanların histogramı (Histogram of Oriented Gradients) yöntemi ile çıkardıkları öznitelikleri, yaş gruplarına sınıflandırma probleminin çözümünde kullanmıştır. Önışleme aşamasında alın, göz kenarları, gözaltları ve elmacık kemiği bölgeleri belirlenmiş, bu bölgelerden çıkarılan öznitelikler görüntülerin,

sınırları 0-15, 16-30, 31-50 ve >50 olan yaş gruplarına sınıflandırılmasında kullanılmıştır. NN ile yapılan sınıflandırma işleminde, İran yüz veritabanından alınan 377 görüntüden 246'sı eğitim, 131'i test için kullanıldığında %87.02 CA elde edilmiştir.

Liang vd. (2011), yaşlanmayla ilişkili yerel ve uzamsal bilgileri yakalayan, gradyan pozisyonu ve yönü histogramlarına (gradient location and orientation histogram) dayalı bir yaş tahmini yöntemi önermiştir. 10x10 boyutlu bölgelere ayrılan görüntülerde, her bölge için, 3 farklı yarıçap ve 8 farklı gradyan yönü kullanılarak 136 elemanlı bir öznitelik vektörü çıkarılmıştır. Bütün bölgelerden çıkarılan öznitelikler birleştirildiğinde 48960 boyutlu bir öznitelik vektörü elde edilmiştir. Bu özniteliklerden yaşın tahmininde önemli olanların seçilmesi için çok görevli öğrenme (multi-task learning) yöntemi geliştirilmiştir. Böylelikle öznitelik vektörünün boyutu önemli ölçüde küçültülmüştür. Yaşın tahmini ise bir regresyon problemi olarak ele alınmış, FG-NET veritabanında LOPO değerlendirme yöntemi ile 5.45 yıl MAE başarı elde edilmiştir. Veritabanında 0-30 yaş aralığındaki 854 resim kullanıldığında ise yaş tahmini başarıyı 3.44 yıl MAE'dir.

Fukunaga ve Higashi (2011) burun bölgesinden çıkardıkları özniteliklerle bir yaş tahmini yöntemi geliştirmiştir. Burun öznitelikleri kişinin yaşlanma sürecinde oldukça değişim göstermektedir. Belirlenen burun bölgesinden yatay tarama ile piksel parlaklık değerlerinin farkları karşılaştırılarak çıkarılan öznitelikler yaşın tahmininde kullanılmıştır. Eğitim örneklerinden çıkarılan özniteliklerle, her yaş grubunda erkek ve kadın örnekler için ayrı olacak şekilde, ortalama öznitelik vektörleri oluşturulmuştur. Herhangi bir test görüntüsüne ait öznitelik vektörü ile yaş gruplarına ait ortalama öznitelik vektörleri arasında şablon eşleme yöntemi ile karşılaştırma yapılarak sınıflandırma gerçekleştirilmiştir. Deneylerde görüntülerin genç (0-20) ve yetişkin (20-49) yaş gruplarına sınıflandırılmasında, genç erkekler %60, yetişkin erkekler %90 CA ile sınıflandırılırken, genç kadınlar %70, yetişkin kadınlar ise %80 CA ile sınıflandırılmaktadır. Sınırları 5-9, 10-14, 15-19, 20-29, 30-39 ve 40-49 olarak belirlenen 6 yaş grubuna sınıflandırmada ise erkekler için %40, kadınlar için %50 CA elde edilmiştir.

Luo vd. (2013), yüz görüntülerinden yüz bölgesini belirledikten sonra histogram eşitleme ile aydınlatma farklılıklarını ortadan kaldırmış, daha sonra görüntülerin parlaklık değerlerini kullanarak sınıflandırma gerçekleştirmiştir. Yaş gruplarının sınırları 0-9, 10-19, 20-29, 30-39, 40-49, 50-59 ve ≥ 60 olarak belirlenmiş ve kadın ve erkek örnekler için ayrı SVM sınıflayıcıları eğitilmiştir. FG-NET ve MORPH veritabanından seçilmiş 1666 resimden, 552 kadın 730 erkek görüntüsü eğitim aşamasında, 179 kadın ve 205 erkek

görüntüsü ise test aşamasında kullanılmıştır. Elde edilen sonuçlara göre sistem kadınlar için %79.89, erkekler için %73.90 CA'ya sahiptir. Grubun belirlenmesinde ± 1 hata toleransı tanındığında ise CA'lar kadınlar ve erkekler için sırasıyla %91.48 ve %96.08'a yükselmiştir. Bu çalışmada aynı zamanda insanın yaş grubunu belirleme performansı değerlendirilmiştir. Elde edilen sonuçlar insanın 0-9 yaş arası çocukları diğer gruplardan kolayca ayırabildiğini fakat diğer yaş grupları için CA'nın %60 altında olduğunu göstermiştir. İnsanın kadınları sınıflandırmadaki başarısı %49.71, erkekleri sınıflandırmadaki başarısı ise %52.23 olarak belirtilmiştir.

Mokadem vd. (2010) yüz görüntülerinin genel ve yerel DCT özneliklerine dayalı bir yaş tahmini yöntemi önermiştir. Yüz görüntüleri 5x5 bloklara ayrılıp, her bölge 25 DCT katsayısı ile temsil edilmiştir. Bu öznelikler tek bir vektörde birleştirilip, vektör boyutu PCA ile küçültülmüştür. Yaşın tahmini bir regresyon problemi olarak ele alınarak doğrusal ve karesel yaşlanma fonksiyonları oluşturulmuştur. MORPH veritabanından belirli özelliklere göre seçilmiş 5000 görüntüden 4000'i eğitim aşamasında 1000 tanesi test aşamasında kullanılarak yapılan deneylerde, 5-kat çapraz doğrulama yöntemi uygulandığında 7.61 MAE değeri elde edilmiştir.

Yang vd. (2010) çalışmalarında yüz görüntülerinden 195552 Haar-benzeri öznelik çıkarmış ve bu özneliklerden ayırt edici olanların seçilmesinde sıralama modeli (ranking model) kullanmıştır. Bu modelde kişinin yaşlanma sürecindeki özneliklerin birbiriyle ilişkisi değerlendirilmiştir. Seçim işlemi sonucunda elde edilen 1000 Haar özneliği ile yaş tahmini gerçekleştirilmiştir. Yaşın tahmini aşamasında SVR kullanılmıştır. FG-NET veritabanı için 4-kat çapraz doğrulama yöntemi ile 5.67 yıl MAE elde edilmiştir.

Zhou vd. (2011) yaşla ilgili özneliklerin çıkarılması için Radon dönüşümünü kullanan bir çalışma yapmıştır. Görüntülere öncelikle farklı standart sapma değerlerine sahip iki Gauss filtresi uygulanmış, filtrelenmiş görüntülerin farkı alınarak kenar bilgisi iyileştirilmiştir. İyileştirilmiş görüntü üzerindeki kenar ve eğrilerin belirlenmesinde Radon dönüşümü kullanılmıştır. Çıkarılan özneliklerden yaşın belirlenmesinde etkin olanların seçilmesi amacıyla SVM içerisinde tekrarlamalı bir ölçekleme yaklaşımı önerilmiştir. Deneylerde yüz görüntülerinin 20 yaş sınır olacak şekilde iki yaş grubuna sınıflandırılması amaçlanmıştır. Yöntemin FG-NET veritabanı üzerindeki CA'sı %75 iken, MORPH-I veritabanı üzerindeki CA'sı %86'dır.

Luu vd. (2011b), çalışmalarında, yüzün belirleyici noktalarının konumlandırılmasında AAM'e göre daha hızlı ve doğru sonuç veren hat belirleme

görünüm modelini (Contourlet Appearance Model) önermiştir. Yöntem AAM gibi sadece bütünsel doku bilgisini değil, altörnekleme dışı hat belirleme dönüşümü ile yerel doku bilgisini de çıkarmaktadır. Çıkarılan öznitelikler görüntülerin öncelikle 20 yaş sınır olacak şekilde iki yaş grubuna sınıflandırılmasında, daha sonra her yaş grubu içinde kesin yaşın belirlenmesinde kullanılmıştır. Sınıflandırma işlemi SVM ile yaş tahmini ise SVR ile gerçekleştirilmiştir. FG-NET veritabanında LOPO yöntemi ile 4.12 yıl MAE başarı sağlanırken, PAL veritabanında 6.0 yıl MAE sonucuna ulaşılmıştır.

Yüzdeki doku özniteliklerini çıkaran LBP'ler, yaşın belirlenmesinde gri seviyeden bağımsız bir doku ölçümü sağlamaktadır. LBP'leri kullanarak görüntüleri çocuk, genç ve yaşlı olarak sınıflandıran bir çalışma Yang ve Ai (2007) tarafından yapılmıştır. Yerel bir görüntü parçasından çıkarılan LBP histogramı ile referans histogramlar arasındaki Ki-karesi uzaklıkları, o görüntünün referans sınıflara ait olmasıyla ilgili bilgi olarak kullanılmıştır. Optimum referans histogramı, tekrarlamalı optimizasyon yöntemiyle (real Adaboost) üretilmiştir. Çalışmada önce çocuklar yetişkinlerden ayrılmış, daha sonra yetişkinler genç ve yaşlı olarak sınıflandırılmıştır. Deneyler FERET veritabanından alınan 1196 kişiye ait 3540 resim ve PIE veritabanından alınan 68 kişiye ait 696 resim üzerinde, 5-kat çapraz doğrulama yöntemi kullanılarak gerçekleştirilmiştir. Elde edilen sonuçlar, FERET veritabanında %7.88, PIE veritabanında ise %12.5 hata ile sınıflandırma yapıldığını göstermiştir.

LBP'ler, Ju ve Wang (2009) tarafından, yüzde yaşlanmaya karşı en hassas bölgelerin belirlenmesi amacıyla kullanılmış ve bu bölgelerden çıkarılan doku öznitelikleriyle yaş tahmini gerçekleştirilmiştir. Yüzün farklı bölgelerinin yaş tahminindeki önemi Lanitis vd. (2002) tarafından araştırılmış ve göz bölgesinin en belirleyici bölge olduğu kanıtlanmıştır. Ju ve Wang (2009) bu çalışmadan yola çıkarak, yüz üzerindeki çeşitli bölgelerden LBP ile çıkardıkları doku özniteliklerini Adaboost sınıflayıcısının eğitiminde kullanarak yaşlanmaya karşı en çok değişen bölgeleri belirlemiştir. Daha sonra belirlenen bölgelerden çıkarılan doku öznitelikleri birleştirilmiş ve veri boyutu PCA ile küçültülmüştür. Yaş tahmini aşamasında güçlü karesel regresyon fonksiyonu kullanılmıştır. FG-NET veri tabanı üzerinde yapılan deneylerde, görüntülerin $1/10^3$ 'ü test, geri kalanı eğitim için kullanıldığında 6.85 yıl MAE ile yaş tahmin edilmiştir.

Li vd. (2012) yüz görüntülerinin şekil ve doku özniteliklerini kullanarak hiyerarşik bir yaş tahmini yöntemi önermiştir. Şekil özniteliklerinin üretiminde aktif şekil modeli kullanılmıştır. Doku öznitelikleri ise bölgesel LBP histogramlarının birleştirilmesi ile elde

edilmiştir. Yaş tahmini aşamasında öncelikle şekil öznitelikleri kullanılarak test örneği bebeklikten-yetişkinliğe ya da yetişkinlikten-yaşlılığa yaş gruplarından birine sınıflandırılmıştır. Bu aşamada karesel bir fonksiyon eğitilerek kullanılmıştır. Daha sonra her yaş grubu içerisinde doku öznitelikleri kullanılarak yaş tahmin edilmiştir. Yaşın tahmini aralıklı gösterim tabanlı sınıflayıcı (sparse representation based classification) ile gerçekleştirilmiştir. Normal koşullarda, her yaş etiketi bir sınıf olarak düşünüldüğünde, sınıf içindeki doku özniteliklerinin benzerliklere sahip olması gerekir. Bu nedenle, test örneğinin öznitelikleri hangi sınıftaki eğitim örnekleri ile en iyi şekilde temsil edilebiliyorsa, test örneği o sınıfa dahil edilmelidir. Bu yöntemin uygulanabilmesi için her sınıfta yeterli sayıda eğitim örneği bulunması gerekir fakat bu pratikte mümkün değildir. Bu nedenle çalışmada kişinin gerçek yaşını belirlemek yerine, bir yaş etiketinden daha genç ya da yaşlı olduğunu belirleme yoluna gidilmiştir. Test görüntüsü ile çok sayıdaki yaş etiketi arasında bu ilişki belirlenip birleştirilerek kişinin yaşına karar verilmiştir. FG-NET veritabanında LOPO yöntemi ile yapılan deneyde 4.32 yıl MAE sonucu elde edilmiştir.

Ylioinas vd. (2012) ise, yüz görüntülerinin doku yapısını temsilinde en çok tekrar eden LBP kodlarının kullanılmasını önermiştir. Eğitim aşamasında her bir yaş grubu için, üretilen LBP kodlarından en baskın olanlar belirlenmiş, bu kodların birleşiminden oluşan öznitelik vektörü ile sınıflandırma yapılmıştır. LBP kodlarının üretiminde sadece piksel farklarının işareti değil, piksel farklarının büyüklüğü de dikkate alınmış ve bu şekilde üretilen kontrast bilgisi doku özneliği olarak kullanılmıştır. Yerel doku bilgisinin üretilebilmesi için görüntüler bölgelere ayrılarak her bölgeden yukarıda açıklanan iki yöntemle öznitelikler çıkarılarak bir vektörde birleştirilmiştir. Images of Groups veritabanından rasgele seçilen 3500 görüntü ile eğitim, 1050 görüntü ile test gerçekleştirilmiştir. Sınırları 0-2, 3-7, 8-12, 13-19, 30-36, 37-65 ve ≥ 66 olarak belirlenen 7 yaş grubuna sınıflandırma işleminde SVM ile %51.7 CA elde edilmiştir. Grubun belirlenmesinde ± 1 hata toleransı tanındığında ise %88.7 CA ile sınıflandırma gerçekleştirilmiştir.

Yüz görüntülerindeki 68 belirleyici nokta koordinatlarını, LBP ile çıkarılan doku bilgisiyle öznitelik seviyesinde birleştiren ve yaş tahmini gerçekleştiren Tharwat vd. (2013), önce görüntüleri sınırları 0-9, 10-19, 20-29 ve 30-39 olarak belirlenen yaş gruplarına sınıflandırmış, daha sonra sınıf içerisinde kesin yaşın belirlenmesini sağlamıştır. Sınıflandırma ve yaş tahmini işlemleri üç şekilde yapılmıştır. Birinci yöntemde k NN ($k=19$) ile test örneğine en yakın k komşu belirlenmiş, bu komşuların sınıflara dağılımı

hesaplanmıştır. Bu dağılıma göre en fazla komşu sayısı hangi sınıfta ise test örneği o sınıfa sınıflandırılmıştır. Kesin yaşın belirlenmesinde ise test örneği ile o sınıftaki tüm örnekler arasındaki mesafeler hesaplanmış, en yakın olan örneğin yaşı test örneğinin yaşı olarak belirlenmiştir. İkinci yöntemde, birinci yöntemdekine benzer şekilde sınıflandırma gerçekleştirildikten sonra, o sınıf içerisinde regresyon ile oluşturulan yaşlanma fonksiyonuna bağlı olarak yaş tahmin edilmiştir. Son yöntemde ise, test örneğinin en yakın k komşusunun sınıflara dağılımı bilgisi, sınıflardaki yaş aralığı bilgisi ve komşu sayısı k kullanılarak ortalama bir değer üretilerek yaş belirlenmiştir. FGNET veritabanındaki 0-39 yaş aralığındaki 933 resim kullanılarak yapılan deneylerde, LOPO değerlendirme yöntemiyle sırasıyla 6.6, 5.8 ve 6.2 yıl MAE başarı elde edilmiştir. Çalışmada önerilen yöntem kadın ve erkek örnekler için ayrı ayrı uygulandığında ise, kadınlar için sırasıyla 7.2, 6.8 ve 7.0 yıl, erkekler içinse sırasıyla 6.0, 5.2 ve 5.9 yıl MAE sonucuna ulaşılmıştır.

Yannick vd. (2013) yüz görüntülerinden aşamalı olarak çıkardıkları LBP özniteliklerini kullanarak yaş grubuna sınıflandırma ve yaş tahmini yaklaşımı önermiştir. Birinci seviyede yüzün bütünü için genel LBP histogramı üretilmiştir. İkinci seviyede görüntü 2x2 bölgeye, üçüncü seviyede ise 4x4 bölgeye ayrılarak LBP histogramları çıkarılmış ve bu histogramlar birleştirilerek öznitelik vektörü üretilmiştir. Bu işlem üç farklı ölçek için yapılarak çok-ölçekli çok seviyeli LBP histogramları elde edilmiştir. Çalışmada yaş grupları 20-29, 30-39, 40-49, 50-59 ve ≥ 60 olarak belirlenmiştir. Her yaş grubunda her bir cinsiyet için ortalama 442 görüntü bulunmaktadır. SVM ile yapılan sınıflandırmada, 5-kat çapraz doğrulama testi ile görüntülerin %80'i eğitim aşamasında, %20'si test aşamasında kullanılarak %82 CA değeri elde edilmiştir. SVR ile yapılan yaş tahmininde ise kadınlar için 6.2 yıl, erkekler için 5.5 yıl MAE ile yaş tahmini gerçekleştirilmiştir.

LBP ile öznitelik çıkarmaya dayalı diğer bir çalışmada (Jeon vd., 2014) 3x3 komşuluklar için, merkez piksel ile komşularının mutlak farklarının ortalaması ile bir M değeri hesaplanmıştır. Daha sonra ise 9x9 boyutlu görüntü bölgesinde her 3x3 lük bölge için üretilen M değerleri ile LBP kodları üretilmiştir. Böylelikle benek, leke gibi daha büyük parlaklık değişimlerine sahip deri özniteliklerinin çıkarılması sağlanmıştır. Gradyan LBP olarak adlandırılan bu yöntemle, göz kenarları, gözaltları, yanaklar ve ağız kenarları gibi bölgelerden çıkarılan öznitelikler, Kore yüz veritabanındaki 473 görüntünün, sınırları 0-12, 13-19, 20-39, 40-59 ve ≥ 60 olarak belirlenen 5 yaş grubuna sınıflandırılmasında

kullanılmış ve %86.55 CA elde edilmiştir. Fakat çalışmada sınıflandırma yöntemi ve eğitim ve test kümelerinin belirlenme ölçütleri açıklanmamıştır.

Gabor özniteliklerini kullanarak yaş tahmini gerçekleştiren Gao ve Ai (2009), çalışmalarında internetten alınmış 0-79 yaş aralığındaki resimlerinden oluşan bir veritabanındaki görüntüleri, bebek, çocuk, yetişkin ve yaşlı olmak üzere 4 yaş grubuna sınıflandırmıştır. Özniteliklerin çıkarılmasında 3 ölçek ve 4 yöndeki 12 Gabor filtresi kullanılmış, LDA ve bulanık-LDA (Fuzzy-LDA) ile sınıflandırma gerçekleştirilmiştir. Çıkarılan 12 Gabor özneliğinin boyutunu küçültmek için PCA uygulanmıştır. Görüntülerden 5408'i eğitimde, 57 bebek, 350 çocuk, 492 yetişkin ve 79 yaşlı görüntüsünden oluşan 978 resim ise test aşamasında kullanılmıştır. Yapılan deneylerde, parlaklık değerleri kullanılarak LDA ile yapılan sınıflandırmada %87.39 CA sonucuna ulaşılmıştır. LBP öznitelikleri kullanıldığında %84.64, Gabor öznitelikleri kullanıldığında ise %91 CA elde edilmiştir. Önerilen bulanık-LDA yöntemi, sınıflandırmayı yaş gruplarının üyelik fonksiyonlarını dikkate alarak yaptığından, Gabor öznitelikleri için %92.54 CA ile, LDA'dan daha iyi sonuç vermiştir.

Wang vd. (2009b) ise, yüz görüntülerinden Gabor ve LBP ile çıkardıkları doku özniteliklerini birleştirerek, görüntülerin yaş gruplarına sınıflandırılmasında kullanmıştır. LBP ile yüzün doku bilgisinin, Gabor ile yüzün şekil bilgisinin çıkarılması hedeflenmiştir. Yaş grubuna sınıflandırmada birden fazla yaş grubu olduğundan, hata doğrulama çıktı kodları (error-correcting output code - ECOC) yöntemi, SVM ve Adaboost ile birlikte kullanılmıştır. FG-NET ve MORPH veritabanlarından alınan toplam 2726 resim ile yapılan deneylerde, görüntülerin çocuk (0-11), genç (12-21), yetişkin (22-60) ve yaşlı (>60) gruplarına sınıflandırılmasında, Gabor ve LBP özniteliklerinin birlikte kullanımının, bu özniteliklerin tek başına kullanımından daha iyi sonuçlar verdiği görülmüştür. Örneğin çocuk sınıfı için, LBP öznitelikleri ve Gabor öznitelikleri ECOC+SVM ile birlikte kullanıldığında LOPO yöntemi ile sırasıyla %88.3 ve %93.1 CA elde edilirken, bu öznitelikler beraber kullanıldığında CA %96.4'e çıkmaktadır. Genç, orta yaşlı ve yaşlı sınıflarında da benzer bir durum söz konusudur. Fakat bu sınıflardaki başarı yüzdesi çocuk sınıfından daha düşüktür. Diğer yandan ECOC+Adaboost için gereken zamanın ECOC+SVM'ye göre çok daha az olmasına karşın, bu yöntemle elde edilen %95 CA'nın ECOC+SVM ile elde edilen başarıya çok yakın olduğu görülmüştür.

Higashi vd. (2011) yüz görüntülerine 5 farklı ölçekte ve 6 farklı yöndeki Gabor filtrelerini uygulayarak her görüntü için 30 Gabor görüntüsü elde etmiştir. Bu görüntüler

yerel yönlü örüntüler (Local Directional Patterns) operatörü ile kodlanmıştır. Daha sonra kodlanmış görüntüler bölgelere ayrılarak bölgesel histogramlar çıkarılmış ve birleştirilmiştir. Bu şekilde oluşturulan öznitelik vektörünün boyutu PCA ile küçültülmüş ve SVM ile sınıflandırma gerçekleştirilmiştir. Yaş gruplarının sınırları ise 0-9, 10-19, 20-34 ve 35-64 olarak belirlenmiştir. FG-NET veritabanından seçilen 261 görüntünün 161'i eğitim aşamasında, geri kalanı test aşamasında kullanıldığında, %60.69 CA elde edilmiştir.

Ma vd. (2015), yüz görüntülerinden Gabor filtreleri ve LBP histogramları ile doku özniteliklerini çıkarmış, yaş tahminini çok görevli öğrenme sistemi olarak modellemiştir. Yaş tahmini her yaş etiketinin bir sınıf olarak değerlendirildiği çok sınıflı bir sınıflandırma problemidir. Her yaş için ikili bir sınıflayıcı, örneğin o sınıfa ait olup olmadığına karar verir. Burada test örneğinin sahip olabileceği her yaş etiketi için bir skor fonksiyonunun oluşturulması gerekir. Test örneğinin yaşı ise en yüksek değere sahip olan fonksiyona göre belirlenir. Fakat bir kişiye ait örnek sayısının yetersiz olması nedeniyle herhangi bir kişi için bu fonksiyonların tatmin edici şekilde oluşturulması mümkün değildir. Bu nedenle çalışmada farklı kişilerin yaş tahmini süreçleri birbiriyle ilişkili görevler olarak değerlendirilmiştir. Her k kişisi için skor fonksiyonu tüm eğitim kümesi kullanılarak elde edilmiş, genel skor fonksiyonu ise kişisel skor fonksiyonların ağırlıklı birleşimi ile oluşturulmuştur. Deneyler FG-NET ve MORPH veritabanlarında 10-kat çapraz doğrulama yöntemi ile gerçekleştirilmiştir. Veritabanının %20'den fazlası eğitim aşamasında kullanıldığında FG-NET, MORPH-I ve MORPH-II veritabanlarında Gabor öznitelikleri ile sırasıyla 8.0, 8.6 ve 5.1 yıl MAE sonucuna ulaşılmıştır. LBP öznitelikleri ile elde edilen MAE'ler sırasıyla 9.57, 6.97 ve 9.0 yıldır.

Weixing vd. (2014) çalışmalarında, yüz görüntülerinden çıkardıkları üç çeşit özniteliği, görüntülerin yaş gruplarına sınıflandırılmasında kullanmıştır. Birinci öznitelik vektörü, görüntülere 8 yönde ve 5 ölçekte Gabor filtresi uygulanarak elde edilen 40 Gabor görüntüsünden LBP histogramlarının üretilerek birleştirilmesi ve PCA ile boyutun küçültülmesi ile elde edilmiştir. İkinci öznitelik vektörü, göz ve ağız çevresi bölgelerinin LBP histogramlarının birleşiminden oluşmaktadır. Öznitelik vektörünün boyutu yine PCA ile küçültülmüştür. Son olarak yüzdeki deri bölgesi belirlenmiş, bu bölgeden Sobel operatörü ile kenar bilgisi çıkarılmıştır. Çıkarılan kenar bilgisinin toplam deri bölgesine oranı üçüncü öznitelik olarak kullanılmıştır. Yaş tahmini aşamasında ise üç sınıflayıcı eğitilerek her bir sınıflayıcı için bir ağırlık katsayısı üretilmiştir. Test görüntüsünün sınıflandırılmasından üç sınıflayıcının sonuçları bu ağırlık katsayıları ile birleştirilerek

karar verilmiştir. İki adet SVM sınıflayıcısı yukarıda açıklanan birinci ve ikinci öznitelik vektörleri kullanılarak ayrı ayrı eğitilirken, bir adet Öklid uzaklığına dayalı sınıflayıcı üçüncü öznitelik kullanılarak eğitilmiştir. Sistem başarımının değerlendirilmesinde, FG-NET veritabanı ve yazarların kendi topladıkları 1600 resim kullanılmıştır. Sınırları 0-17, 18-45, 46-60 ve 60-69 olarak belirlenen yaş gruplarına sınıflandırmada, her bir sınıf için 300 eğitim, 100 test örneği kullanıldığında %85.75 CA elde edilmiştir. Sai vd. (2015), benzer şekilde görüntülere 8 yönde ve 5 ölçekte Gabor filtresi uygulayarak ürettikleri 40 Gabor görüntüsünden bölgesel LBP histogramlarını çıkararak birleştirmiş ve LDA ile öznitelik vektörünün boyutunu küçülmüştür. FG-NET ve PAL veritabanından seçilen 383 görüntünün 0-10, 11-19, 20-60 ve >60 yaş gruplarına sınıflandırılmasında aşırı öğrenme makineleri (extreme learning machines) kullanılmıştır. Aşırı öğrenme makinesi, bir gizli katmana sahip ileri beslemeli NN'den oluşturulan basit ve etkin bir öğrenme algoritmasıdır. Sınıflandırma sonucunda 10-kat çapraz doğrulama yöntemi ile 0-10 ve ≥ 60 yaş grupları için %90, 20-60 yaş grubu için %80, 11-19 yaş grubu içinse %40 CA elde edilmiştir.

Yaşlanma ile birlikte yüz görünümündeki değişimler çok belirgin olduğundan Yan vd. (2008a) öznitelik tanımlayıcısı olarak uzaysal esnek parçaları (Spatially Flexible Patches-SFP) kullanmayı önermiştir. SFP, yerel parçaları ve onların pozisyonlarını incelediğinden, görüntülerdeki küçük sapma ve poz değişiklikleri için başarılı bir çözüm üretebilmektedir. Bunun yanında bu yöntem yeterli sayıda örnek olmadığı zaman öznitelik kümesinin ayırıcı karakteristiklerini güçlendirebilir. Yöntemde yerel parçalar, ortalama değerlerine ve varyanslarına göre normalize edildikten sonra yerel öznitelikler DCT ile çıkarılmıştır. Bu parçalar Gauss karıştırma modeli (Gaussian Mixture Model) ile modellenmiştir. YGA veritabanından 1000 görüntü eğitim, 3000 görüntü test aşamasında kullanılmış, kadın görüntüleri için 8.53 yıl, erkek görüntüleri için 7.82 yıl MAE başarı elde edilmiştir. FG-NET veritabanındaki yaş tahmini başarıyı ise 4.95 yıldır (Yan vd., 2008b). Zhuang vd. (2008) ise, SFP'leri gauss karıştırma modeli yerine gizli Markov modeli (Hidden Markov Model) süper vektörü ile temsil etmeyi önermiştir. Her bir yüz görüntüsü kısmen üst üste gelen parçalarla ifade edilmiştir. 32x32 boyutundaki yüz görüntüleri 6x6 parçalara ayrılmış ve her parça ortalama ve varyans değerlerine göre normalize edilmiştir. Daha sonra bu parçalara 2 boyutlu DCT dönüşümü uygulanmış, dönüşüm sonuçları ve x, y koordinatları, 38 elemanlı bir vektöre aktarılmıştır. Bu vektörler ise gizli Markov modeli ile modellenmiştir. Bu yöntem ile YGA veritabanındaki kadın ve

erkek görüntüleri için ayrı ayrı işlem yapılmış, görüntülerin yarısı eğitim aşamasında, kalanı test aşamasında kullanılmıştır. Elde edilen sonuçlar kadın görüntüleri için 6.33 yıl, erkek görüntüleri için 5.39 yıl MAE'dir.

Guo vd. (2009a), yüz görüntülerinden yaşın tahmininde biyolojiden esinlenilmiş özniteliklerin (Biologically Inspired Features - BIF) kullanılmasını öneren ilk çalışmayı yapmıştır. Yöntem insanın görsel nesne tanıma modelinden türetilmiştir. Bu model basit ve karmaşık hücre birimleri olarak adlandırılan sıralı katmanlar içermektedir. Bu birimler birincil görme merkezinden ikincil geçici kortekse ilerledikçe daha karmaşık bir yapı meydana getirir. İlk katman olan S1, giriş görüntüsüne Gabor filtresi uygulanarak oluşturulur. İkinci katman C1, S1 üzerinde bir MAX işlemi uygulanarak elde edilir. Bu tip öznitelikler yaşlanma örüntüsünü yakalamada etkin olan, küçük geçişleri, dönmeleri ve ölçek değişimlerini elde etme avantajına sahiptir. Çıkarılan BIF özelliklerinin boyutları PCA ile küçültülmüştür. BIF öznitelikleri kullanılarak FG-NET veritabanında SVR ile yaş tahmini yapıldığında, LOPO yöntemi ile 4.77 yıl MAE sonucu elde edilmiştir. YGA veritabanında SVM ile yapılan yaş tahmininde ise 4-kat çapraz doğrulama yöntemi ile kadın ve erkek örnekler için sırasıyla 3.91 ve 3.47 yıl MAE başarı sağlanmıştır. Hem yaş hem cinsiyet tahmini yapan daha kapsamlı bir çalışmada, BIF özniteliklerinin boyutunun küçültülmesinde PCA, OLPP ve MFA yöntemleri kullanılmıştır. BIF+MFA ile YGA kadın veritabanlarında 2.61 yıl, erkek veritabanında ise 2.64 yıl MAE başarı elde edilmiştir (Guo vd., 2009b). Bu sonuçlar BIF özniteliklerinin yaş tahminindeki üstün performansını göstermektedir.

Ni vd. (2009), güçlü çok durumlu regresyon öğrenme algoritması (Robust Multi Instance Regressor-RMIR) önermiştir. Çalışmada web üzerinden toplanmış verilerden oluşan büyük bir veritabanı kullanıldığında, ortalamadan çok uzaktaki veriler için de çözüm üretebilen evrensel bir yaş tahmini sisteminin oluşturulması hedeflenmiştir. Yüz görüntüleri 80x80 boyutuna ölçeklenip histogram eşitleme uygulanmıştır. 8x8 boyutundaki görüntü parçalarından DCT öznitelikleri çıkarıldıktan sonra evrensel arka plan modeli 512 Gauss bileşeni ile eğitilmiştir. Üretilen vektörün boyutu iki kez PCA'nın uygulanarak önce 2000'e sonra 500'e küçültülmüştür. Birinci boyut azaltma hesaplama verimliliği, ikincisi ise ayırt edici gücü arttırmak için uygulanmıştır. Eğitim aşamasında internetten toplanan görüntüler kullanılmış, sistem FG-NET veritabanı ile test edildiğinde 9.49 yıl, MORPH-I veritabanı ile test edildiğinde 7.42 yıl, MORPH-II veritabanı ile test edildiğinde ise 8.60 yıl MAE elde edilmiştir. BIF öznitelikleri kullanılarak ile yapılan benzer bir çalışmada ise FG-

NET, MORPH-I ve MORPH-II veritabanları için sırasıyla 8.37 yıl, 7.13 yıl ve 6.06 yıl MAE sonucuna ulaşılmıştır (Ni vd., 2011).

El-Dib ve El-Saban (2010) BIF yöntemini genişleterek daha detaylı yüz özniteliklerinin çıkarılması amacıyla alın bölgesini de içeren yüz görüntüleri kullanmıştır. FG-NET veritabanındaki görüntüler 68 nokta ile etiketlenmiştir. Bu noktalar kullanılarak kesilen yüz görüntüleri alın bölgesini içermemektedir. Yöntem yüz bölgesini alın da dahil olacak şekilde 75 nokta ile etiketlemekte ve BIF ile öznitelik çıkarmaktadır. Eğitilen 1 SVM ve 6 SVR'nin sonuçları birlikte değerlendirilerek FG-NET veritabanı için 3.17 yıl, MORPH veritabanından seçilen 443 görüntü için 4.11 yıl MAE ile yaş tahmini gerçekleştirilmiştir. FG-NET veritabanındaki yüz görüntüleri 68 nokta ile etiketlendiğinde elde edilen başarı ise 3.81 yıl MAE'dir. El-Dib ve Onsi (2011) benzer bir çalışmada yüzün farklı bölgelerinden öznitelikler çıkararak yaş tahminindeki başarısını değerlendirmiştir. Yüz görüntülerinden 20 nokta ile sadece göz bölgesi, 58 nokta ile alın hariç yüz bölgesi ve 75 nokta ile alın dahil tüm yüz bölgesi etiketlenmiş ve bu bölgelerden BIF ile öznitelikler çıkarılmıştır. SVM ve SVR birlikte kullanılarak yapılan yaş tahmini sonuçları FG-NET veritabanı için sırasıyla 3.71, 3.69 ve 3.17 yıl MAE'dir. Bu sonuçlar göz bölgesindeki kırışıklıkların en önemli yaşlanma öznitelikleri olduğunu göstermiştir.

İnsanın yaşlanması yavaş bir süreç olduğundan 25 ve 26 yaşlarındaki görüntüsü birbirine çok benzemektedir. Gerçek hayatta kişinin yaşı örneğin "yaklaşık olarak 25" şeklinde ifade edilerek sadece 25 yaş etiketi değil komşu yaş etiketleri de tahmin içerisinde bulunmaktadır. Sonuç olarak yüz görünümünü açıklamak için birden fazla yaş etiketi kullanılabilir. Geng vd. (2013) bu fikirden yola çıkarak, belirli bir yaş etiketinin öğrenilmesinde komşu yaşlardaki görüntülerin kullanılmasını önermiştir. Bu amaçla bir test görüntüsüne tek bir yaş etiketi değil bir etiket dağılımı atanmaktadır. Etiket dağılımı yüz görünümünü ifade etme derecesine sahip belirli sayıdaki komşu yaş etiketlerinden oluşmaktadır. Etiket dağılımlarının öğrenilmesi şartlı olasılıklı NN (conditional probability neural network) ile gerçekleştirilmiştir. Deneylerde FG-NET veritabanından AAM ile, MORPH veritabanından BIF ile öznitelikler çıkarılmıştır. BIF özniteliklerinin boyutunun küçültülmesinde MFA kullanılmıştır. Etiket dağılımı Gauss dağılımı ile ifade edildiğinde FG-NET veritabanında LOPO yöntemi ile 4.76 yıl MAE, MORPH veritabanında 10-kat çapraz doğrulama yöntemi ile 4.87 yıl MAE elde edilmiştir. Geng vd. (2014) daha sonra farklı yaş gruplarındaki etiket dağılımlarını, o yaş grubundaki yaşlanma eğilimini ifade edecek şekilde oluşturulmasını önermiş ve bu yolla performans artışı hedeflemiştir. Kişinin

çocukluk (0-20) ve yaşlılık (51-76) dönemlerindeki yaşlanma hızı, orta yaş (21-50) dönemine göre daha fazladır. Bu nedenle çalışmada yaş etiket dağılımlarının o yaşın bulunduğu yaş grubuna göre adaptif olarak belirlenmesi önerilmiştir. MORPH veritabanındaki görüntülerinden BIF ile çıkarılan özniteliklerin boyutu MFA ile küçültülmüştür. 10-kat çapraz doğrulama yöntemi ile 4.34 yıl MAE elde edilmiştir.

Li vd. (2014) çalışmalarında yaşlanma görüntüleri arasındaki sıra ilişkisini koruyan ve görüntülerin yerel topolojik yapısını gösteren, daha küçük boyutlu bir öznitelik gösteriminin öğrenilmesini hedeflemiştir. Büyük boyutlu yaş öznitelik uzayındaki iyi özniteliklerin, yerel topolojik yapıyı ve yüzler arasındaki sıra bilgisini korumakla kalmaması, aynı zamanda olabildiğince bağımsız olması gerekir. Çalışmada her özneliğin yerel yapıyı ve sıra bilgisini koruma becerisi ölçülmüştür. Aynı zamanda bu öznitelikler içerisinde gereksiz olanların belirlenmesinde doğrusal olmayan korelasyon kullanılmıştır. Son olarak, öznitelik seçme yöntemleri ile öğrenilen küçük boyutlu yaşlanma öznitelikleri ile yaşın tahmininde yarı denetimli bir yaş tahmini algoritması geliştirilmiştir. FG-NET veritabanındaki görüntülerden BIF ile öznitelikler çıkarılmış ve 150 tanesi seçilerek deneylerde kullanılmıştır. Görüntüler sınırları 0-4,5-9,10-14,... \geq 50 olarak belirlenen 11 yaş grubuna bölünmüş, 5-kat çapraz doğrulama yöntemi ile ortalama 1.306 hata ile yaş grubu belirlenmiştir.

Han vd. (2014) çalışmalarında yüz görüntülerinden otomatik olarak kişinin yaşını, cinsiyetini ve ırkını belirleyen genel bir sistem sunmuştur. Görüntülerden BIF ile öznitelikler çıkarılmış ve daha çok bilgi taşıyan öznitelikler seçilmiştir. Daha sonra yaşın, cinsiyetin ve ırkın belirlenmesi için hiyerarşik bir sınıflayıcı oluşturulmuştur. Sınıflandırmada 3 adet ikili SVM sınıflayıcısı eğitilmiştir. Bu sınıflayıcılarla görüntüler ırk ve cinsiyetine göre 4 gruba ayrılmış, her grup içerisinde SVR ile yaş tahmini yapılmıştır. Deneyler FG-NET ve MORPH veritabanları üzerinde 5-kat çapraz doğrulama yöntemi ile gerçekleştirilmiştir. MORPH veritabanında cinsiyet sınıflandırmada kadınlar için %91.9, erkekler için %98.7, ortalama olarak %97.6 CA sonucuna ulaşılmıştır. Irk belirlemede ise beyaz kökenli kişiler için %98.9, siyah kökenli kişiler için %99.1, ortalama olarak %99.1 CA elde edilmiştir. Yaş tahmini sonuçları ise FG-NET veritabanı için 4.8 yıl, MORPH veritabanı için 6.38 yıl MAE'dir. Guo ve Mu (2014) ise BIF özniteliklerinin boyutunu kanonik korelasyon analizi ile küçülterek kişinin yaşını, cinsiyetini ve ırkını belirleyen tümleşik bir sistem önermiştir.

Suo vd. (2007), yüz görüntülerinin benzetiminde yüksek çözünürlüklü hiyerarşik bir yüz modeli önermiştir. Bu model yüz görüntülerini çok katmanlı bir AND-OR grafi ile temsil etmektedir. Buradaki amaç, yüzdeki yaşlanmayı taklit edecek ve yaş tahmini için kullanılabilir istatistiksel bir yüz modeli oluşturmaktır. Bir giriş görüntüsü için önce bir graf gösterimi üretilir. Bu graf, yaşın algılanmasında önemli olan bilgileri ve her yaş grubundaki yüzler arasındaki farklılıkları açıklamaktadır. Bunlar saç stili ve şeklindeki genel değişimler, yüz bileşenlerinin yaşlanmaya bağlı değişimler ve deformasyonlar ve yüzün çeşitli bölgelerindeki kırışıklıklardır. Oluşturulan bu graf gösteriminde yüzün yaşlanması dinamik Markov süreçleri ile modellenmiştir. Çeşitli yaş grupları üzerinde öğrenilen dinamik modele bağlı olarak graf yapısı örneklenmiş, yeni yüz görüntüsü örneklenmiş graflardan öğrenilmiştir. Üretici model ve dinamikler 50000 yüz görüntüsünden alınan verilerle eğitilmiştir. Model kullanılarak üretilen yaşlanma görüntülerinin doğruluğu anket yolu ile test edilmiştir. Çalışmada 20-30, 30-40, 40-50, 50-60 ve 60-80 yaş aralıklarına sahip 5 yaş grubu oluşturulmuştur. 20-30 yaş grubundan 20 kişi seçilerek bu kişilerin diğer yaş gruplarındaki görüntüleri oluşturulan modele bağlı olarak üretilmiştir. 1. deneyde A kümesi 30 yaş üstü 80 üretilmiş görüntüyü, B kümesi ise 80 gerçek görüntüyü içermektedir. Anketörlerden her iki gruptaki görüntülerin yaşlarını ayrı ayrı tahmin etmeleri istenmiş, her iki grup için yaş tahmini başarısının birbirine tutarlı olduğu görülmüştür. 2. deneyde ise A kümesi 20-30 yaş grubundan daha önce daha yaşlı görüntüleri üretilmiş kişilerde dâhil olmak üzere 50 kişinin resmini, B kümesi ise üretilmiş 80 görüntüyü içermektedir. Bu deneyde anketörlerden B kümesindeki her görüntüyü A kümesindeki görüntülerle eşleştirmesi istenmiştir. Elde edilen sonuçlara göre anketörler bu eşleştirme deneyinde 30-40 yaş grubu için %100, 40-50 yaş grubu için %83.21, 50-60 yaş grubu için %75.58, 60-80 yaş grubu için %50.71 oranında başarılı olmuştur.

Suo vd. (2008; 2010) geliştirdikleri bu yüksek çözünürlüklü hiyerarşik yüz modeli temelinde grafiksel yüz özniteliklerini (topoloji, geometri, fotometri ve düzen) düzenlemiştir. Topolojik öznitelikler, saç stilini, yüz bileşenlerine ait bölgeleri ve kırışıklıkların varlığını, geometrik öznitelikler yüz bileşenlerinin konumlarını, fotometrik öznitelikler rengi, alçak ve yüksek frekanslı parlaklık görüntülerini, düzen öznitelikleri ise antropometrik oran bilgilerini içermektedir. Hiyerarşik yüz modelinde yüz görüntüleri kabadan ince detaylara doğru ayrıştırılmış, yaşlanma süreci Markov zinciri ile modellenmiştir. FG-NET veritabanında çok katmanlı ağ kullanılarak regresyon analizi yapıldığında, görüntülerin yarısı eğitim, diğer yarısı test için kullanılarak 4-kat çapraz

dođrulama testi ile 5.97 yıl MAE sonucu elde edilmiştir. Kendi oluşturdukları 9-89 yaş aralığındaki 8000 Asya kökenli kişi görüntüsünü içeren veritabanında ise 4.68 yıl MAE başarı sağlanmıştır.

2. YAPILAN ÇALIŞMALAR

2.1. Giriş

İnsan yüzü kimlik, cinsiyet, etnik köken, duygusal durum, yaş gibi pek çok bilgiyi içermektedir. Bunlardan yaş bilgisi, kriminoloji, güvenlik sistemlerinin tasarımı, çocukların korunması, satış, pazarlama, reklamcılık gibi alanlarda kullanılmaktadır. Bu nedenle yüz görüntülerinden yaş grubunun ve yaşın belirlenmesi bilgisayarla görme alanında oldukça ilgi çeken bir araştırma konusu haline gelmiştir.

Yaş tahmini çalışmaları genellikle iki önemli kısımdan oluşmaktadır. Bunlar özniteliklerin çıkarılması ve sentezlenmesi, sınıflayıcının tasarımı ve eğitimidir. Her iki kısım da, sınıflandırmanın doğruluğunu ve performansını doğrudan etkilemektedir. Önerilen yaş tahmini yöntemlerinin başarılı sonuçlar verebilmesinin yanında gerçek zamanlı olarak uygulanabilirliği de önem taşımaktadır. Bu nedenle öznitelik çıkarma ve sınıflandırma aşamaları kısa sürede çözüm üretebilir nitelikte olmalıdır.

Yaş tahmini sistemlerinin sınıflandırma aşamasında, kişinin gerçek yaşının tek aşamalı ya da hiyerarşik olarak belirlenmesi mümkündür. Tek aşamalı yaş tahmini yöntemi, büyük bir yaş aralığına sahip görüntüleri kullanarak yaşı tahmin etmeye çalışmaktadır. Burada olası yaş etiketi sayısının fazla olması sınıflandırma doğruluğunu düşürebilmektedir. Hiyerarşik yaş tahmininde ise öncelikle kişinin yaş grubu belirlenmekte, böylece olası yaş etiketlerinin sayısı azaltılmaktadır. Daha sonra bu küçük küme içerisinde daha büyük bir doğrulukla yaşı tahmin edilebilmektedir. Burada yaş gruplarının belirlenmesi konusunda farklılıklar olmaktadır. Kullanılacak yaş gruplarının teorik bir temele oturtulması, yöntemlerin performanslarının değerlendirilmesini ve kıyaslanmasını kolaylaştıracaktır. Bu çalışmada;

1. Yüz görüntülerinin sınıflandırılması aşamasında kullanılacak yaş gruplarının sınırları, gelişim psikoloğu Erik Erikson'un, "insanın sosyal gelişim aşamaları" teorisine (Erikson, 1968) göre düzenlenmiş, önerilen yaş grupları kullanıldığında AAM, DCT, LBP, Radon dönüşümü ve Gabor filtreleri gibi mevcut öznitelik çıkarma yöntemlerinin yaş tahmini başarımı değerlendirilmiş ve önceki çalışmalarda kullanılan yaş grupları ile kıyaslaması gerçekleştirilmiştir. Yaşın tahmininde, *k*NN, SVM ve LDA ile yaş grubunun belirlenmesi ve daha sonra yaş

grupları altında çoklu lineer regresyon ile kesin yaşın tahmini aşamalarından oluşan, hiyerarşik bir sistem kullanılmıştır.

2. AAM, DCT, LBP, Radon dönüşümü ve Gabor filtreleri ile çıkarılan özniteliklerin hem sınıflandırma hem de yaş etiketinin belirlenmesi aşamalarında karar seviyesinde birleştirilmesiyle üretilen karma özniteliklerin, sınıflandırma ve yaş tahmini performansları hesaplanmıştır. Ayrıca bu özniteliklerin yine önerilen yaş grupları ve önceki çalışmalarda kullanılan yaş grupları için sınıflandırma başarımı karşılaştırmalı olarak değerlendirilmiştir.
3. Görüntü morflemeye (image morphing) dayalı yeni bir model-tabanlı yaş tahmini yöntemi önerilmiştir. Yöntemde, önerilen yaş gruplarının ortak özelliklerini temsil etmek için, yaş modelleri üretilmiştir. Yaş grubundan dengeli bir şekilde seçilen yüz görüntüleri, morfleme yöntemi ile birleştirilerek, yaş gruplarına ait ortalama yaş bilgisini tutan yaş modelleri elde edilmiştir. Daha sonra bu modeller üzerinden çeşitli uzaklık ölçütleri kullanılarak sınıflandırma gerçekleştirilmiştir.
4. Önerilen yaş gruplarını kullanan model tabanlı yaş tahmini sisteminde, yaş grubuna sınıflandırma aşamasında, oylama tekniğine dayalı bir puanlama yönteminin kullanılması önerilmiştir. Burada yaş gruplarına ait yaş modelleriyle sınıflandırılacak yüz görüntüsü arasındaki uzaklığın tek bir ölçütle değerlendirilmesi yerine, farklı uzaklık ölçütlerinin sonuçlarının oylama yöntemiyle birleştirilmesi sağlanmış ve böylece sınıflandırma doğruluğunun artırılması hedeflenmiştir.

Bir sonraki bölümde yaş gruplarının belirlenmesi ve bu yaş gruplarını kullanarak yaş tahmini gerçekleştiren sistemin yapısı konularında detaylı bilgi verilmektedir.

2.2. Yaş Gruplarının Belirlenmesi ve Yaş Tahmini Sistemi

Yaş grubuna sınıflandırma işleminde kullanılan yaş grupları, sınıflandırma başarımını doğrudan etkileyen bir faktördür. Geçmişte günümüze kadar, yaş gruplarına sınıflandırma konusunda yapılan çalışmalar incelendiğinde, kullanılan yaş gruplarının sınırlarının birbirinden çok farklı olduğu görülmektedir. Bu yaş grupları genellikle çalışmalarda kullanılan veritabanlarındaki görüntülerin yaş aralığına göre belirlenmiş, insanın bebekliğinden ölümüne kadar geçen süre için genel bir gruplama oluşturulmamıştır. Diğer yandan pek çok çalışmada yaş grupları için kullanılan yaş

sınırlarının belirlenme kriterleri açıklanmamıştır. Ek olarak aynı veritabanı üzerinde deneyler gerçekleştiren farklı çalışmalarda, farklı sınırlara sahip yaş grupları kullanılmıştır. Tablo 2.1’de çeşitli çalışmalarda kullanılan yaş grupları verilmiştir. Tablodan görüldüğü gibi önceki çalışmalarda kullanılan yaş gruplarının sınırları büyük bir çeşitliliğe sahiptir.

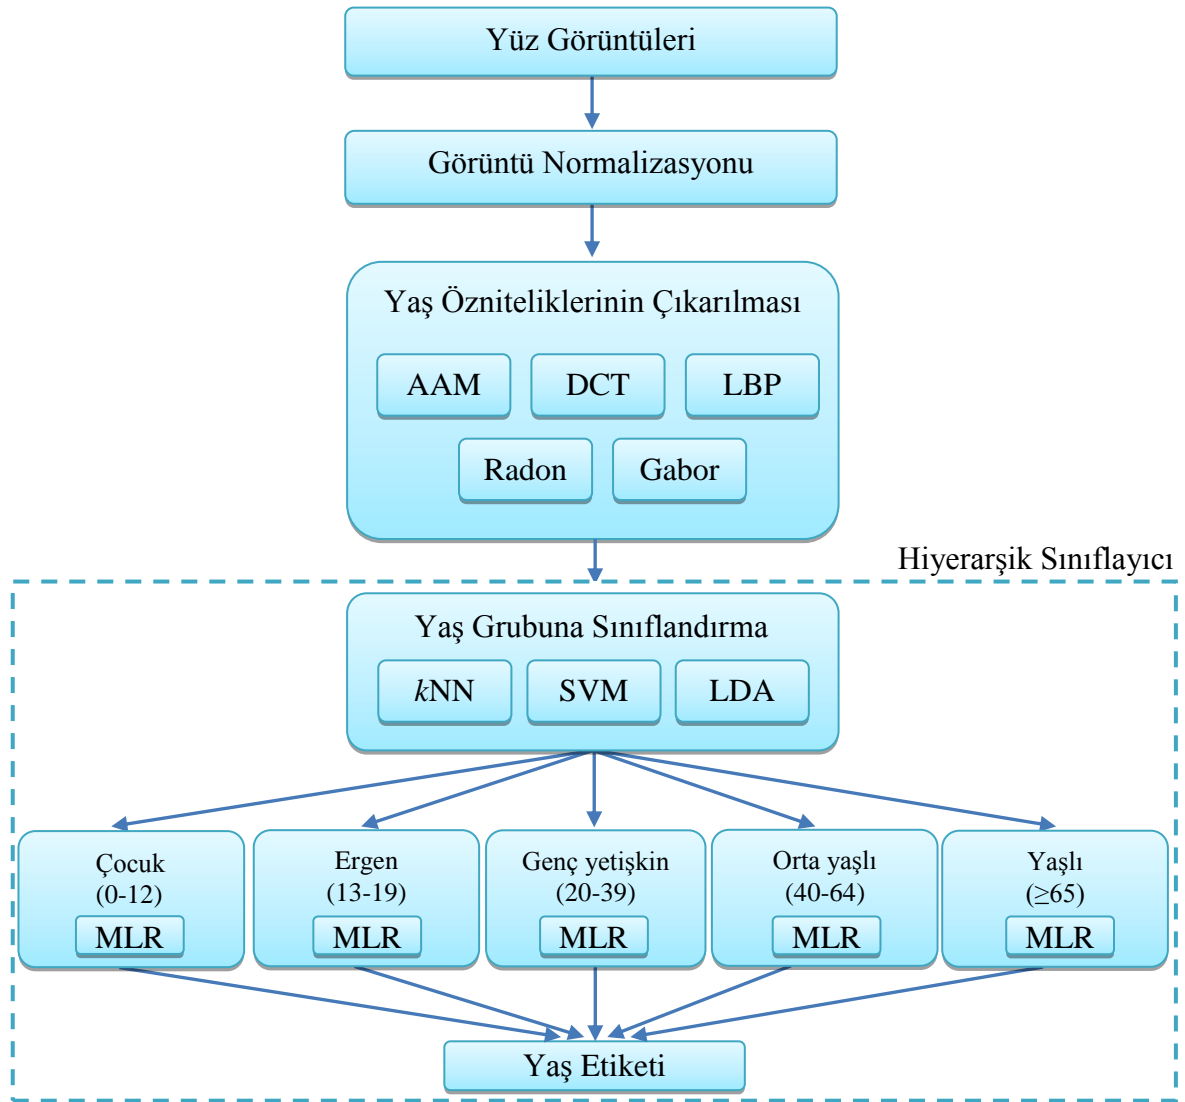
Tablo 2.1. Yaş grubuna sınıflandırma çalışmalarında kullanılan yaş grupları

Yöntem	Veritabanı	Yaş Grupları
Kwon ve Lobo (1999)	47 resim	Bebek, genç, yaşlı
Horng vd. (2001)	230 resim	0-2, 3-39, 40-59, ≥ 60
Txia vd. (2009)	MORPH	21-30, 31-40, 41-50, 51-60
Liu vd. (2014)	MORPH	16-19, 20-59, 60-77
Geng vd. (2014)	MORPH	0-20, 21-50, 51-76
Dehshibi ve Bastanfard (2010)	İran yüz veritabanı	0-15, 16-30, 31-50, ≥ 51
Izadpanahi ve Toygar (2012)	İran yüz veritabanı	0-2, 3-7, 8-19, 20-39, 40-60
Higashi vd. (2011)	FG-NET	0-9, 10-19, 20-34, 35-64
Guo vd. (2011)	FG-NET	0-14, 15-29, 30-49, 50-69
Liu vd. (2012)	FG-NET	0-2, 3-10, 11-18, 19-39, 40-69
Weixing vd. (2014)	FG-NET	0-17, 18-45, 46-60, 61-69
Liu vd. (2014)	FG-NET	0-3, 4-19, 20-59
Wang vd. (2009b)	FG-NET+MORPH	0-11, 12-21, 22-60, ≥ 61
Kalansuriya ve Dharmaratne (2013)	FG-NET+FERET	8-13, 14-25, 26-45, 46-63
Sai vd. (2015)	FG-NET+PAL	0-10, 11-19, 20-60, ≥ 61
Tez çalışmasında	FG-NET PAL MORPH	0-12,13-19,20-39,40-64,≥ 65

Daha önce de bahsedildiği gibi kişinin yaşlanma süreci, çeşitli genetik özelliklerinin yanında, yaşam koşullarından ve psikolojik durumundan da etkilenmektedir. Bu nedenle bu tez çalışmasında sınıflandırma aşamasında kullanılacak olan yaş gruplarının sınırları, gelişim psikoloğu Erik Erikson’un, “insanın sosyal gelişim aşamaları” teorisine göre belirlenmiştir (Erikson, 1968). Bu teoriye göre sağlıklı bir gelişime sahip insanın, doğumundan ölümüne kadar geçmesi gereken sekiz evre bulunmaktadır. Kişi üzerindeki biyolojik ve sosyo-kültürel etkenlerle karakterize edilen bu evrelerin yaş sınırları, 0-2, 2-4,

4-5, 5-12, 13-19, 20-39, 40-64, ≥ 65 şeklindedir. Çalışmada yüzün doku bilgisine dayalı bir yaş tahmini sisteminin geliştirilmesi hedeflenmiştir. Yüz dokusunun küçük yaşlarda çok değişmeyeceği düşünülerek 0-12 yaş grubu birlikte değerlendirilmiş, diğer yaş grupları Erikson'un teorisine uygun olarak oluşturulmuştur. Sonuç olarak çalışmada yaş grubuna sınıflandırma aşamasında kullanılan yaş grupları, çocuk (0-12), ergen (13-19), genç yetişkin (20-39), orta yaşlı (40-64) ve yaşlı (≥ 65) olarak belirlenmiştir.

Yaş grupları belirlendikten sonra, mevcut yöntemlerle öznelik çıkarma, yaş grubuna sınıflandırma ve kesin yaş etiketini belirleme işlemleri gerçekleştirilmiştir. Bu sistemin genel yapısı Şekil 2.1'de görülmektedir.

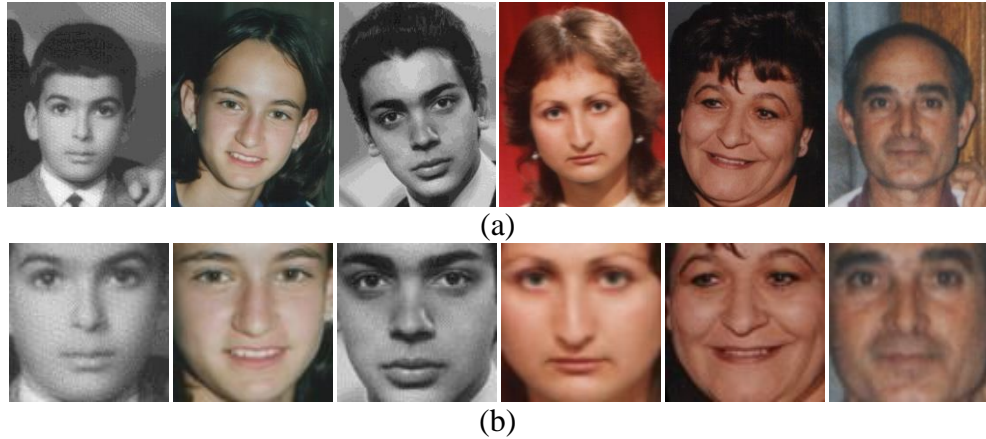


Şekil 2.1. Önerilen yaş grupları ile yaş tahmini sisteminin genel yapısı

Sistemde yüz görüntüleri göz konumlarına göre hizalanıp aynı boyutta kesilerek normalizasyon işlemi gerçekleştirilmiştir. Daha sonra yaşla ilgili özniteliklerin çıkarılmasında AAM, DCT, LBP, Radon dönüşümü ve Gabor filtreleri kullanılarak yaş tahminindeki performansları değerlendirilmiştir. Sınıflandırma işlemi ise iki aşamalı bir hiyerarşik sınıflayıcı ile gerçekleştirilmiştir. Öznitelikleri çıkarılan yüz görüntüleri öncelikle önerilen yaş gruplarına *k*NN, SVM ya da LDA sınıflayıcıları ile sınıflandırılmıştır. Daha sonra her sınıf altında MLR ile üretilen sınıfa özel yaşlanma fonksiyonları kullanılarak kişinin gerçek yaş etiketi belirlenmiştir. Yaş tahmini sisteminin ve kullanılan yöntemlerin detaylı açıklaması ilerleyen bölümlerde verilmiştir.

2.3. Görüntü Normalizasyonu

Yaş tahmini sisteminde öncelikle orijinal görüntüler normalize edilmektedir. Şekil 2.2’de farklı yönelime ve ölçeğe sahip görüntüler ve normalizasyon sonucu üretilen yüz görüntüleri görülmektedir.



Şekil 2.2. Görüntü normalizasyonu (a) Orijinal görüntüler (b) Normalize edilmiş görüntüler

Normalizasyon aşamasında görüntülerdeki poz, ölçek gibi farklılıkların ortadan kaldırılması ve görüntülerin hizalanması hedeflenmektedir. Diğer yandan orijinal görüntülerdeki arka plan, saç, kıyafet gibi bilgiler yaş tahmini performansını kötü yönde etkileyebilir. Bu nedenle orijinal görüntülerden sadece yüz bölgesinin çıkarılması ve yüzlerin yönelim ve boyutlarının hizalanması gerekmektedir. Görüntülerdeki kafa

yöneliminin düzletilmesi için, görüntüler iki gözün merkezi arasında çizilen doğrunun x eksenini ile yaptığı açı kadar döndürülmüştür. Döndürme işleminden sonra göz merkezleri arasındaki mesafe 50 piksel olacak şekilde görüntüler ölçeklenerek, ölçeklemeden doğan farklılıklar elimine edilmiştir. Son aşamada görüntüler göz merkezleri aynı konumda olacak şekilde kesilmiştir.

Yaş tahmini sisteminde görüntüler normalize edildikten sonra, çeşitli yöntemler kullanılarak yaşlanma ile ilgili özniteliklerin çıkarılması sağlanmıştır. Bu yöntemler bir sonraki bölümde açıklanmaktadır.

2.4. Yaş Özniteliklerinin Çıkarılması

Yaşın tahmininde, yaşlanma ile ilgili özniteliklerin çıkarılması aşaması büyük önem taşımaktadır. Bu nedenle çalışmada yaşlanma ile ilgili özniteliklerin çıkarılmasında çeşitli yöntemler kullanılmıştır. Yüzün genel şekil ve parlaklık öznitelikleri AAM'le, yerel doku öznitelikleri ise DCT, LBP, Radon dönüşümü ve Gabor filtreleriyle çıkarılmış ve PCA ile boyut küçültme işlemi gerçekleştirilmiştir. Öznitelik çıkarma yöntemleri ve boyut küçültme işlemi alt bölümlerde detaylı olarak açıklanmaktadır.

2.4.1. Aktif Görünüm Modelleriyle Öznitelik Çıkarma

AAM, yüz görüntülerinin kodlanmasında kullanılan istatistiksel bir yöntemdir. Yöntem 1.3.2 bölümünde detaylı olarak açıklanmıştır. Bu yöntemde eğitim örneklerinden şekil, parlaklık ve birleşik şekil-parlaklık modelleri üretilmekte ve bu modeller kullanılarak her bir görüntü, şekil (\mathbf{b}_s), parlaklık (\mathbf{b}_g) ve birleşik şekil-parlaklık (\mathbf{b}_c) model parametreleri ile temsil edilmektedir. AAM öznitelikleri yüzün bütünsel olarak hem şekil hem de parlaklık bilgisini içermektedir. Bu öznitelikler yüzün doku bilgisini iyi bir şekilde kodlayamamasına rağmen genel olarak yaşın belirlenmesinde başarılı olmaktadır. Bu nedenle çalışmada AAM öznitelikleri çıkarılarak yaş tahmini performansı değerlendirilmiştir.

Yüz görüntülerinden AAM ile özniteliklerin çıkarılabilmesi için yüz üzerindeki belirleyici nokta koordinatlarına ihtiyaç duyulmaktadır. FG-NET veritabanı, 1002 görüntünün her biri için 68 belirleyici nokta koordinatını içerisinde bulundurmaktadır.

Çalışmada kullanılan MORPH ve PAL veritabanları ise belirleyici noktaların bilgisini içermemektedir. Bu nedenle PAL veritabanındaki 580 yüz görüntüsü için 68 belirleyici noktanın koordinatı elle girilmiştir. MORPH veritabanı içinse AAM ile öznelik çıkarma işlemi gerçekleştirilmemiştir.


AAM ile öznelik çıkarma işleminde öncelikle şekil modelinin eğitimi gerçekleştirilir. Bu aşamada görüntüler, yüzün şeklini belirleyen 68 noktanın koordinatı ile temsil edilmektedir. Şekil modeli üretiminde her bir yüz görüntüsündeki ölçek ve dönme gibi farklılıkları ortadan kaldırılması gerekmektedir. Bu amaçla eğitim kümesindeki ilk görüntüye ait şekil koordinatları referans olarak alınmıştır. Yüz şeklini belirleyen koordinat değerleri Procrustes analizi gerçekleştirilerek öncelikle merkez orijin olacak şekilde koordinat düzleminde kaydırılmış (translation), referans görüntüye göre ölçeklenmiş (scaling) ve döndürülmüştür (rotation). Bir görüntüye ait düzenlenmiş nokta koordinatları 136×1 boyutlu $\mathbf{x} = [x_1 \ y_1 \ \dots \ x_{68} \ y_{68}]^T$ vektöründe tutulduğunda, n elemanlı eğitim kümesi $\mathbf{X} = [\mathbf{x}_i; \mathbf{x}_i \in R^D]_{i=1}^n$ ile ifade edilir. Daha sonra şekil bilgisini içeren \mathbf{X} matrisinin temel bileşenleri belirlenerek bir şekil modeli (\mathbf{P}_s - dönüşüm matrisi) elde edilmiştir. Burada şekil bilgisindeki gürültünün giderilmesinin yanında, veri kaybının az olmasını sağlamak için üretilen öz değerlerin %99'u korunmuştur. Eğitim kümesindeki örneklere ait şekil modeli parametreleri ise $\mathbf{b}_s = \mathbf{P}_s^T \mathbf{x}$ ile elde edilmiştir.

Şekil modelinin üretilmesi sırasında eğitim kümesine ait ortalama yüz şekli $\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$ ile üretilmiştir. Eğitim kümesindeki tüm yüz görüntüleri ortalama yüz şekline eğriltildikten sonra, yüz bölgesindeki FG-NET için 7410, PAL için 7915 pikselin parlaklık değeri, parlaklık modelinin eğitiminde kullanılmıştır. Bu durumda FG-NET veritabanı için piksel parlaklık değerlerini tutan \mathbf{g} vektörü 7410×1 , PAL veritabanı için ise 7915×1 boyutundadır. Parlaklık modeli, n elemanlı eğitim kümesindeki örneklere ait parlaklık bilgisini içeren $\mathbf{G} = [\mathbf{g}_i; \mathbf{g}_i \in R^D]_{i=1}^n$ matrisinin temel bileşenlerinin belirlenmesi ile üretilmektedir. Eğitim kümesindeki parlaklık bilgisinin ortalaması $\bar{\mathbf{g}} = \frac{1}{n} \sum_{i=1}^n \mathbf{g}_i$ ile elde edilmektedir. Burada \mathbf{G} 'nin kovaryans matrisinin öz vektörleri üretilerek \mathbf{P}_g dönüşüm matrisi elde edilir. Temel bileşenlerin belirlenmesi sırasında, öz değerlerin %99'u alınarak yüz üzerindeki doku bilgisinin korunması sağlanmıştır. Eğitim kümesindeki örneklere ait parlaklık modeli parametreleri ise, $\mathbf{b}_g = \mathbf{P}_g^T \mathbf{g}$ ile üretilmiştir. Son aşamada şekil modeli parametreleri ve parlaklık modeli parametrelerinin tek bir vektörde birleştirilerek ($\mathbf{b} = [\mathbf{b}_s \ \mathbf{b}_g]^T$) tekrar PCA uygulanması sonucu birleşik şekil-parlaklık modeli için

dönüşüm matrisi \mathbf{P}_c elde edilmiştir. Burada ortalama şekil parlaklık bilgisi $\bar{\mathbf{b}} = \frac{1}{n} \sum_{i=1}^n \mathbf{b}_i$ 'dir. Eğitim örneklerine ait birleşik şekil-parlaklık model parametreleri ise $\mathbf{b}_c = \mathbf{P}_c^T \mathbf{b}$ ile üretilmiştir.

Herhangi bir test görüntüsü için, öncelikle görüntüye ait 68 nokta koordinatlarının, eğitim aşamasında kullanılan referans görüntünün koordinat değerlerine göre ölçeklenmesi ve döndürülmesi işlemleri gerçekleştirilmektedir. Düzenlenmiş nokta koordinatları $\mathbf{x}_t = [x_1 \ y_1 \ \dots \ x_{68} \ y_{68}]^T$ vektörü ile temsil edilsin. Daha sonra bu değerler eğitim kümesinden öğrenilen şekil modeline ait dönüşüm matrisi ile çarpılarak test görüntüsüne ait şekil modeli parametreleri üretilmektedir ($\mathbf{b}_{s_t} = \mathbf{P}_s^T(\mathbf{x}_t - \bar{\mathbf{x}})$). Test görüntüsüne ait parlaklık modeli parametrelerinin üretilmesinde ise, öncelikle test görüntüsü eğitim kümesinden elde edilen ortalama şekle eğriltilmiş ve eğriltilen görüntüde yüz bölgesindeki piksel parlaklık değerleri ile $\mathbf{g}_t = [g_1 \ \dots \ g_k]^T$ (k : yüz bölgesindeki piksel sayısı) elde edilmiştir. Test görüntüsüne ait parlaklık model parametreleri ($\mathbf{b}_{g_t} = \mathbf{P}_g^T(\mathbf{g}_t - \bar{\mathbf{g}})$) ile üretilmiştir. Son olarak şekil ve parlaklık model parametreleri birleştirilerek $\mathbf{b}_t = [\mathbf{b}_{s_t} \ \mathbf{b}_{g_t}]$ oluşturulduktan sonra birleşik şekil-parlaklık model parametreleri $\mathbf{b}_{c_t} = \mathbf{P}_c^T(\mathbf{b}_t - \bar{\mathbf{b}})$ ile elde edilmiştir.

FG-NET veritabanı için üretilen \mathbf{b}_s , \mathbf{b}_g ve \mathbf{b}_c model parametrelerinin boyutu sırasıyla 57, 513 ve 362 iken, PAL veritabanında 81, 480 ve 418'dir. Çalışmada \mathbf{b}_s , \mathbf{b}_g ve \mathbf{b}_c model parametrelerinin yaş tahmini performansı ayrı ayrı değerlendirilmiştir. AAM'in uygulanması sırasında PCA için korunacak öz vektör sayısının azalması durumunda Şekil 2.3'te görüldüğü gibi yüz üzerindeki doku bilgisi (kırıksıklıklar) belirgin bir şekilde atılmaya başlamaktadır. Çalışmada AAM'in uygulanması sırasında bu nedenle öz vektörlerin %99'u kullanılarak doku bilgisinin korunması amaçlanmıştır.



Şekil 2.3. Orijinal görüntü ile parlaklık parametreleriyle yeniden üretilen görüntünün karşılaştırılması (a) Orijinal görüntü (b) PCA(%99) üretilen görüntü (c) b ve a'nın farkı (d) PCA(%98) ile üretilen görüntü (e) d ve a'nın farkı

2.4.2. Ayrık Kosinüs Dönüşümüyle Öznitelik Çıkarma

Yüz tanıma uygulamalarında görüntülerin doğrudan kullanılması, görüntülerdeki bilgi fazlalığı ve korelasyondan dolayı verimliliği düşürmektedir. Diğer yandan görüntülerdeki aydınlatma açısı, renk ve poza bağlı değişiklikler de tanıma sistemlerinin başarımını kötü yönde etkilemektedir. Bu tip değişikliklerden doğan problemleri azaltan ve görüntülerdeki bilgi fazlalığını kaldıran DCT, yüz tanıma uygulamalarında ön işleme aşamasında kullanıldığı gibi (Chen vd., 2006), de-korelasyon, enerji sıkıştırma, ayrılabilirlik ve ortogonallik özelliklerinden dolayı çeşitli uygulamalarda öznitelik çıkarma ve veri sıkıştırma yöntemi olarak ta kullanılmaktadır (Rao ve Yip, 1990). Tüm bu özellikler DCT'nin yaş tahmini alanında da kullanılabileceği konusunda yol göstermektedir. DCT'nin özellikleri aşağıda açıklanmaktadır.

- De-korelasyon: Görüntü transformasyonunun temel avantajı, komşu pikseller arasındaki tekrarın ortadan kaldırılmasıdır. Bu, kodlama verimliliğinden ödün vermeden, bağımsız olarak kodlanabilen ve korelasyon içermeyen dönüşüm katsayılarının elde edilebilmesini sağlar.
- Enerji sıkıştırma: Bir dönüşümün etkinliği, giriş verisini olabildiğince az katsayı ile ifade edebilmesiyle ölçülebilir. Bu özellik, yeniden üretilen görüntüde görsel bir bozulma olmaksızın, nispeten küçük genliğe sahip katsayıların silinmesine imkan sağlar. DCT yüz görüntüleri gibi yüksek korelasyona sahip görüntülerde, az sayıda katsayı ile yüksek varyans dağılımı sergiler. Diğer bir ifadeyle, DCT enerjii alçak frekans bölgesine sıkıştırır. Bu nedenle, yüksek frekanslı içerik, önemli bir kalite düşüşü olmaksızın atılabilir.
- Ayrılabilirlik: Bir boyutlu DCT (1D-DCT) denklem 2.1 ile ifade edilebilir.

$$F(k) = \alpha(k) \sum_{x=0}^{N-1} f(x) \cos \left[\frac{\pi}{N} \left(x + \frac{1}{2} \right) k \right] \quad (2.1)$$

İki boyutlu DCT ise bir boyutlu dönüşüm formülü kullanılarak aşağıdaki gibi üretilebilir.

$$F(k_1, k_2) = 1D-DCT_x(1D-DCT_y) \quad (2.2)$$

Bu özellik iki boyutlu dönüşümün, bir boyutlu dönüşümün görüntünün satır ve sütunlarında ardışık olarak uygulanması ile elde edilebilmesi avantajını sağlar.

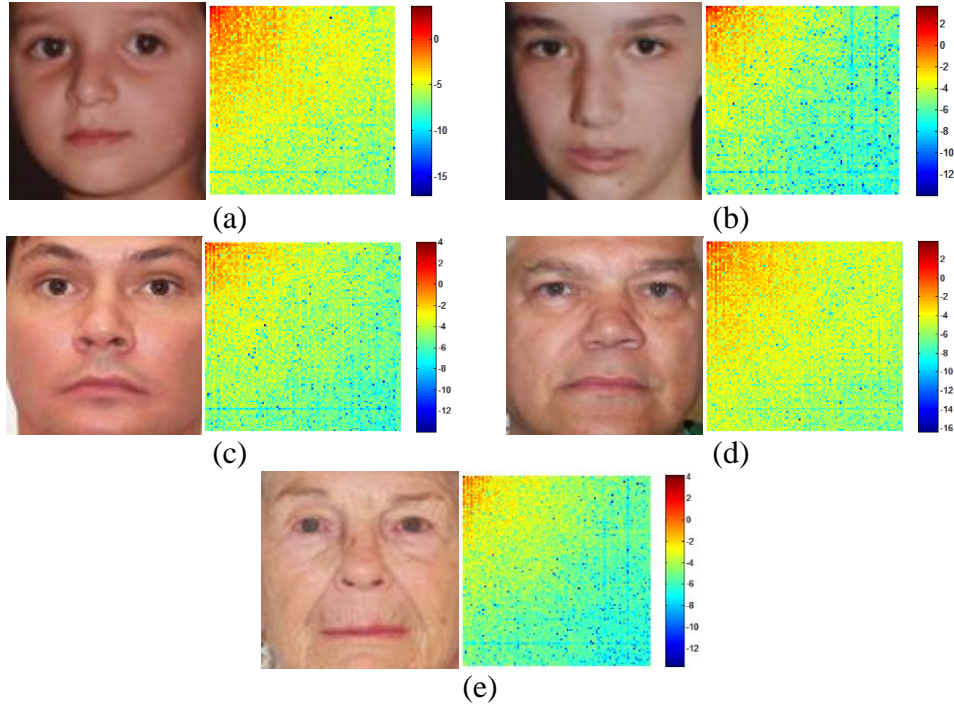
- Ortogonalite: Örüntü tanıma yöntemlerinde, modeli hesaplama yönünden verimli hale getirmek için dönüşümün ortogonalitesi, sınıf ayırma gücü kadar önemlidir. DCT tabanlı fonksiyonlar ortogondur. Ek olarak de-korelasyon özelliğinden dolayı bu özellik, ön hesaplama karmaşıklığında biraz azalma sağlar.

DCT sonlu bir dizi formatındaki verileri, farklı frekanslara sahip kosinüs fonksiyonlarının birleşimi ile ifade edebilen tersi alınabilir lineer bir dönüşümdür. DCT uygulanarak frekans uzayına taşınan orijinal işaretin ters DCT ile zaman uzayına geri taşınması mümkündür. Orijinal işaret DCT ile dönüştürüldükten sonra elde edilen DCT katsayıları, işaret içerisindeki frekansların önemini ifade eder. İlk katsayılar işaretteki DC bileşenler olarak adlandırılan düşük frekansları temsil eder ve genellikle önemli bilgiyi taşır. Son katsayılar ise işaretin yüksek frekanslı kısmını ifade eder. Bu yüksek frekanslar genellikle gürültü nedeniyle oluşurlar. Arada kalan diğer katsayılar işaretin farklı bilgi seviyelerini temsil etmektedir.

Görüntü işleme alanında iki boyutlu DCT kullanılmaktadır. Örneğin standart JPEG kodlama yönteminde de-korelasyon adımında iki boyutlu DCT kullanılmaktadır. İki boyutlu DCT denklem 2.3'te verilmiştir. Denklemden gri seviyelerden oluşan orijinal görüntü $f(x,y)$ ile, görüntü boyutları ise N_1 ve N_2 ile ifade edilmektedir. İki boyutlu DCT, görüntüden yine $N_1 \times N_2$ boyutlu bir katsayılar matrisi üretmektedir.

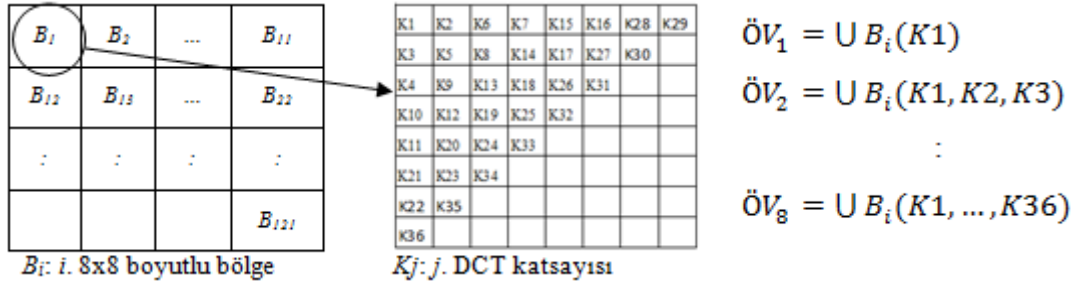
$$F(k_1, k_2) = \sum_{x=0}^{N_1-1} \sum_{y=0}^{N_2-1} f(x, y) \cos \left[\frac{\pi}{N_1} \left(x + \frac{1}{2} \right) k_1 \right] \cos \left[\frac{\pi}{N_2} \left(y + \frac{1}{2} \right) k_2 \right] \quad (2.3)$$

Şekil 2.4'te yaş gruplarından seçilen örnek görüntüler ve DCT sonuçları verilmiştir. Şekilden görüldüğü gibi dönüşüm sonucunda elde edilen katsayılar matrisinde, alçak frekanslı katsayılar sol üst köşeye toplanmıştır. Bu katsayılar görsel olarak önemli bilgiyi taşımaktadır. Çalışmada DCT ile görüntülerdeki yerel öznelikler çıkarılmış ve bu özneliklerin yaş tahminindeki başarısı incelenmiştir (Günay ve Nabiyev, 2015). Normalize edilmiş ve 88x88 boyutlarında kesilmiş resimlere DCT uygulanmıştır. Yaşın tahmininde yüz dokusunun genel gösterimler yerine yerel gösterimlerle daha iyi bir şekilde ifade edildiği, uzamsal doku bilgisinin yaş tahmininde etkili olduğu pek çok çalışma tarafından desteklenen bir görüştür. Görüntülere 8x8 bloklar halinde uygulanan dönüşüm



Şekil 2.4. Yaş gruplarından örnek görüntüler ve DCT sonuçları (a) 4 yaş (b) 15 yaş (c) 34 yaş (d) 61 yaş (e) 87 yaş

sonucu elde edilen 64 katsayıdan yüksek frekans katsayılarını elimine etmek için kuantalama işlemi uygulanmıştır. Geriye kalan alçak frekanslı bileşenler zig-zag tarama yöntemi ile seçilmiştir. Her bölgeden bu yöntemle üretilen bölgesel katsayılar tek bir vektörde birleştirilerek o görüntüye ait öznitelik vektörünü meydana getirmiştir. Burada zig-zag tarama yönteminin kullanılmasının nedeni bölgelerden öncelikli olarak alçak frekanslı katsayıları alarak öznitelik vektörlerinin oluşturulmasıdır. Çünkü çalışmada bir yerel bölgeyi temsil etmek için kullanılacak DCT katsayı sayısı deneysel olarak belirlenmiş sırasıyla her bölgeden çeşitli sayıda en düşük frekanslı katsayılar alınarak öznitelik vektörü üretilmiştir. Şekil 2.5'te de görüldüğü gibi öncelikle her bölgeden en düşük frekanslı 1 DCT katsayısı alınarak öznitelik vektörü elde edilmiştir. Daha sonra her bölgeden en düşük frekanslı 3 DCT katsayısı alınarak öznitelik vektöründe birleştirilmiş ve yaş tahmini gerçekleştirilmiştir. Bu şekilde üretilen öznitelik vektörlerinin yaş tahmini başarımına göre bir bölgenin temsil edilmesinde kullanılacak DCT katsayısı sayısı belirlenmiştir. Şekilde görüldüğü gibi üretilen DCT katsayılar matrisinde kuantalama nedeniyle yüksek frekanslı katsayılar 0'a düşürüldüğü için, matrisin ilk yarısındaki alçak frekanslı katsayıların yaş tahmini başarımı değerlendirilmiştir.



Şekil 2.5. Bölgesel DCT öznitelik vektörlerinin üretilmesi

Çalışmada DCT'nin uygulanması sırasında kullanılan 8×8 blok boyu JPEG sıkıştırma standardına göre belirlenmiştir (Pennebaker ve Mitchell, 1992). Bu standardın geliştirilmesi sırasında daha büyük blokların işlenmesinin, bilgisayarın çalışmasını oldukça yavaşlattığı ve daha iyi bir sıkıştırma sağlamadığı görülmüştür. Pratikte çok farklı türdeki görüntüler ve görüntüleme koşulları için optimum DCT blok boyutu 8×8 olarak belirlenmiş ve kodlama standartlarında kullanılmıştır. Görüntüde 8×8 boyutlu bir bloğa DCT'nin uygulanması sonucunda 64 DCT katsayısı elde edilmektedir. Bu katsayılardan kaç tanesinin öznitelik vektörüne aktarılacağı deneysel olarak belirlenmiştir. Bu amaçla bölgelerden üretilen katsayılardan sırasıyla 1, 3, 6, 10, 15, 21, 28 ve 36 tanesi öznitelik vektöründe birleştirilerek yaş tahmini gerçekleştirilmiş ve en iyi sonuca göre bölgeyi temsil etmede kullanılacak katsayı sayısına karar verilmiştir.


2.4.3. Yerel İkili Örüntülerle Öznitelik Çıkarma

LBP (Ojala vd., 2002), sayısal görüntülerdeki doku bilgisini tanımlayan çok güçlü bir yöntem olduğu için yüz tanıma sistemlerinde kullanılması uygundur (Ahonen vd., 2004). LBP operatörü kullanılarak kişi tanıma (Ahonen vd., 2004), yüz belirleme (Hadid vd., 2004), cinsiyet belirleme (Lian ve Lu, 2006) ve yüz ifadelerinin tanınması (He vd., 2006) gibi konularda çalışmalar yapılmıştır. Yaşın belirlenmesinde ise yüz derisinin doku analizi önem taşımaktadır. Çünkü kişinin yaşlanma sürecinde deri bölgesinde belirgin değişiklikler meydana gelmektedir. Bunlar kırışıklıklar, benekler, lekeler olarak ortaya çıkmaktadır. LBP bu tip doku özelliklerini gri seviyeden bağımsız olarak kodlayabilen bir yöntem olduğundan yaş tahmininde de başarılı olabileceği düşüncesini uyandırmıştır (Günay ve Nabiyev, 2008; Nabiyev ve Günay, 2011).

LBP doku analizi operatörü, gri-seviyeden bağımsız bir doku ölçümü yöntemidir. Orijinal LBP operatörü, görüntünün her pikseli için bir kod oluşturmaktadır. Bu kod merkez pikselin, 3x3 komşuluğundaki piksellerle karşılaştırılması sonucu elde edilen ikili bir sayıdır. Her bir resim pikseli, kendisi ve komşuları arasındaki farkın $u(x)$ basamak fonksiyonu ile ikilileştirilmesiyle etiketlenir. Daha sonra bu ikili sayı onlu sayıya dönüştürülerek merkez piksele karşılık gelen LBP kodu elde edilmiş olur. LBP kodlarının üretilmesi aşağıdaki denklem ile gerçekleştirilmektedir.


$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p \quad u(y) = \begin{cases} 1, & y \geq 0 \text{ ise} \\ 0, & y < 0 \text{ ise} \end{cases} \quad (2.4)$$

Burada x_c , LBP kodu üretilen merkez pikseli, x_p merkez pikselin komşularını, R komşuların merkez piksele olan uzaklığını, P ise işleme sokulan komşu sayısını ifade etmektedir. Bu şekilde üretilen LBP kodu merkez piksel için benzersiz bir tanımlayıcı olarak kullanılır. Şekil 2.6'da LBP operatörü ile bir piksele karşılık gelen kodun üretilmesine ilişkin bir örnek verilmiştir.



Şekil 2.6. LBP kodlarının üretilmesi

Orijinal LBP operatörü, çeşitli dairesel komşulukların kullanılabilceği şekilde genişletilmiş ve böylece farklı ölçekteki dokuların analizini gerçekleştirmek mümkün olmuştur. Piksellerin ara değerlerinin bulunması (interpolasyon), herhangi bir çap ve sayıdaki komşuluğa imkân sağlamaktadır. Şekil 2.7'de çeşitli LBP operatörlerine örnekler verilmiştir. Çalışmada ise (8,1) LBP operatörü kullanılmıştır.



Şekil 2.7. (8, 1), (8, 2) ve (16, 2) LBP operatörleri

Oluşturulan LBP kodlarının tümü doku tanımlamada kullanılmamaktadır. Doku tanımlamada kullanılan düzgün (uniform) örüntüler, ikili LBP kodunda dairesel olarak 0-1 ya da 1-0 geçişi sayısı 2 ya da daha az olanlardır. Örneğin 0000000 ve 1111111 örüntüleri 0 geçişe, 01110000, 00001111 ve 11001111 örüntüleri 2 geçişe sahip olduğundan düzgündür. Fakat 4 geçişli 11001000 ve 6 geçişli 01010011 örüntüleri düzgün değildir. Yapılan çalışmalarda araştırılan doku yüzeylerinde, düzgün örüntülerin, bazen %90'ın üzerinde, geniş bir çoğunluğa sahip olduğu görülmüştür (Ojala vd., 2002). LBP histogramı çıkarılırken düzgün örüntüler kullanıldığından, histogramda her bir düzgün örüntü için bir bölme bulunurken, düzgün olmayan örüntülerin hepsi tek bir bölmede toplanmaktadır. Tüm örüntüler incelendiğinde $P=8$ komşuluk için $2^P=256$ farklı örüntü üretilebileceği ve bunlardan sadece 58 tanesinin düzgün olduğu görülmektedir. Düzgün örüntüler 00000000, 00000001, 00000011, 00000111, 00001111, 00011111, 00111111, 01111111, 11111111 ve bunların dairesel olarak döndürülmesiyle elde edilmektedir. Bu durumda LBP histogramı 59 bölmeye sahip olacaktır.

$I(x,y)$ giriş görüntüsü üzerinde, 1 piksel uzaklıktaki 8 komşuluk için LBP histogramı aşağıdaki gibi üretilir.

$$H_i = \sum_{x_c \in I(x,y)} f\{LBP_{8,1}(x_c) = U(i)\} \quad i = 0,1, \dots, n-1$$


$$f(y) = \begin{cases} 1, & y \text{ doğru ise} \\ 0, & y \text{ yanlış ise} \end{cases} \quad (2.5)$$

Histogram üretiminde sadece düzgün örüntüler dikkate alındığı için $n=58$ 'dir. $U(i)$ ise, 8 komşulukta üretilen mümkün 256 farklı örüntüden düzgün olan 58 tanesini tutan dizidir. Bu histogram tüm resim üzerindeki kenarlar, benekler, düz alanlar gibi mikro-örüntülerle ilgili bilgi taşımaktadır. Bütünsel gösterimlerde doku tanımlayıcıları görüntü

alanı boyunca ortalama değere yaklaşma eğilimindedir (Ahonen vd., 2006). Yüz görüntülerinde uzaysal ilişkilerle ilgili bilgilerin korunması önemli olduğundan, bu görüntüler için bütünsel gösterimler uygun değildir. Bu nedenle görüntünün daha verimli bir gösterimini oluşturmak için bölgesel LBP histogramları kullanılmaktadır. Bu amaçla giriş görüntüsü R_0, R_1, \dots, R_{m-1} ile ifade edilen m bölgeye ayrılır ve her bölge için ayrı ayrı LBP histogramları aşağıdaki gibi oluşturulur.

$$H_{i,j} = \sum_{x_c \in R_j} f\{LBP_{8,1}(x_c) = U(i)\} \quad i = 0, 1, \dots, n-1 \quad j = 0, 1, \dots, m-1 \quad (2.6)$$

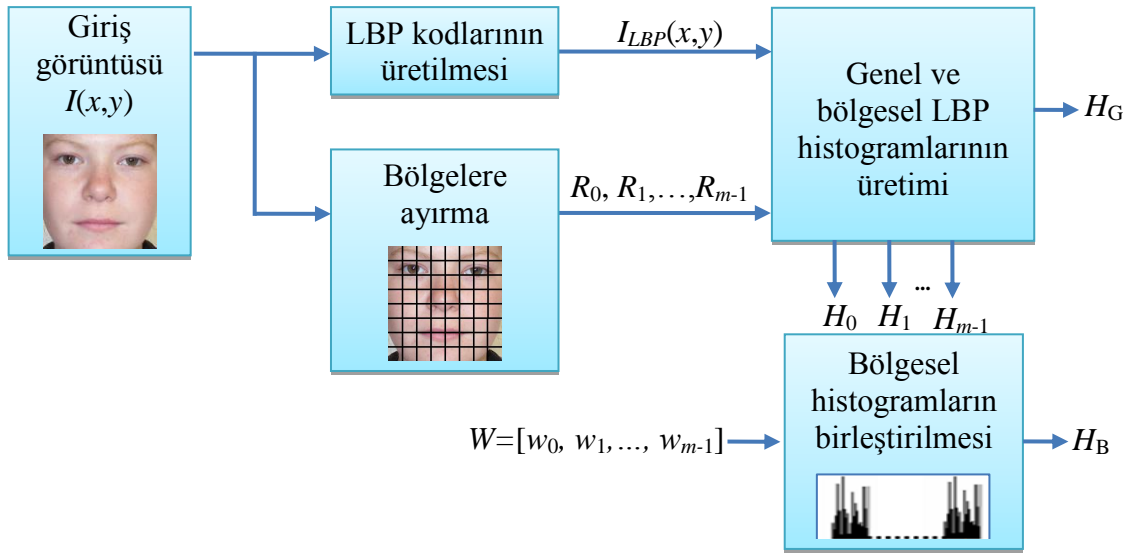
Burada $H_{i,j}$, j . bölgeye ait LBP histogramındaki i . değeri ifade etmektedir. Üretilen bölgesel histogramlar birleştirilerek giriş görüntüsü için tek bir LBP histogramı elde edilir. Bölgesel histogramların birleştirilmesi sırasında, görüntüdeki bölgelere önem derecesine göre $W=[w_0, w_1, \dots, w_{m-1}]$ gibi ağırlık katsayıları verilebilir. Bölgelerin önem derecesinin araştırılması ve katsayılarının belirlenmesi ayrıca çözülmesi gereken bir problemdir. Çalışmada katsayılar belirlenirken yüz üzerindeki yaşlanma etkileri dikkate alınmıştır. Örneğin alın, gözü, ağız kenarları ve yanak bölgeleri yaşlanma etkilerini belirgin bir şekilde ifade ettiğinden bu bölgelere daha yüksek katsayılar atanmıştır. Şekil 2.8'de bölgelere ayrılmış örnek bir görüntü ve her bölge için kullanılan katsayılar verilmiştir. Şekilde siyah bölgelerin katsayısı 0, gri bölgelerin katsayısı 2, beyaz bölgelerin katsayısı ise 4'tür. Her bölge için çıkarılan LBP histogramları, bölgesel katsayılarla çarpıldıktan sonra birleştirilmektedir.



Şekil 2.8. 8x8 bölgeye ayrılmış yüz görüntüsü ve bölge ağırlıkları (siyah-0, gri-2, beyaz-4)

LBP histogramı üretimi sırasındaki işlem adımları Şekil 2.9'da görülmektedir. Öncelikle, $I(x,y)$ giriş görüntüsündeki her bir piksel için denklem 2.4 kullanılarak LBP kodları üretilmektedir. Oluşan LBP görüntüsü $I_{LBP}(x,y)$ ile ifade edilmiştir. Diğer yandan

giriş görüntüsü istenen sayıda bölgeye parçalanmaktadır. Genel ve bölgesel LBP histogram üretimi modülünde denklem 2.5 ile yüzün tamamı için genel bir LBP histogramı üretilmektedir. Bu histogram \mathbf{H}_G ile ifade edilmiştir. Modülde aynı zamanda her bir bölge için denklem 2.6 ile bölgesel LBP histogramları ($\mathbf{H}_0, \mathbf{H}_1, \dots, \mathbf{H}_{m-1}$) oluşturulmaktadır. Üretilen bölgesel histogramlar, bölgelere atanan ağırlık katsayıları ($\mathbf{W}=[w_0, w_1, \dots, w_{m-1}]$) ile çarpıldıktan sonra birbiri ardına birleştirilerek \mathbf{H}_B elde edilmektedir.



Şekil 2.9. LBP histogramının oluşturulması

Çalışmada bölgesel LBP histogramlarının çıkarılması işleminde kullanılacak bölge sayısı deneysel olarak belirlenmiştir. 88x88 boyutuna normalize edilmiş görüntüler sırasıyla 2x2, 4x4 ve 8x8 bölgelere ayrılmış, üretilen bölgesel LBP histogramlar birleştirilerek yaş tahmini gerçekleştirilmiştir. Bölge sayısına bağlı olarak LBP özniteliklerinin yaş tahmini performansının değişimi incelenerek kullanılacak bölge sayısına karar verilmiştir.


2.4.4. Radon Dönüşümüyle Öznitelik Çıkarma

Radon dönüşümü (Radon, 1983) doku sınıflandırma (Cui vd., 2006), kızılötesi parmak görüntüsü sınıflandırma (Wu ve Ye, 2009), yürüyüş tanıma (Boulgouris ve Chi, 2007), yüz tanıma (Jadhav ve Holambe, 2010) gibi çok sayıdaki bilgisayarla görme

uygulamasında kullanılmaktadır. Yöntem aynı zamanda Al-Shaykh ve Doherty (1996) tarafından invaryant görüntü analizinde kullanılmıştır.

Radon dönüşümü özel bir görüntü izdüşümü alma yöntemidir. Dönüşüm, piksellerle temsil edilen görüntüyü, geometrik olarak daha fazla bilgi içeren ve daha küçük boyuta sahip Radon-piksel görüntüsüne dönüştürür. Radon izdüşümünde, belirli bir açıda yönlendirilmiş bir doğru üzerindeki piksel parlaklıkları toplanmaktadır. Dolayısı ile bir Radon-pikseli, orijinal görüntüde bir doğru üzerinde bulunan tüm piksellerin bilgisini içermektedir. Bu aynı zamanda o yöndeki uzaysal frekans bileşenlerinin iyileştirilmesini sağlamaktadır. Farklı yönlerdeki Radon izdüşümlerinin hesaplanmasıyla piksel parlaklık değişiklikleri korunur ve böylece yönlü alçak frekanslı bileşenler güçlendirilmiş olur. Bu özellik Radon dönüşümünün, görüntüdeki gürültüye karşı daha dayanıklı olmasını sağlamaktadır. Aynı zamanda, yüz üzerinde kırışıklıkları temsil eden çizgiler, eğriler gibi yönlü yüz özniteliklerin çıkarılması için kullanılması konusunda bizi motive etmiştir. Diğer yandan Radon piksel gösterimi boyut olarak orijinal görüntüden çok daha küçüktür. N -piksel görüntü için Radon piksel sayısı yaklaşık olarak $O(\sqrt{N})$ 'dir.

İki boyutlu Radon dönüşümü Şekil 2.10'da görüldüğü gibi düz doğrular boyunca işaretin integralini alan bir integral dönüşümüdür.



Şekil 2.10. $f(x, y)$ görüntüsünün Radon dönüşümü

Bir $f(x, y)$ görüntüsünün (s, θ) düzlemindeki Radon dönüşümü aşağıdaki denklemle üretilmektedir.

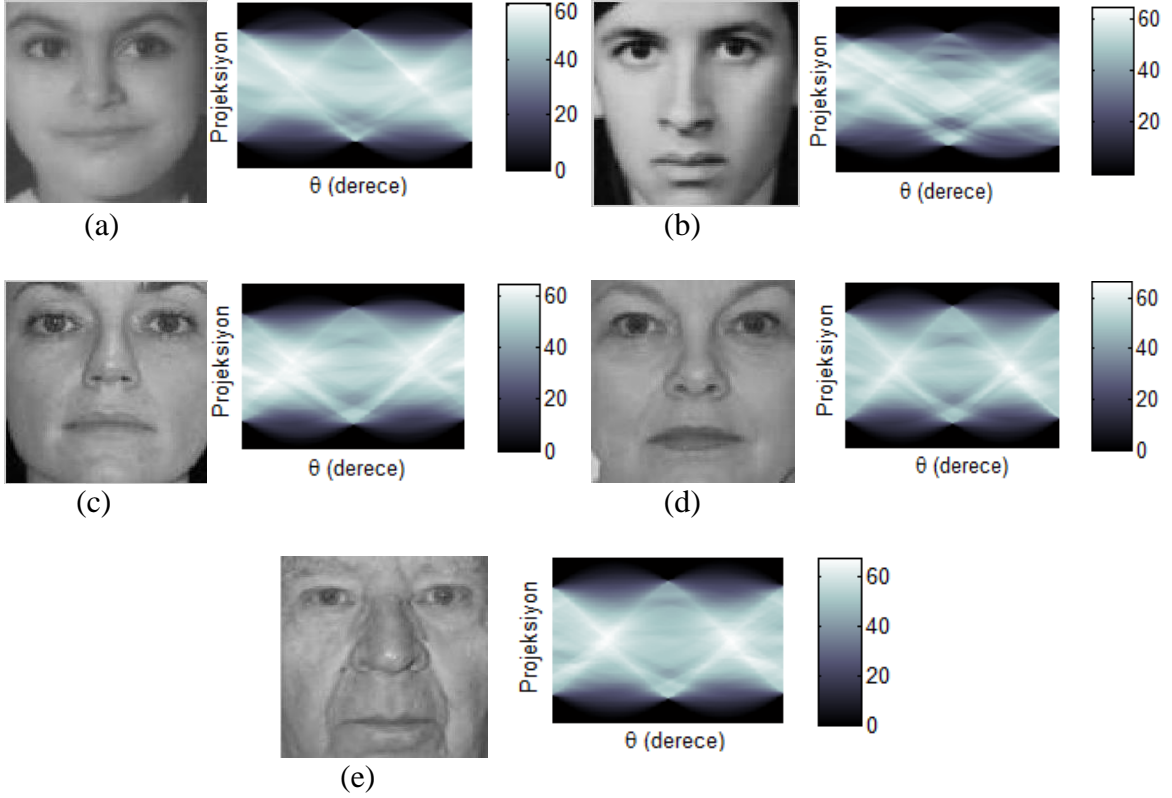
$$R(s, \theta)[f(x, y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(s - x \cos \theta - y \sin \theta) dx dy \quad (2.7)$$

Bu denklemde $\delta(\cdot)$ Dirac delta fonksiyonu, $s \in [-\infty, \infty]$ doğrunun orijine olan dik uzaklığı, $\theta \in [0, \pi]$ ise x eksenine ile doğrunun normali arasındaki açıdır. Denklem 2.7'ye göre $R(s, \theta)$ 'daki bir Radon pikseli, orijinal görüntüde orijinden dik olarak s piksel uzaklıkta konumlandırılmış ve θ derece eğime sahip doğru üzerindeki tüm piksellerin bilgisini içermektedir. Bir görüntünün Radon dönüşümü Şekil 2.11'de verilen sözde kod (pseudocode) kullanılarak kolaylıkla elde edilebilir.

<p>Algoritma: Bir görüntünün Radon dönüşümünün üretilmesi</p> <p>Giriş: Giriş görüntüsü I ve açı kümesi $\theta = \{\theta_1, \dots, \theta_t\}$</p> <p>Çıkış: $R \leftarrow$ Giriş görüntüsünün Radon dönüşümü (her sütun görüntünün θ_i derecedeki iz düşümüdür.)</p> <p>1: for $\forall_i : \theta_i \ i = 1, \dots, t$ do</p> <p>2: $I_{\theta_i} \leftarrow$ Görüntüyü θ_i derece döndür</p> <p>3: $R_{\theta_i} \leftarrow I_{\theta_i}$ 'nin sütun toplamlarını üreterek bir diziye aktar</p> <p>4: $R \leftarrow R \cup R_{\theta_i}$ (R'nin i. sütununa R_{θ_i} 'yi aktar)</p> <p>5: end for</p>
--

Şekil 2.11. Bir görüntünün Radon dönüşümünün üretilmesi algoritması

Çalışmada Radon dönüşümü yüz görüntülerindeki yaşlanma ile ilgili özneliklerin çıkarılması için kullanılmıştır. Bu amaçla yüz görüntülerinden çeşitli derecelerde iz düşümler üretilmiştir. Bu iz düşüm vektörleri $\frac{1}{4}$ oranında küçültülerek birleştirilmiş ve böylece görüntüye ait öznelik vektörü elde edilmiştir. Şekil 2.12'de çalışmada kullanılan yaş gruplarından seçilmiş örnek görüntüler için 0-180 dereceleri arasındaki tüm yönlerde üretilen Radon izdüşümleri görülmektedir. Şekildeki Radon görüntülerinde yatay eksen orijinal görüntülerin döndürme açısını, dikey eksen ise döndürülmüş görüntünün izdüşümünü ifade etmektedir. Şekilden görüldüğü gibi farklı yaşlardaki görüntüler için Radon dönüşümleri de farklılık göstermektedir.



Şekil 2.12. Yaş gruplarından örnek görüntüler ve 0-180 derece için Radon dönüşümü sonuçları (a) 6 yaş (b) 18 yaş (c) 34 yaş (d) 54 yaş (e) 79 yaş


Radon dönüşümünün uygulanması sırasında görüntü belirli açılarla döndürülüp izdüşümü alınmaktadır. Burada döndürme açısının artım miktarının belirlenmesi için çalışmada bir değerlendirme yapılmıştır. Bu amaçla 0-180 dereceleri arasında sırasıyla 1, 2, 3, 4, 5, 6, 9, 10, 12, 15, 18, 20, 30, 45, 60 ve 90 derece artımlarla üretilen Radon dönüşümlerinin yaş tahminindeki başarımı ölçülmüştür. Diğer yandan Radon dönüşümünün yüzün bütününe uygulanması ile genel özniteliklerin çıkarılmasının yanında, yüz görüntüsü bölgelere ayrılarak Radon dönüşümü uygulanmış ve yerel özniteliklerle yaş tahmini performansındaki başarımları ölçülmüştür (Günay ve Nahiyev, 2012).

2.4.5. Gabor Filtreleri ile Öznitelik Çıkarma

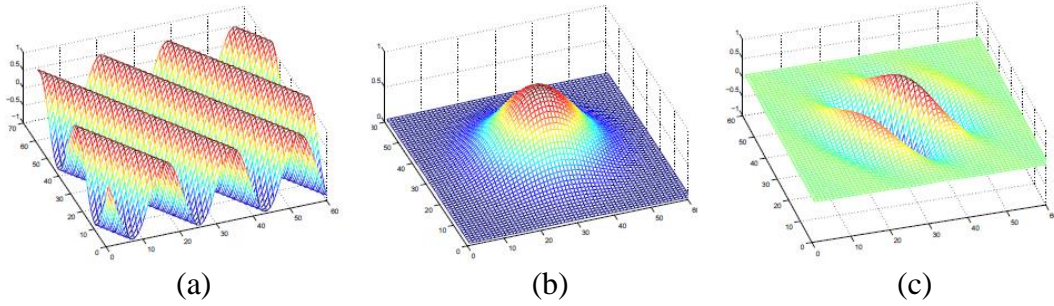
Yaşın tahmininde yüzdeki kırışıklıklar oldukça önemli bilgiler taşımaktadır. Kırışıklıklar yüz üzerinde çeşitli bölgelerde meydana gelen yönlü çizgilerdir. Farklı yönlere sahip olan bu çizgiler kişinin yaşına göre ince ya da derin olabilmektedir. Bu nedenle yüz görüntülerine çeşitli yön ve ölçekteki (frekanstaki) Gabor filtrelerinin

uygulanmasıyla bu çizgilerin belirlenmesi ve yaş tahmininde kullanılması mümkündür. Genel olarak Gabor filtreleri görüntü analizinde sıkça kullanılan bir yöntemdir. Frekans ve yönelim karakteristiklerine göre insan görme sistemiyle büyük benzerlik gösteren bu filtreler, yüz izleme ve poz tanıma (Kim vd., 2008), yüz tanıma (Shen ve Bai, 2006), doku analizi ve sınıflandırma (Chang ve Kuo, 1993) gibi alanlarda uygulamalara sahiptir.

Bir Gabor filtresi bir sinüs işaretinin bir Gauss fonksiyonu ile modüle edilmesiyle elde edilmektedir (Şekil 2.13). İki boyutlu görüntülerde ise Şekil 2.14'teki gibi 30° yönelimli bir sinüsoidin bir Gaussian ile birleştirilmesi sonucu Gabor filtresi elde edilir.



Şekil 2.13. Bir sinüs işaretinin Gauss fonksiyonu ile modülasyonu



Şekil 2.14. İki boyutlu Gabor filtresinin oluşturulması (a) 30° yönelimli bir sinüsoid (b) İki boyutlu Gauss fonksiyonu (c) İki boyutlu Gabor filtresi

İki boyutlu Gabor filtresi çekirdek matrisi denklem 2.8 ile hesaplanmaktadır. Denkleminde ilk üstel ifade (Gauss fonksiyonu) x' ve y' ne bağlı olarak azalan bir ifade iken, ikinci üstel ifade karmaşık sayı içeren periyodik bir ifadedir. Bu denklem Euler formülünden yararlanılarak düzenlenirse, g fonksiyonu gerçel ve sanal bileşenleri cinsinden de ifade edilebilir.

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \quad (2.8)$$

Denklemden λ Kosinüs çarpanının dalga boyunu belirleyen katsayıdır. Katsayının 1 olması durumunda Kosinüs ifadesi sürekli 1 olacağından ($\cos(2 \cdot \pi \cdot x') = 1$), katsayı 2 veya daha büyük bir tamsayı seçilmelidir. θ , x' ve y' değerlerinin hesaplanmasında kullanılır ve oluşturulmak istenen Gabor çekirdeğinin yönelim açısıdır. x' ve y' değişkenleri verilen bir θ değeri için aşağıdaki formül ile hesaplanır.

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos(\theta) & \sin(\theta) \\ -\sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \quad (2.9)$$


ψ , açısı oluşturulacak çekirdek matrisinin faz açısıdır. Bu değer değiştirilerek filtre x ekseninde ötelenabilir. σ değeri Gaussian fonksiyonun standart sapmasını belirleyen katsayıdır. γ ise verilen standart sapma değerinin y' için belirlenmesini sağlar. Bu değer 1 olması durumunda oluşacak çekirdek matris x ve y için eşit standart sapmaya sahip olduğundan eşit uzunlukta olacaktır. Farklı bir oran seçildiğinde ise çekirdek matris dikdörtgenimsi bir şekilde oluşacaktır.

Üretilen Gabor filtresinin bir görüntüye uygulanması, iki boyutlu konvolüsyon işlemi olup aşağıda verilen denklemle gerçekleştirilir.


$$G(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \iint I(p, q) g(x - p, y - q; \lambda, \theta, \psi, \sigma, \gamma) dpdq \quad (2.10)$$

Denklemden $I(p, q)$ Gabor filtresi uygulanacak görüntüyü $g(x, y; \lambda, \theta, \psi, \sigma, \gamma)$ ise Gabor filtresini ifade etmektedir.

Çalışmada 4 frekansta ve 6 yönde 24 Gabor filtresi üretilerek görüntülerden öznelik çıkarılmasında kullanılmıştır. Ölçek ve yön sayısının artırılması yaş tahmininde hesaplama süresini arttırdığı ölçüde bir iyileşme sağlamamaktadır (Choi vd., 2011). Üretilen 24 Gabor filtresi Şekil 2.15'te görülmektedir. Şekil 2.16'da ise örnek görüntüler için Gabor filtreleme sonuçları verilmiştir.



Şekil 2.15. 4 ölçek ve 6 yön için üretilen 24 Gabor filtresi



Şekil 2.16. Gabor filtreleme işlemi

Şekilden görüldüğü gibi Gabor filtreleri, görüntüyü bir dizi sınırlı frekans ve yönelimler içinde, yoğunluk bakımından değişimleri olan birçok filtrelenmiş görüntüye ayırmaktadır. Herhangi bir Gabor filtresi görüntüye uygulandığında, görüntüde filtre ile aynı yerel frekans ve yöndeki noktalar daha güçlü cevap vermektedir. Örneğin yönelimi 0 derece olan Gabor filtreleri, frekanslarına göre görüntüdeki yatay kenarların bulunduğu yerlerde yüksek genliğe sahip olmaktadır. Aynı yönde farklı kalınlıktaki kenarların belirlenmesi için görüntüye aynı yönetime fakat farklı frekanslara sahip filtreler uygulanmaktadır.

2.4.6. Öznitelik Vektörlerinin Boyutunun Küçültülmesi

Çalışmada çeşitli yöntemlerle üretilen öznitelik vektörlerinin boyutunun küçültülmesinde PCA yöntemi kullanılmıştır. PCA ile veri kümesi, içindeki benzerlikler ve farklılıklar ön plana çıkacak şekilde ifade edilebilmektedir. PCA'daki ana düşünce verinin dağılımını en iyi şekilde yakalayan vektörlerin bulunmasıdır. Bu vektörler, veriye ait kovaryans matrisinin öz vektörleridir. Üretilen öz vektörlerin sayısı, eğitim kümesinde yer alan örnek sayısına eşittir. Elde edilen öz vektörlerden, öz değerleri en yüksek olanlar yani dağılıma en çok katkıda bulunanlar seçilerek diğerleri ihmal edilebilir.

PCA'nın amacı M boyutlu \mathbf{X} veri kümesinden $m \leq M$ boyutlu \mathbf{Y} kümesine lineer bir dönüşüm sağlamaktır. M örnekten oluşan eğitim kümesinden çıkarılan $N \times 1$ boyutlu öznitelik vektörleri $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M$ ile sembolize edilsin. Öncelikle verinin ortalaması hesaplanarak eğitim kümesinden aşağıdaki gibi çıkarılır.

$$\bar{\mathbf{x}} = \frac{1}{M} \sum_{i=1}^M \mathbf{x}_i \quad (2.11)$$

$$\mathbf{x}'_i = \mathbf{x}_i - \bar{\mathbf{x}}, \quad \mathbf{A} = [\mathbf{x}'_1 \ \mathbf{x}'_2 \ \dots \ \mathbf{x}'_M], \quad i=1,2,\dots,M \quad (2.12)$$

Elde edilen bu \mathbf{A} matrisi üzerinden, verinin dağılımını en iyi ifade eden, her biri $N \times 1$ boyutunda, M adet ortonormal \mathbf{u}_k vektörü bulunacaktır. Bu vektörlerin her biri denklem 2.13'te tanımlanan λ_k katsayılarını maksimum yapacak şekilde seçilmektedir. \mathbf{u}_k vektörleri ve λ_k sabitleri denklem 2.14'te verilen \mathbf{C} kovaryans matrisinin sırasıyla öz vektörleri ve öz değerleridir.

$$\lambda_k = \frac{1}{M} \sum_{i=1}^M (\mathbf{u}_k^T \mathbf{x}'_i)^2 \quad (2.13)$$

$$\mathbf{C} = \mathbf{A}\mathbf{A}^T \quad \mathbf{C}_{i,j} = \mathbf{x}'_i \mathbf{x}'_j{}^T \quad (2.14)$$

Aslında bu öz vektörlerden öz değerleri en büyük olan $m \leq M$ tanesi önemli olup diğerleri ihmal edilebilir. Çünkü öz değerleri en büyük olanlar daha fazla bilgi taşımaktadır. Elde edilen bu öz vektörler kullanılarak veri boyutu küçültülebilir. i . resme

ait, boyutu küçültülmüş öznitelik vektörü aşağıdaki gibi hesaplanan m adet katsayıdan oluşmaktadır.

$$\begin{aligned} w_k &= \mathbf{u}_k^T \mathbf{x}'_i \quad k = 1, \dots, m \\ \mathbf{w}_i &= [w_1 \ w_2 \ \dots \ w_m] \quad i = 1, 2, \dots, M \end{aligned} \quad (2.15)$$

Test kümesindeki herhangi bir görüntü için öznitelik çıkarma işlemi sonucunda üretilen $N \times 1$ boyutlu vektör \mathbf{x} ile temsil edildiğinde, denklem 2.16 kullanılarak boyutu küçültülebilir. Burada test örneğine ait öznitelik vektöründen eğitim kümesinin ortalaması çıkarıldıktan sonra, eğitim kümesinden elde edilen öz vektörlerle çarpılmakta ve böylece örneğe ait m adet katsayı hesaplanmaktadır.

$$\begin{aligned} w_k &= \mathbf{u}_k^T (\mathbf{x} - \bar{\mathbf{x}}) \quad k = 1, \dots, m \\ \mathbf{w} &= [w_1 \ w_2 \ \dots \ w_m] \end{aligned} \quad (2.16)$$

Çalışmada DCT, Radon, LBP ve Gabor öznitelikleri için elde edilen özvektörlerden %99'u korunarak boyut küçültme işlemi gerçekleştirilmiştir. Eğitim ve test kümelerinin boyutları yukarıda anlatılan şekilde küçültüldükten sonra çeşitli sınıflayıcılar ya da uzaklık ölçütleri kullanılarak, test örneğinin hangi sınıfa dahil olduğuna karar verilmektedir.

2.4.7. Karma Özniteliklerin Çıkarılması

Yaşlanma ile ilgili özniteliklerin çıkarılması, yaş tahmini sistemlerinde başarıyı etkileyen en önemli faktördür. Bu nedenle çeşitli yöntemlerle çıkarılan özniteliklerin birleştirilmesi ile elde edilen karma öznitelikler, farklı yöntemlerin iyi yönlerinin birleştirilmesini ve başarımın arttırılmasını sağlayabilir. Daha önceki bölümlerde açıklandığı gibi, çalışmada yüzün genel öznitelikleri AAM'le çıkarılmaktadır. AAM öznitelikleri yüzün bütünsel olarak hem şekil hem de parlaklık bilgisini içerdiğinden sadece küçük yaşlarda değil, genel olarak tüm yaşlarda başarılı olabilmektedir. Fakat AAM'ler, yaşlı insanlar için yüzdeki kırışıklık bilgisini iyi bir şekilde kodlayamamaktadır. Çünkü bu yöntemde, görüntüdeki parlaklık değerleri için doku örüntüsünü hesaplayacak uzaysal bir komşuluk dikkate alınmamaktadır. Bu nedenle yüz görüntülerindeki doku öznitelikleri DCT, LBP, Radon dönüşümü ve Gabor filtreleriyle çıkarılmaktadır.

Çalışmada yüz görüntülerinin AAM ile çıkarılan genel öznitelikleri, DCT, LBP, Radon dönüşümü veya Gabor filtreleriyle çıkarılan doku öznitelikleriyle birleştirilerek, karma özniteliklere dayalı yaş tahmini gerçekleştirilmiştir. Birleştirme işlemi hem öznitelik seviyesinde (feature level fusion) hem de karar seviyesinde (decision level fusion) yapılmıştır. Öznitelik seviyesinde birleştirme işleminde, n görüntüden oluşan eğitim kümesindeki i . görüntü için j . yöntemle üretilen öznitelik vektörü ($\mathbf{f}_{i,j}$), denklem 2.17'ye göre z-skor normalizasyonu ile normalize edilmiştir.

$$\hat{\mathbf{f}}_{i,j} = (\mathbf{f}_{i,j} - \mu_j) / \sigma_j \quad j = 1, \dots, m \quad i = 1, \dots, n \quad (2.17)$$

Denklemden n görüntü sayısını, m öznitelik çıkarma yöntemi sayısını, $\mathbf{f}_{i,j}$ i . görüntünün j . yöntemle çıkarılan öznitelik vektörünü, μ_j ve σ_j ise sırasıyla $\mathbf{f}_{i,j}$ öznitelik vektörünün ortalamasını ve standart sapmasını ifade etmektedir. m farklı yöntemle çıkarılan öznitelik vektörleri bu şekilde normalize edildikten sonra denklem 2.18 kullanılarak birleştirilmiş ve yaşın tahmininde kullanılmıştır.

$$\mathbf{f}_{i,\text{birleşik}} = [\hat{\mathbf{f}}_{i,1} \hat{\mathbf{f}}_{i,2} \dots \hat{\mathbf{f}}_{i,m}] \quad i = 1, \dots, n \quad (2.18)$$

Karar seviyesinde birleştirme işleminde ise öznitelik çıkarma yöntemlerinin tek başlarına kullanılmaları sonucu üretilen yaş etiketlerinin ortalaması alınarak kişinin yaşı belirlenmiştir. Test kümesindeki i . görüntü için, herhangi öznitelik çıkarma yöntemi ile üretilen yaş etiketi $y_{i,j}$, kullanılan öznitelik çıkarma yöntemi sayısı m ise, kişinin yaşı y_i aşağıdaki denkleme göre hesaplanmaktadır.

$$y_i = \sum_{j=1}^m y_{i,j} / m \quad i = 1, \dots, n \quad (2.19)$$

Yaşlanma ile ilgili öznitelikler çıkarıldıktan sonra, çalışmada yaşın tahmini için oluşturulan hiyerarşik sınıflayıcı bir sonraki bölümde açıklanmaktadır.

2.5. Hiyerarşik Sınıflayıcı

Tek aşamalı yaş tahmini yönteminde, büyük bir yaş aralığına sahip görüntüler kullanılarak yaş tahmin edilmeye çalışılmaktadır. Hiyerarşik yaş tahmininde ise öncelikle kişinin yaş grubu belirlenmekte, daha sonra belirlenen yaş grubu içerisinde yaş tahmini gerçekleştirilmektedir.

Yaş tahmininin, büyük bir yaş aralığına sahip görüntüler kullanılarak yapılması, aralıktaki olası yaş etiketi sayısının fazla olması nedeniyle düşük bir başarımla elde edilmesine neden olur. Bunun yerine, öncelikle kişinin yaş grubunun belirlenmesi ile olası yaş etiketlerinin sayısı azaltılması ve daha küçük bir küme içerisinde yaş tahmini, yaş tahmini başarımlarını artırır. Bu nedenle çalışmada öncelikle tüm eğitim kümesinden tek aşamalı olarak yaş tahmini gerçekleştirilmiş ve daha sonra yaş grubuna sınıflandırma ve kesin yaşın belirlenmesi yöntemlerini birleştiren hiyerarşik bir sınıflayıcı oluşturulmuştur. Çalışmada yaş tahmini başarımlarını arttırmak için oluşturulan hiyerarşik sınıflayıcı yüz görüntülerini öncelikle önerilen yaş gruplarına sınıflandırmakta, daha sonra her yaş grubu içinde kesin yaş etiketinin belirlenmesini sağlamaktadır. Burada sınıflandırma aşamasında tüm görüntüler kullanılırken, yaş grubu altında yaşlanma fonksiyonunun öğrenilmesinde sadece o yaş grubu içerisindeki görüntüler kullanılmıştır. Böylece her yaş grubunun farklı özelliklerini temsil eden farklı yaşlanma fonksiyonları üretilmiştir. Çalışmada görüntülerin sınıflandırılması aşamasında en yakın komşuluk, SVM ve LDA sınıflandırma yöntemleri kullanılmıştır. Yaş grupları altındaki yaşlanma fonksiyonları ise MLR yöntemi ile modellenmiştir. Bu yöntemler alt başlıklarda detaylı olarak açıklanmaktadır.

2.5.1. Yaş Gruplarına Sınıflandırma


Yaş grubuna sınıflandırma, bir test görüntüsünün herhangi bir yaş grubu ile ilişkilendirilmesi anlamına gelmektedir. Bu aşamada öncelikle en basit yaklaşım olan k NN sınıflayıcısı kullanılmıştır. Daha sonra parametre kestirimi zaman alıcı olmasına rağmen, sınıflandırma problemini bir optimizasyon problemine dönüştürüp çözen ve pek çok çalışmada başarılı sonuçlar elde edilmesini sağlayan SVM yöntemi ile sınıflandırma gerçekleştirilmiştir. Son olarak kıyaslama amaçlı olarak sınıflar arasındaki ayırt edici özellikleri ortaya çıkarmaya dayalı LDA yöntemi ile sınıflandırma yapılmıştır.

2.5.1.1. En Yakın Komşuluk Sınıflayıcısı ile Sınıflandırma

En yakın komşuluk sınıflayıcısı test örneğinin sınıfını, eğitim kümesindeki en yakın komşu ya da komşuların sınıflarına bakarak tayin eden bir sınıflandırma yöntemidir. Karar verme aşamasında kullanılacak komşu sayısına göre yöntem en yakın komşuluk ya da k -en yakın komşuluk sınıflayıcısı olarak adlandırılmaktadır. Bu sınıflayıcılar, örnekler arasındaki ilişkiyi çeşitli uzaklık ölçütleri ile tanımlamaktadır. Test örneğinin sınıflandırılması için eğitim örneklerinden en yakın olduğu bir veya k örneğin sınıf etiketleri dikkate alınır. Başka bir yaklaşım ise sınıf merkezlerinin hesaplanması ve test örneğinin hangisine daha yakın olduğunun tespiti ile sınıf etiketinin belirlenmesidir.

2.5.1.1.1. Standart En Yakın Komşuluk

Bir test örneğinin bilinen tüm eğitim örneklerine uzaklığının çeşitli uzaklık ölçütleri ile hesaplanması ve elde edilen sonuçların karşılaştırılması ile bir sınıfa dahil edilmesidir. Şekil 2.17'de standart en yakın komşuluk sınıflayıcısı ile sınıflandırma örneği görülmektedir. Şekilde ? ile temsil edilen test örneğinin en yakın komşusu A sınıfına dahil olduğundan, test örneği de A sınıfına dahil edilmektedir.



Şekil 2.17. Standart en yakın komşuluk sınıflayıcısı

x , sınıflandırılmak istenen test örneğini, C_i , her birinde farklı sayıda eğitim örneği bulunan n adet eğitim sınıfının birini temsil etsin. $d(x, x_t)$, $x_t \in \{C_1 \cup C_2 \cup \dots \cup C_n\}$ ise, x örneği ile herhangi bir eğitim örneği arasındaki uzaklığı ifade etsin. Bu açıklamalara göre en yakın komşuluk sınıflayıcısı ile sınıflandırma işlemi aşağıdaki gibidir.

$$x \in \{C_i | \min d(x, x_t) = d(x, x_j), x_j \in C_i\} \quad (2.20)$$

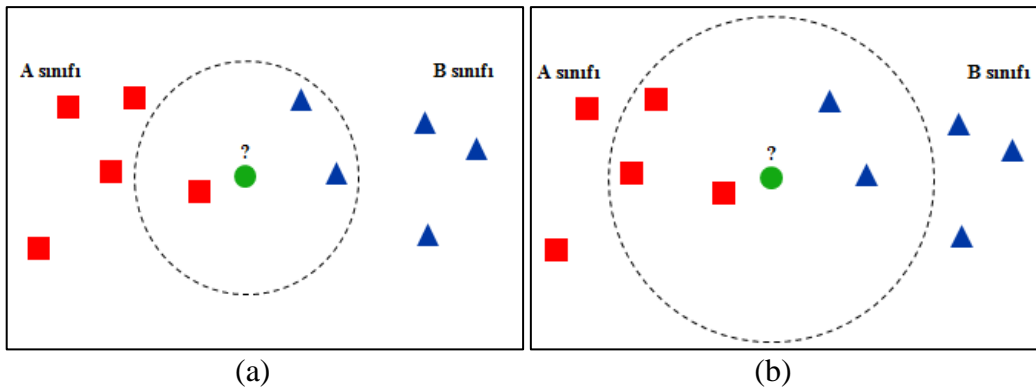
2.5.1.1.2. k En Yakın Komşuluk

k NN sınıflayıcısı, test örneğini en yakın k komşusunun sınıf etiketlerine göre sınıflandıran bir yöntemdir. Burada test örneği ile eğitim örnekleri arasındaki uzaklıklar hesaplandıktan sonra en yakın k komşusu belirlenir. Bu k adet komşu en fazla hangi sınıfa aitse, test örneği o sınıfa dahil edilir. Genel olarak, sınıflandırılmak istenen test örneği x 'in en yakın k komşusu $x_j \in \{x_1, x_2, \dots, x_k\}$ ile temsil edilsin. Test örneğinin dahil edileceği sınıf aşağıdaki denkleme göre belirlenir. Denklemden n sınıf sayısını, $v(C_t)$ ise test örneğinin k komşusundan C_t sınıfına ait olanların sayısını ifade etmektedir.

$$x \in \{C_i | \max (v(C_t)) = v(C_i)\} \quad t = 1, \dots, n$$

$$v(C_t) = \sum_{j=1}^k f(x_j, C_t) , \quad f(x_j, C_t) = \begin{cases} 1, & x_j \in C_t \\ 0, & x_j \notin C_t \end{cases} \quad (2.21)$$

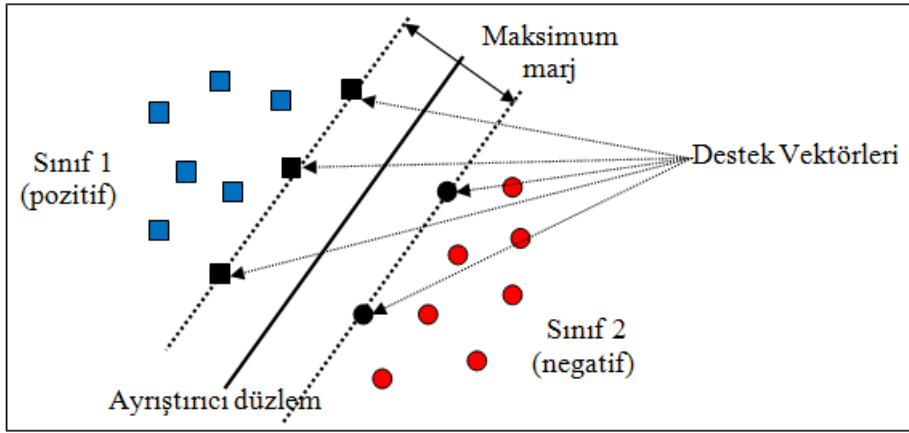
k NN sınıflayıcısındaki k değeri deneysel olarak seçilmektedir. k 'nın büyük seçilmesi sınıflandırma hatasını azaltırken, küçük seçilmesi sınıflandırmada yakın komşuların etkisini arttırmaktadır. Şekil 2.18'de $k=3$ ve $k=5$ için k NN sınıflandırma sonuçları görülmektedir. Şekil 2.18.a'da $k=3$ seçildiğinde test örneği B sınıfına sınıflandırılırken, Şekil 2.18.b'de $k=5$ için test örneği A sınıfına sınıflandırılmaktadır.



Şekil 2.18. k NN sınıflayıcısı (a) $k=3$ (b) $k=5$

2.5.1.2. Destek Vektör Makineleri ile Sınıflandırma

SVM, bir sınıflandırma ya da regresyon modeli oluşturmak için destek vektörlerini kullanan denetimli bir öğrenme algoritmasıdır (Cortes ve Vapnik, 1995). SVM'nin temel amacı iki sınıflı ayırabilen lineer bir hiperdüzlemin bulunmasıdır. Bu hiperdüzlem sınıflar arası mesafeyi maksimize ederken, sınıfları ayırma hatasını minimize etmektedir. Optimal bir SVM hiperdüzlemi Şekil 2.19'da görülmektedir.



Şekil 2.19. Optimal SVM hiperdüzlemi

İki sınıflı bir sınıflandırma probleminde eğitim örnekleri \mathbf{x}_i , eğitim örneklerine karşılık gelen sınıf etiketleri y_i ile aşağıdaki gibi tanımlansın.

$$\{(\mathbf{x}_i, y_i) \mid \mathbf{x}_i \in R^n, y_i \in \{-1, +1\}\}_{i=1}^M \quad (2.22)$$

Linear SVM, bu iki sınıflı ayıran bir hiperdüzlemin olduğunu varsayar. Bu düzlem aşağıdaki denklemle ifade edilir.

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad \mathbf{x} \in R^n, \mathbf{w} \in R^n, b \in R \quad (2.23)$$

Denklemde \mathbf{w} düzlemin normalini, b ise düzlemin orijinden uzaklığını belirtmektedir. Bu denklem y etiketine sahip \mathbf{x} veri noktası için aşağıdaki gibi bir karar kuralı oluşturmak için kullanılabilir.

$$y = \begin{cases} +1, & f(\mathbf{x}) \geq 0 \\ -1, & f(\mathbf{x}) < 0 \end{cases} \quad (2.24)$$

Eğitim aşamasında, eğitim ve test kümelerindeki tüm örnekler için doğru sonuç verecek şekilde \mathbf{w} ve b parametreleri belirlenir. Lineer SVM için iyi bir genelleştirme yeteneği, sınıflar arasında maksimum marjın bulunmasıyla elde edilebilir. Diğer bir ifadeyle, ayrıştırıcı hiperdüzleme yakın noktalar arasındaki mesafenin maksimize edilmesi gerekmektedir. Bu ise aşağıda verilen optimizasyon probleminin çözülmesini gerektirir.

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad \text{Kısıtlama: } y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad i = 1, \dots, M \quad (2.25)$$

Bu problemin çözümü zor olduğundan Lagrange çarpanlarının (α) eklenmesi ile bu kısıtlı problem aşağıdaki şekilde ifade edilebilir.

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 + \sum_{i=1}^M \alpha_i y_i (\mathbf{w}^T \mathbf{x}_i + b) + \sum_{i=1}^M \alpha_i, \quad \alpha_i \geq 0 \quad (2.26)$$

Bu dışbükey ikinci dereceden programlama probleminin çözülmesi, problemin aşağıda verilen formülasyonunun çözülmesi ile eşdeğerdir.

$$\max_{\alpha} L(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i=1}^M \sum_{j=1}^M \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$$


$$\text{Kısıtlama: } \sum_{i=1}^M \alpha_i y_i = 0, \quad \alpha_i \geq 0 \quad i = 1, \dots, M \quad (2.27)$$

Sınıf etiketi bilinmeyen bir \mathbf{x} örneği için karar fonksiyonu ise aşağıdaki şekle dönüşür. Denklemden SV destek vektörlerini ifade etmektedir.

$$y = \text{sgn} \left(\sum_{i \in SV} \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + b \right) \quad (2.28)$$

Gerçek uygulamalarda verilerin çok azı lineer bir hiperdüzlem ile ayrılabilir. Bu nedenle sadece lineer sınıflandırmaya imkan sağlayan lineer SVM, çekirdek hilesi ile değiştirilebilir. Şekil 2.20.a'da görüldüğü gibi veriler arasında lineer ayırma

yapılamamaktadır. Ayırtırmayı yapabilmek için bir eğri, sınır olarak çizilmelidir. Ayırma işlemi çekirdek hilesiyle lineer olmayan uzayda Şekil 2.20.b'de görüldüğü gibi yapılabilir.



Şekil 2.20. SVM'de çekirdek hilesi (a) Lineer ayrıştırılamayan veriler (b) Çekirdek hilesi sonucu lineer ayrıştırılabilen veriler

Lineer olmayan yollarla ayrılabilen veriler, çekirdek fonksiyonu olarak adlandırılan,

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j) \rangle \quad (2.29)$$

haritalama fonksiyonu ile daha büyük boyutlu bir uzaya taşınır. Bu fonksiyon sayısal çarpım gibi davranarak hesaplama maliyetini düşürmektedir. Böylece lineer olmayan SVM, 2.27 denklemindeki $\mathbf{x}_i^T \mathbf{x}_j$ ifadesinin $K(\mathbf{x}_i, \mathbf{x}_j)$ ile değiştirilmesi sonucu aşağıdaki gibi elde edilir.

$$\sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i=1}^M \sum_{j=1}^M \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (2.30)$$

Bu durumda karar kuralı ise,

$$y = \text{sgn} \left(\sum_{i \in SV} \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}_j) + b \right) \quad (2.31)$$

şeklinde olur. SVM'nin kullandığı çekirdek fonksiyonları Tablo 2.2'de verilmiştir. Çalışmada verilerin lineer olmayan dağılımı göz önünde tutularak, radyal tabanlı çekirdek fonksiyonu kullanılmıştır.

Sınıflayıcın eğitimi sırasında radyal tabanlı çekirdek fonksiyonu kullanan SVM sınıflayıcısı için, C (cost) ve γ (gamma) parametrelerinin optimizasyonu gerçekleştirilmiştir. SVM pozitif ve negatif örnekleri birbirinden ayıran bir düzlem bulmaya çalışır. Örneklerden bazıları yanlış etiketlenmiş ya da olağandışı ise uydurulan model yetersiz kalabilmektedir. Bu nedenle bazı örneklerin göz ardı edilmesine ya da sınırın yanlış tarafında yerleşimine imkan sağlayan yumuşak marjlı (soft-margin) SVM düşüncesi oluşturulmuştur. Burada C parametresi her bir destek vektörünün etkisini denetleyen yumuşak marj fonksiyonunun, γ ise Gauss çekirdeğinin parametresidir. C'nin düşük olması karar yüzeyini yumuşak yapar ve yanlış taraftaki örneklere izin verilir. C'nin büyük olması tüm örneklerin doğru sınıflandırılmasını amaçladığı için daha fazla örneğin destek vektörü olarak seçilmesine neden olur. γ model tarafından destek vektörü olarak seçilen örneklerin etki alanlarını belirlemektedir. Küçük değerler etki alanını genişletirken büyük değerler etki alanını daraltmaktadır.

Çalışmada C ve γ parametreleri eğitim kümesindeki örnekler kullanılarak ızgara arama (grid search) yöntemi ile belirlenmiştir. Bu parametreler için belirlenen aralıktaki değerlerden en iyi sonucu verenler çapraz doğrulama yöntemi ile elde edilmiştir. Eğitim kümesinden elde edilen bu parametreler kullanılarak test kümesi için sınıflandırma gerçekleştirilmiştir.

Tablo 2.2. SVM çekirdek fonksiyonları

Çekirdek Fonksiyonu	Formül
Doğrusal	$\mathbf{x}_i * \mathbf{x}_j$
Polinomal	$(\gamma \mathbf{x}_i \cdot \mathbf{x}_j + \text{katsayı})^{\text{derece}}$
Radyal tabanlı fonksiyon (RBF)	$\exp(-\gamma \mathbf{x}_i * \mathbf{x}_j ^2)$
Sigmoid	$\tanh(\gamma \mathbf{x}_i \cdot \mathbf{x}_j + \text{katsayı})$

SVM iki sınıflı sınıflandırma problemlerinin çözümü için tasarlanmıştır. Çok sınıflı sınıflandırma problemlerinin SVM ile çözülmesi için bire-karşı-bir ya da bire-karşı-hepsi yöntemleri kullanılır. k sınıflı bir sınıflandırma probleminin çözümünde bire-karşı-bir yöntemi, k sınıfın tüm ikili kombinasyonlarını temsil eden $k(k-1)/2$ adet SVM sınıflayıcısı oluşturur. Bu sınıflayıcılardan her biri, k sınıftan sadece iki tanesini birbirinden ayıracak şekilde eğitilir. Tüm sınıflayıcıların sonuçları elde edildikten sonra, çoğunluğun oylanması stratejisine göre nihai sonuç belirlenir ve veri örneği en çok oy alan sınıfa atanır. Bire-karşı-hepsi yönteminde ise her sınıf için, o sınıfı diğer sınıflardan ayıran bir SVM eğitilir. Diğer bir ifade ile k sınıflı bir sınıflandırma problemi için k adet SVM oluşturulur. Bu sınıflayıcılardan en yüksek çıkış değerine sahip olana göre karar verilerek örnek o sınıfa dahil edilir. Çalışmada bire-karşı-hepsi yöntemi ile çok sınıflı sınıflandırma gerçekleştirilmiştir.

2.5.1.3. Doğrusal Ayrıştırma Analizi ile Sınıflandırma

LDA'nın amacı nesnelerin onları temsil eden öznitelikler üzerinden iki ya da daha fazla sınıfa sınıflandırılmasıdır. Genel olarak nesne üzerindeki gözlemlere dayalı olarak nesnenin önceden tanımlanmış gruplara atanması işlemi olarak ifade edilir. Yöntemde sınıflar arasındaki farklılıklar artırılmaya çalışılırken, sınıf içi örnekler arasındaki farklar azaltılmaya çalışılmaktadır. \mathbf{X} 'in öznitelik vektörlerini, \mathbf{y} 'nin ise sınıf etiketlerini temsil ettiği bir sınıflandırma probleminde öncelikle \mathbf{X} için sınıf içi yoğunluklar belirlenir. Bir sınıfın ön olasılığını temsil eden π_k , eğitim kümesinden aşağıdaki formüle göre belirlenir.

$$\pi_k = k. \text{ sınıftaki örnek sayısı} / \text{eğitim kümesindeki örnek sayısı} \quad (2.32)$$

Daha sonra \mathbf{X} için koşullu sınıf yoğunluklarının belirlenmesi gerekir. Bu ise sonsal olasılığın Bayes kuralına göre aşağıdaki gibi hesaplanmasını gerektirir. Denklemden $f_k(\mathbf{x})$ k . sınıfın yoğunluğunu ifade etmektedir.

$$Pr(G = k | \mathbf{X} = \mathbf{x}) = f_k(\mathbf{x})\pi_k / \sum_{i=1}^N f_i(\mathbf{x})\pi_i \quad (2.33)$$


Denklem $G = k$ sınıfının koşullu olasılığını vermektedir. Sonsal olasılığın Bayes kuralına göre maksimizasyonu ise $f_k(\mathbf{x})\pi_k$ 'nin maksimize edilmesi anlamına gelir.

$$G(\mathbf{x}) = \arg \max_k Pr(G = k | \mathbf{X} = \mathbf{x}) = \arg \max_k f_k(\mathbf{x})\pi_k \quad (2.34)$$

LDA'da tüm sınıflara ait yoğunlukların Gauss dağılımına sahip olduğu varsayılmaktadır. Çok değişkenli Gauss dağılımı için şartlı yoğunluk fonksiyonu aşağıdaki gibidir.

$$f_k(\mathbf{x}) = \frac{1}{(2\pi)^{p/2} |\Sigma_k|^{1/2}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu}_k)^T \Sigma_k^{-1} (\mathbf{x}-\boldsymbol{\mu}_k)} \quad (2.35)$$

Denklemden p boyutu, Σ_k k . sınıfa ait kovaryans matrisini, $\boldsymbol{\mu}_k$ ise k . sınıfın ortalamasını temsil eder. LDA'da tüm sınıflar için aynı kovaryans matrisi kullanılmaktadır. Bu şekilde sınıflayıcı lineer hale gelir. Kovaryans matrisi Gauss yoğunluğunu belirlediği için farklı sınıfların Gauss yoğunlukları aynı şekle sahiptir fakat farklı ortalamalara sahip olduklarından Şekil 2.21'deki gibi eksende kaymış olarak görünürler.



Şekil 2.21. Farklı sınıflar için Gauss dağılımları

Sınıflara ait Gauss dağılımlarının belirlenmesinde öncelikle sınıfların ön olasılıkları π_k , denklem 2.32'ye göre hesaplanır. Sınıf ortalamaları, ilgili sınıftaki örneklerin ortalaması ile aşağıdaki gibi üretilir.

$$\mu_k = \sum_{g_i=k} \mathbf{x}^{(i)} / N_k \quad (2.36)$$

Tüm sınıflar için ortak kovaryans matrisi ise aşağıda denklem kullanılarak hesaplanır.

$$\Sigma = \sum_{k=1}^K \sum_{g_i=k} (\mathbf{x}^{(i)} - \boldsymbol{\mu}_k)(\mathbf{x}^{(i)} - \boldsymbol{\mu}_k)^T / (N - K) \quad (2.37)$$

Burada optimal sınıflandırma Bayes kuralına göre gerçekleştirilir ve en büyük sonsal olasılığa sahip olan k sınıfı seçilir. Bu ise ön olasılıkların ve sınıf içi yoğunlukların çarpımının maksimizasyonu anlamına gelir. Diğer bir ifade ile sınıfların ön olasılıkları ile ortak kovaryansa sahip Gauss dağılımlarının çarpımının maksimize edilmesi gerekir. Log işleminin uygulanması ile LDA sınıflayıcısı sadeleştirilerek,

$$G(\mathbf{x}) = \arg \max_k \mathbf{x}^T \Sigma^{-1} \boldsymbol{\mu}_k - \frac{1}{2} \boldsymbol{\mu}_k^T \Sigma^{-1} \boldsymbol{\mu}_k + \log(\pi_k) \quad (2.38)$$

şekline dönüşür.

Yukarıda açıklanan yöntemlerle herhangi bir görüntünün, yaş gruplarından birine sınıflandırılması gerçekleştirilmektedir. Daha sonra ise belirlenen yaş grubu içerisinde kişinin gerçek yaş etiketinin tahmini yapılmaktadır. Çalışmada kişinin gerçek yaş etiketini tahmin etmek için kullanılan yöntem bir sonraki bölümde açıklanmaktadır.

2.5.2. Yaş Etiketinin Belirlenmesi

Yüz görüntülerinden yaşla ilgili özniteliklerin çıkarılmasının ardından, yaşın tahmini bir regresyon ya da sınıflandırma problemi olarak ele alınabilir. Çalışmada yaşın tahmininde MLR yöntemi (Jobson, 1991) kullanılmıştır. MLR bağımlı bir değişkenle, bir ya da daha fazla bağımsız değişkenin arasındaki lineer ilişkinin modellenmesi için kullanılan bir yöntemdir. MLR'de en küçük kareler yöntemiyle oluşturulan modelle, izlenen ve tahmin edilen değerler arasındaki hatanın minimize edilmesi sağlanmaktadır. Çalışmada kullanılan yaşlanma fonksiyonu genel olarak aşağıdaki gibi ifade edilmektedir.

$$yaş = f(\mathbf{M}) \Leftrightarrow \hat{\mathbf{l}} = \hat{f}(\mathbf{Y}) \quad (2.39)$$

Denklemden \hat{l} tahmin edilen yaş etiketlerini, $f(\cdot)$ bilinmeyen yaşlanma fonksiyonunu ve $\hat{f}(\cdot)$ tahmin edilen yaşlanma fonksiyonunu ifade etmektedir. Matris olarak ifade edildiğinde;

$$l = \tilde{Y}b + e, \text{Var}(e) = \sigma^2 I \quad (2.40)$$

Denklemden l yaş etiket vektörünü, \tilde{Y} izlenebilen değerler için 1'ler sütunu içeren bilinen bir matrisi, b ise bilinmeyen parametre vektörünü ifade etmektedir. b parametre vektörü, öğrenme sürecinde yaklaşık olarak tahmin edilmektedir. e ise izlenemeyen rasgele değişkenleri içeren, ortalaması 0, varyansı σ^2 olan hata vektörüdür. Model uydurma kısmında b vektörü en küçük kareler, $(\tilde{Y}'\tilde{Y})^{-1}\tilde{Y}'l = Hl$ ile ya da güçlü regresyon analizi ile belirlenir. Bu modele bağlı olarak l 'nin tahmini değeri ise;

$$\hat{l} = \tilde{Y}\hat{b} \quad (2.41)$$

ile hesaplanabilir. Hata vektörü ise $E(\hat{e}) = 0$ ve $\text{Var}(\hat{e}) = \sigma^2(I - H)$ olan $\hat{e} = l - \hat{l}$ 'dir.

2.5.2.1. Yaşlanma Fonksiyonu

Regresyon aşamasında lineer fonksiyon kullanımının, verilerin gösteriminde yetersiz kalabileceği, kübik ya da daha yüksek dereceli fonksiyonların ise verileri temsil etme aşamasında işlem karmaşıklığını artıracakları bilinmektedir (Lanitis vd., 2002; Fu vd., 2008). Bu nedenle çalışmada yaşlanma süreci karesel yaşlanma fonksiyonu ile modellenmiştir. Yaşlanma fonksiyonu genel olarak,

$$Y\beta = l \quad (2.42)$$

ile ifade edilebilir. Bu denklemde $n \times (2m+1)$ boyutlu Y , n örnekten oluşan eğitim kümesinde, her bir örnek için üretilen m elemanlı $y = [y_1 \dots y_m]$ öznitelik vektörleri ve $y^2 = [y_1^2 \dots y_m^2]$ vektörlerinin birleşiminden oluşan matris, $n \times 1$ boyutlu $l = [l_1 \dots l_n]^T$ eğitim kümesindeki örneklere ait yaş etiketlerini içeren vektördür. $(2m+1) \times 1$ boyutlu $\beta = [\beta_0 \cup \beta_1 \cup \beta_2]$ ise ağırlık katsayılarını içeren vektördür. Burada β_0 ofset değerini,

$\beta_1 = [\beta_{1,1} \dots \beta_{1,m}]^T$, \mathbf{y} vektöründeki her bir değer için eğitim kümesinden öğrenilen ağırlık katsayılarını, $\beta_2 = [\beta_{2,1} \dots \beta_{2,m}]^T$ ise \mathbf{y}^2 vektöründeki her bir eleman için eğitim kümesinden öğrenilen ağırlık katsayılarını ifade etmektedir. Daha açık bir ifade ile \mathbf{y} öznitelik vektörleri üretilmiş ve l yaş etiketleri bilinen n örnekten oluşan eğitim kümesi üzerinden karesel yaşlanma fonksiyonunun öğrenilmesi, denklem 2.43'te verilen ifadede β katsayılarının belirlenmesi anlamına gelmektedir.

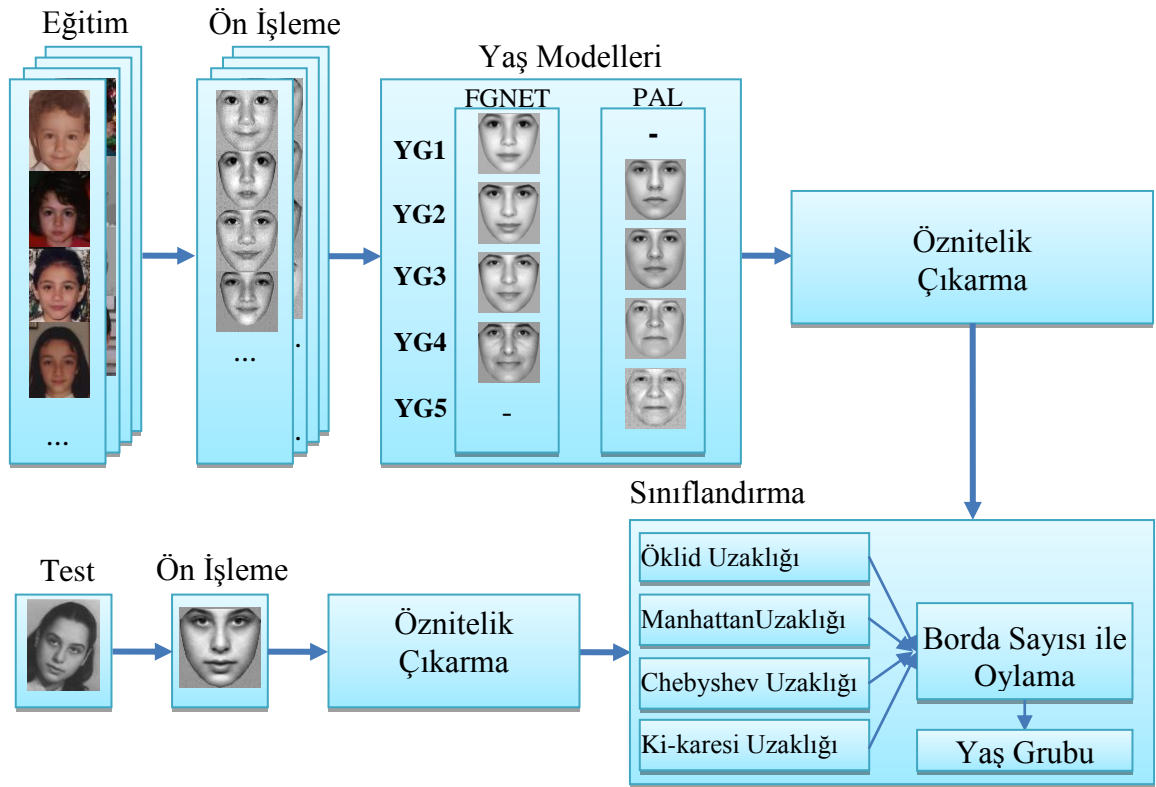
$$\begin{bmatrix} 1 & y_{1,1} & y_{1,2} & \dots & y_{1,m} & y_{1,1}^2 & y_{1,2}^2 & \dots & y_{1,m}^2 \\ & & & & \vdots & & & & \\ & & & & \vdots & & & & \\ 1 & y_{n,1} & y_{n,2} & \dots & y_{n,m} & y_{n,1}^2 & y_{n,2}^2 & \dots & y_{n,m}^2 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_{1,1} \\ \beta_{1,2} \\ \vdots \\ \beta_{1,m} \\ \beta_{2,1} \\ \beta_{2,1} \\ \vdots \\ \beta_{2,m} \end{bmatrix} = \begin{bmatrix} \hat{l}_1 \\ \vdots \\ \hat{l}_n \end{bmatrix} \quad (2.43)$$

Çalışmada β katsayıları en küçük kareler (least squares) yöntemiyle belirlenmektedir. Bu katsayılar eğitim kümesinden belirlendikten sonra herhangi bir test örneği için üretilen $\mathbf{x} = [x_1 \dots x_m]^T$ öznitelik vektörü üzerinden yaşın tahmini denklem 2.44 ile gerçekleştirilmektedir.

$$l = \beta_0 + \beta_1^T \mathbf{x} + \beta_2^T \mathbf{x}^2 \quad (2.44)$$

2.6. Model Tabanlı Yaş Tahmini Yaklaşımı

Bu tez çalışmasında ilk kez model tabanlı bir yaş tahmini yöntemi önerilmektedir. Önerilen yöntemin genel yapısı Şekil 2.22'de görülmektedir. Yöntemde, yaş gruplarının ortak özelliklerini içeren yaş modellerinin üretilmesi ve bu modeller üzerinden görüntülerin yaş gruplarına sınıflandırılması amaçlanmıştır. Yaş modelleri, yaş gruplarından seçilen yüz görüntülerinin ön işleme aşamasından geçirildikten sonra morfleme yöntemiyle birleştirilmesi sonucunda üretilmektedir. Yüz görüntülerinin ortalaması alındığında iki ağızlı iki kaşlı vb. görüntüler ortaya çıkmaktadır. Bu ise farklı görüntüler için farklı sonuçlar doğurmaktadır. Bu açıdan tüm yaş gruplarına ait yaklaşık



Şekil 2.22. Önerilen model tabanlı yaş grubuna sınıflandırma yönteminin genel yapısı

aynı uzaklıkta olan bir invaryantın belirlenmesi gerekmektedir. Çalışmada her bir yaş grubu için böyle bir invaryant görüntü oluşturmak için morflmeye dayalı yaş modelleri üretilmiştir. Yaş grubundan seçilen görüntülerdeki piksel dağılımından bölgesel ortalamalar alınarak modeller oluşturulduğundan, elde edilen sonuç görüntüsü ilgili yaş grubunu temsil etmektedir.

Bir yaş grubuna ait yaş modelinin üretilmesinde, yaş grubundan seçilen n adet görüntünün morflenmesi denklem 2.45 ile ifade edilebilir. Denklemde M üretilen yaş modelini, m morfleme işleminde kullanılan bölge sayısını, $B_{j,i}$ ise i . görüntüdeki j . bölgeyi temsil etmektedir. Sonuç olarak morflenmiş görüntüdeki her bir bölge, görüntülerde bu bölgeye karşılık gelen farklı boyuttaki bölgelerin ortak bir düzleme iz düşürülmesi (denklemde f ile ifade edilmiştir) ve ortalamasının alınması ile oluşturulmaktadır. Bu nedenle üretilen yaş modellerinde her bir bölge, o yaş grubundan seçilen yüz görüntülerinin aynı bölgelerindeki verilerin ortalamasını tutmaktadır. Sonuç olarak bir yaş modeli, ait olduğu yaş grubunun ortalama yaş karakteristiklerini temsil etmektedir.

$$M = \bigcup_{i=1}^n \frac{\sum_{j=1}^m f(B_{j,i})}{m} \quad (2.45)$$

Ayrıca tanıma başarısını yükseltmek için giriş resimlerinin 180 derece yansıması alınarak görüntüler düzleştirilmiş ve modellerle karşılaştırması gerçekleştirilmiştir. Bunun sonucunda yüz ifadesi ve poz değişikliklerinden oluşan problemler giderilebilir. Morflenmiş modelin gerçeğe benzer olması için çalışmada yaş gruplarından üç yaş aralıklarla örnekler alınarak model görüntüleri oluşturulmuştur. Bu model görüntüler başlangıçta cinsiyet farkı dikkate alınarak elde edilmiş daha sonra birleştirilerek bir yaş grubu için genel bir model oluşturulmuştur.


Yaş modellerinin oluşturulmasının ardından, bu modellerden öznitelikler çıkarılmaktadır. Ön işleme aşamasından geçen herhangi bir test görüntüsünden çıkarılan öznitelikler, yaş modellerinden çıkarılan özniteliklerle karşılaştırılarak, görüntünün mevcut yaş gruplarından birine sınıflandırılması sağlanmaktadır. Bir sonraki bölümde önerilen model tabanlı yaş tahmini sisteminde yaş modellerinin oluşturulması hakkında detaylı bilgi verilmektedir.

2.6.1. Yaş Modelleri

Yaş modelleri yaş gruplarının ortak özelliklerini temsil etmek amacıyla üretilen, ilgili yaş grubundan seçilen birden fazla görüntünün birleşiminden oluşan ortalama görüntülerdir. Bu modellerin üretilmesi aşamasında görüntülerin birleştirilmesi amacıyla kullanılan görüntü morfleme tekniği bir sonraki bölümde anlatılmaktadır. Daha sonraki bölümde ise önerilen yaş grupları için yaş modellerinin üretilmesi açıklanmaktadır.

2.6.1.1. Görüntü Morfleme

Görüntü morfleme, kaynak görüntünün hedef görüntüye düzgün bir şekilde dönüştürülmesi yöntemidir. Yöntem hareketli görüntülerde özel efektlerin üretilmesi için sıklıkla kullanılmaktadır. Diğer yandan, bilgisayarla görme, tıbbi görüntü işleme gibi alanlarda pek çok uygulamaya sahiptir (Alexa vd, 2000; Fu ve Foroosh, 2004; Nöllenburg vd., 2008). Morfleme işlemi sırasında bir dizi ara görüntü üretilmektedir. Şekil 2.23'te morfleme işlemi için örnek bir görüntü dizisi verilmiştir.




Şekil 2.23. Morfleme işlemi (a)Kaynak görüntü (d-f) Morfleme sürecinde üretilen ara görüntüler (g) Hedef görüntü

Kaynak görüntü Şekil 2.23.a'da, hedef görüntü ise Şekil 2.23.g'de görülmektedir. Morfleme işlemi bir görüntünün başka bir görüntüye aşamalı olarak dönüştürülmesini ifade eder. Morflemede yapılan işlem iki görüntünün belirli oranlarda birleştirilmesidir. Oranların belirlenmesinde üretilen ara görüntü sayısı dikkate alınmaktadır. Genel olarak, üretilen ara görüntü sayısı n ise, birleştirme oranı için artım miktarı $100/(n+1)$ ile hesaplanır. Şekil 2.23'teki morfleme işleminde, üretilen ara görüntüler Şekil 2.23.b-f'de verilmiştir. Üretilen ara görüntü sayısı 5 olduğu için birleştirme oran artım miktarı $100/6 \approx 16.6$ olarak belirlenmiştir. Her ara görüntü üretiminde, kaynak görüntünün oranı 100'den başlayarak bu miktar kadar azaltılırken, hedef görüntünün oranı 0'dan başlayarak bu miktar kadar arttırılmaktadır. Dolayısı ile Şekil 2.23.b kaynak görüntünün %84.6'sı ile hedef görüntünün %16.6'sının birleşiminden oluşmaktadır. Şekil 2.23.d'nin üretilmesi sırasında birleştirme oranları %50, %50 iken Şekil 2.23.f için birleştirme oranları sırasıyla %16.6 ve %84.4'tür. Sonuç olarak morfleme süreci ilerledikçe kaynak görüntü kaybolmakta, hedef görüntü ortaya çıkmaktadır. Görüldüğü gibi oluşan görüntü dizisinde ilk yarıdaki görüntüler kaynak görüntüye, ikinci yarıdakiler ise hedef görüntüye daha çok benzemektedir. Dizinin tam ortasındaki görüntü ise kaynak ve hedef görüntüsünün ortalamasıdır.

Görüntülerin morflenmesinde çeşitli yöntemler kullanılabilir. Geometrik tabanlı yöntemler (Gashtasby, 1986) görüntüleri kontrol noktaları üzerinden bölgelere ayırmakta ve morfleme işlemini bu bölgeler üzerinden gerçekleştirmektedir. Alan morfleme (Beier ve Neely, 1992) yöntemi ise görüntülerde tanımlanan bir dizi doğru üzerinden koordinat dönüşümlerini gerçekleştirmektedir.

2.6.1.1.1. Geometrik Tabanlı Morfleme

Geometrik tabanlı morfleme yöntemleriyle bir görüntünün başka bir görüntüye dönüştürülebilmesi için, bu görüntüler üzerinde bazı kontrol noktalarına ihtiyaç duyulur. Bu noktalar Şekil 2.24.a'da görüldüğü gibi yüzün çevresini, göz merkezlerini, burnu ve ağız kenarlarını belirleyen noktalardır. Kontrol noktaları belirlendikten sonra, bu noktalar kullanılarak görüntü Şekil 2.24.b'deki gibi birbiri üzerine gelmeyen bölgelere parçalanmakta ve bu bölgeler üzerinde geometrik dönüşümler gerçekleştirilmektedir.



Şekil 2.24. Morfleme işleminde kullanılan (a) kontrol noktaları ve (b) bölgeler

Şekil 2.24'te gözbebekleri (2), burun (1), ağız kenarları (2) ve yüz çevresi (6) toplam 11 kontrol noktası ile belirlenmiştir. Bu noktalar kullanılarak yüz görüntüsü 14 üçgensel, 5 dörtgensel bölgeye ayrılmıştır. Bu kontrol noktaları aynı zamanda morfleme sürecindeki üretilen ara görüntülerin kontrol noktalarının belirlenmesinde kullanılmaktadır. Kaynak ve hedef görüntüleri, üretilen ara kontrol noktalarına göre eğriltildikten sonra morfleme sürecini tamamlamak için renk interpolasyonu gerçekleştirilmektedir. Morfleme işlemi sonucu üretilen ara görüntünün kalitesi kontrol noktalarının pozisyonuna ve sayısına bağlıdır (Karungaru vd., 2004). Nokta sayısı arttıkça oluşan bölge sayısı da artmakta, bu ise sonuç görüntüsünün kalitesini arttırmaktadır.

Kontrol noktaları belirlenmiş ve bölgelere ayrılmış iki kaynak görüntünün morflenmesi aşağıdaki işlem adımlarını içermektedir. Görüntüler arasında bir ara görüntü oluşturmak için birinci görüntüye α ve ikinci görüntüye $(1 - \alpha)$ ağırlıkları verilir. Birinci görüntüdeki herhangi bir A kontrol noktası ve ikinci görüntüde ona karşılık gelen B kontrol noktası kullanılarak, yeni bir kontrol noktası (F) lineer interpolasyon yöntemiyle aşağıdaki gibi üretilir.

$$F = \alpha A + (1 - \alpha)B \quad (2.46)$$

Oluşturulacak ara görüntü için üretilen bu kontrol noktaları, görüntüyü iki kaynak görüntüye ait kontrol noktalarından farklı bir şekilde bölgelere ayırmayı sağlayacaktır. Daha sonra kaynak görüntüler, kendi kontrol noktaları denklem 2.46'ya göre üretilen kontrol noktalarıyla eşleşecek şekilde eğritilirler. Eğritme işleminde kaynak görüntülerdeki her bir bölge, ara görüntüde kendilerine karşılık gelen bölgeye iz düşürülmektedir. Şekil 2.24.b'de görülen üçgensel bölgelerin dönüştürülmesinde afin dönüşüm, dörtgensel bölgelerin dönüştürülmesinde ise bilineer dönüşüm kullanılmaktadır.

Afin dönüşüm bir ABC üçgeninden DEF üçgenine lineer bir haritalama sağlar. ABC üçgeni içerisindeki herhangi bir p noktasının pozisyonu köşe koordinatları ile aşağıdaki gibi ifade edilebilir.


$$p = \lambda_1 A + \lambda_2 B + \lambda_3 C \quad (2.47)$$

$$\lambda_1 + \lambda_2 + \lambda_3 = 1 \quad (2.48)$$

Bu denklemlerden λ_1 , λ_2 ve λ_3 'ün hesaplanması ile birlikte, afin dönüşüm iki üçgen arasında bire bir haritalama işlemine dönüşür. ABC üçgenindeki p noktasına DEF üçgeninde karşılık gelen q noktası ise aşağıdaki denklemlerle hesaplanır.

$$q = \Phi(p) = \lambda_1 D + \lambda_2 E + \lambda_3 F \quad (2.49)$$

Burada hesaplanan q noktasının koordinatları her zaman tamsayı olarak elde edilemez. Bu nedenle çalışmada bilineer interpolasyon yöntemi (denklem 2.50) kullanılarak, elde edilen q noktasına karşılık gelen piksel parlaklık değeri, bu nokta etrafındaki parlaklıkların interpolasyonu ile elde edilmiştir. Şekil 2.25'te görüldüğü gibi bilinmeyen $I(x,y)$ 'nin hesaplanmasında nokta etrafındaki bilinen $I(x_1,y_1)$, $I(x_1,y_2)$, $I(x_2,y_1)$ ve $I(x_2,y_2)$ değerleri için öncelikle x yönünde daha sonra y yönünde lineer interpolasyon denklem 2.50'ye göre gerçekleştirilir.



Şekil 2.25. Bilineer interpolasyonda kullanılan noktalar

$$\begin{aligned}
 I(x, y_1) &= \frac{x_2 - x}{x_2 - x_1} I(x_1, y_1) + \frac{x - x_1}{x_2 - x_1} I(x_2, y_1) \\
 I(x, y_2) &= \frac{x_2 - x}{x_2 - x_1} I(x_1, y_2) + \frac{x - x_1}{x_2 - x_1} I(x_2, y_2) \\
 I(x, y) &= \frac{y_2 - y}{y_2 - y_1} I(x, y_1) + \frac{y - y_1}{y_2 - y_1} I(x, y_2)
 \end{aligned} \tag{2.50}$$

Bilineer dönüşüm ise $ABCD$ dörtgeninden $EFGH$ dörtgenine lineer bir haritalama yöntemidir. $ABCD$ dörtgeninin içindeki herhangi bir p noktasının pozisyonu, dörtgenin köşe noktaları ile denklem 2.51'deki gibi ifade edilebilir. Bu denklemdeki u ve v değerlerinin çözülmesiyle, $ABCD$ dörtgenindeki p noktasına, $EFGH$ dörtgeninde karşılık gelen q noktası denklem 2.52 ile hesaplanır. Bu sayede bilinear dönüşüm de afin dönüşüm gibi birebir haritalama işlemi haline gelir.

$$\begin{aligned}
 p &= (1 - u)(1 - v) A + u(1 - v) B + uv C + (1 - u)v D \\
 0 &\leq u, v \leq 1
 \end{aligned} \tag{2.51}$$

$$q = (1 - u)(1 - v) E + u(1 - v) F + uv G + (1 - u)v H \tag{2.52}$$


Eğriltme işleminde koordinat dönüşümleri sırasıyla tüm bölgeler için yapılır. Her iki kaynak görüntü, ara görüntü için üretilen kontrol noktalarına göre eğriltildiği için, kontrol noktaları eşleşmiş olur. Morfleme işlemini tamamlamak için kontrol noktalarına benzer şekilde eğriltilmiş görüntülerdeki piksel parlaklık değerleri için aşağıdaki gibi interpolasyon işlemi gerçekleştirilir.

$$I_{morph}(x, y) = \alpha I_1(x, y) + (1 - \alpha) I_2(x, y) \quad 0 \leq \alpha \leq 1 \quad (2.53)$$

Denklemde $I_1(x, y)$ ve $I_2(x, y)$ eğriltelen kaynak görüntülerini, $I_{morph}(x, y)$ ise morfleme sonucu üretilen ara görüntüyü ifade etmektedir.

2.6.1.1.2. Alan Morfleme

Alan morfleme tekniğinde kaynak ve hedef görüntüler arasındaki koordinat dönüşümü, bu görüntülerde tanımlanan bir dizi doğru üzerinden gerçekleştirilmektedir. Şekil 2.26'da kaynak ve hedef görüntüler üzerindeki yüz, göz, burun ve ağız bölgeleri 25 doğru ile belirlenmiştir.

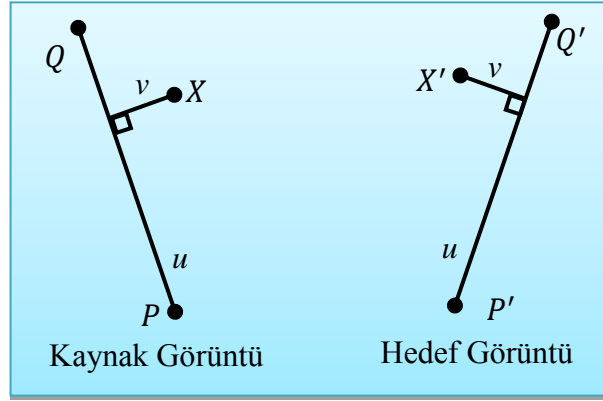


Şekil 2.26. Kaynak ve hedef görüntüler için tanımlanmış doğrular

Alan morfleme yönteminde, Şekil 2.27'de görüldüğü gibi, kaynak görüntüdeki herhangi bir X pikseli ve PQ doğrusu için, X 'in PQ doğrusu boyunca pozisyonunu ifade eden u parametresi ve PQ doğrusundan X 'e olan dik uzaklığı temsil eden v parametresi denklem 2.54 ile hesaplanmaktadır. Hedef görüntüde bu X noktasına karşılık gelen X' noktası ise, hedef görüntüde PQ doğrusuna karşılık gelen $P'Q'$ doğrusu ve hesaplanan u, v parametreleri kullanılarak denklem 2.55 ile hesaplanmaktadır.

$$u = \frac{(X-P) \cdot (Q-P)}{\|Q-P\|^2}, \quad v = \frac{(X-P) \cdot \perp(Q-P)}{\|Q-P\|} \quad (2.54)$$

$$X' = P' + u \cdot (Q' - P') + \frac{v \cdot \perp(Q' - P')}{\|Q' - P'\|} \quad (2.55)$$



Şekil 2.27. Bir doğru ile alan morfleme

Kaynak ve hedef görüntülerinde sadece PQ , $P'Q'$ doğruları varsa, kaynak görüntüde PQ doğrusunun etrafındaki tüm pikseller, hedef görüntüde $P'Q'$ doğrusunun etrafındaki bölgeye haritalanır. Bu algoritma Şekil 2.28'de verilmiştir.


```

for (x = 0; x < resimGenişlik; x++)
  for (y = 0; y < resimYükseklik; y++)
    X = [x y]
    u = (X - P) . (Q - P) / ||Q - P||2
    v = (X - P) . ⊥ (Q - P) / ||Q - P||
    X' = P' + u . (Q' - P') + v . ⊥ (Q' - P') / ||Q' - P'||
    hedefGörüntü[X'] = kaynakGörüntü [X]

```

Şekil 2.28. Bir doğru çifti (PQ , $P'Q'$) için alan morfleme algoritması

Birden fazla doğruya sahip görüntülerde ise dönüşüm daha karmaşık bir yapıya sahiptir. Şekil 2.29'da iki doğruya sahip bir alan morfleme örneği görülmektedir. Birden fazla doğrunun olduğu durumda, kaynak görüntüdeki bir pikselin görüntüdeki n adet doğruya göre pozisyonunu ve uzaklığını ifade eden n adet u ve v parametreleri üretilmektedir. Bu durumda hedef görüntüde, u ve v parametrelerinin ve ilgili doğruların kullanılması sonucunda n adet nokta üretilecektir. Bu noktaların birleştirilmesiyle tek bir noktanın üretilmesi için, noktaların ağırlıkları hesaplanmaktadır. n noktanın her biri için denklem 2.56 kullanılarak ağırlıklar üretildikten sonra, noktaların ağırlıklı ortalaması alınarak tek bir nokta elde edilmektedir. Noktanın ağırlığı hesaplanırken, noktanın doğruya olan uzaklığı dikkate alınmaktadır. Nokta doğruya ne kadar yakınsa ağırlığı o kadar fazla olacaktır.



Şekil 2.29. İki doğru ile alan morfleme

$$w_i = (l_i^p / (a + d_i))^b \quad (2.56)$$

Denklemden l_i i . doğrunun uzunluğunu, d_i X noktasından doğruya olan uzaklığı ifade etmektedir. Diğer yandan a parametresi doğrunun kuvvetini belirlemektedir. Küçük değere sahip olması doğruya yakın olan noktaları, uzaktaki noktalara göre daha fazla etkilemektedir. Büyük değere sahip olması ise hem yakın hem de uzaktaki noktaları etkilemektedir. Bu ise daha düzgün bir morfleme işlemi sağlamakla beraber daha az kontrol sağlamaktadır. b parametresi doğruların uzaklığa bağlı olarak noktaya olan etkilerini kontrol etmektedir. Değeri büyük ise, sadece noktaya yakın olan doğrular o noktaya etki edecektir. $b=0$ olduğunda ise tüm noktalar tüm doğrular tarafından eşit şekilde etkilenecektir. p parametresi ise $[0, 1]$ arasında değer almaktadır. 0 değerine sahipse tüm doğrular aynı ağırlığa sahiptir. 0'dan büyük olduğunda daha uzun doğrular daha büyük ağırlığa sahip olmaktadır. Bu algoritma Şekil 2.30'da görülmektedir.

Alan morfleme yöntemi bölgelere dayalı morflemeye göre çok daha karmaşık ve yavaştır. Çünkü her bir noktanın haritalanması için tüm doğru çiftlerinin dikkate alınması gerekmektedir.

Çalışmada öncelikle yüz görüntülerinden otomatik olarak 11 belirleyici noktanın (Şekil 2.24) tespiti sağlanmış ve bu noktalar ile görüntü üçgensel ve dörtgensel bölgelere ayrılarak morfleme işlemi gerçekleştirilmiştir. Burada üretilen kontrol nokta sayısının azlığı morfleme sonuçlarının yeterince iyi olmamasına neden olmuştur (Şekil 2.31.b). Daha iyi sonuçlar elde etmek amacıyla alan morfleme yöntemi kullanılmıştır (Şekil 2.31.c). Fakat alan morfleme yönteminin işlem karmaşıklığı ve zaman alıcı olması

nedeniyle çalışmada, kullanılan kontrol noktalarının sayısı artırılarak geometrik tabanlı morfleme yöntemi tercih edilmiştir.

```

for (x = 0; x < resimGenişlik; x++)
  for (y = 0; y < resimYükseklik; y++)
    X = [x y]; DSUM = [0 0]; wtoplam = 0;
    for (i = 0; i < doğruSayısı; i++)
      ui = (X - Pi) · (Qi - Pi) / ||Qi - Pi||2
      vi = (X - Pi) · ⊥ (Qi - Pi) / ||Qi - Pi||
      Xi' = Pi' + ui · (Qi' - Pi') + vi · ⊥ (Qi' - Pi') / ||(Qi' - Pii = Xi' - X
      di = (ui < 0)? ||X - Pi||: ((ui > 1)? ||X - Qi||: abs(vi))
      wi = (lip / (a + di))b
      DSUM += Di · wi
      wtoplam += wi
    X' = X + DSUM / wtoplam
  hedefGörüntü[X'] = kaynakGörüntü [X]

```

Şekil 2.30. Birden fazla doğru çifti ($P_i Q_i, P_i' Q_i'$) için alan morfleme algoritması



Şekil 2.31. Morfleme yöntemiyle üretilen ortalama yüzler (a) Birinci kaynak resim (b) Geometrik tabanlı morfleme ile üretilen ortalama yüz (c) Alan morfleme ile üretilen ortalama yüz (d) İkinci kaynak resim

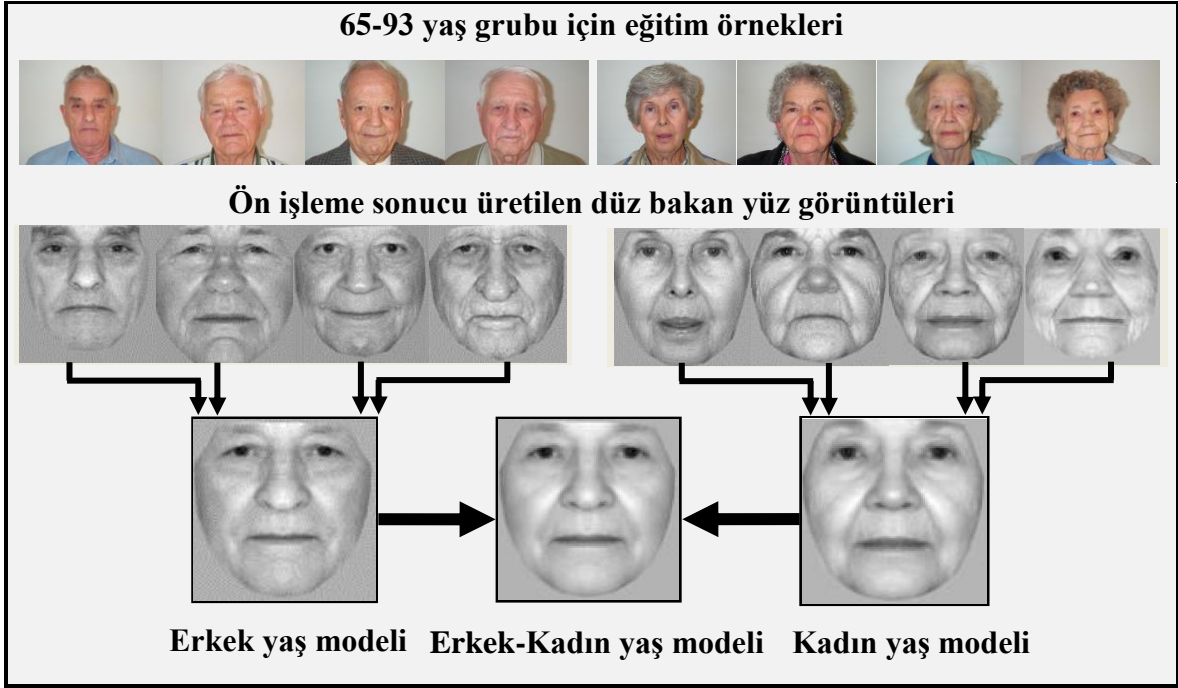
2.6.1.2. Yaş Modellerinin Üretilmesi

Sınıflandırma yöntemlerinin performansı, seçilen eğitim örneklerine bağlı olarak farklılık gösterebilmektedir. Ayrıca sistem performansını arttırmak amacıyla büyük miktarda eğitim örneğinin kullanılması, sınıflandırma sisteminin eğitimini daha karmaşık ve zaman alıcı yapmaktadır. Bu tez çalışmasında, farklı ve büyük eğitim kümelerinin etkilerini ortadan kaldırmak ve daha basit bir sınıflandırma sistemi oluşturmak için, yaş

gruplarının ortalama yaş bilgisini temsil eden yaş modellerinin üretilmesi önerilmiştir (Günay ve Nabiyev, 2009).

Sınıflandırmada kullanılacak yaş modellerinin üretilmesi aşamasında öncelikle yaş gruplarının belirlenmesi gerekmektedir. Çalışmanın bu bölümünde de Erikson'un teorisi temel alınarak yaş grupları çocuk (0-12), ergen (13-19), genç (20-39), orta yaşlı (40-64) ve yaşlı (≥ 65) olarak belirlenmiştir. Deneylerde kullanılan veritabanlarından FG-NET'teki kişilerin yaş aralığı 0-69, PAL veritabanındaki kişilerin yaş aralığı ise 18-93 olduğu için, yaşlı grubunun sınırları 65-93 olarak alınmıştır. Oluşturulan yaş gruplarında en fazla yaş değişimi genç, orta yaşlı ve yaşlı gruplarında olup genç grubunda 20, orta yaşlı grubunda 25, yaşlı grubunda ise 29 farklı yaş etiketi bulunmaktadır. Bu değerlerin ortalaması hesaplandığında herhangi bir yaş grubundaki farklı yaş etiketinin sayısı 24 olarak belirlenmiştir. Herhangi bir yaş sınıfını temsil etmek için o sınıftan her yaş etiketini temsil edecek şekilde 24 görüntünün kullanılması yerine, 3 yıllık yaş farkının yüzün görünümünde çok fazla bir değişime yol açmayacağı bilgisi (Aeminov vd., 1989) dikkate alınarak, yaş grupları 8 görüntü ile temsil edilmiştir. Bu görüntüler yaş grubunun sınırları içerisinde 3 yıl aralıklarla seçilen 4 kadın ve 4 erkek görüntüsünden oluşmaktadır. Görüntülerin seçilmesinin ardından her yaş grubu için morfleme tekniğine dayalı olarak 1 erkek, 1 kadın ve 1 erkek-kadın yaş modeli üretilmiştir. Üretilen bu yaş modelleri yaş gruplarının ortak karakteristiklerini içermektedir.

Şekil 2.32'de PAL veritabanındaki 65-93 yaş grubu için yaş modellerinin üretilmesi aşamaları görülmektedir. Orijinal yüz görüntüleri ön işleme aşamasından geçtikten sonra düz bakan görüntüler üretilmiş ve yüz bölgesi dışındaki bilgiler elimine edilmiştir. Daha sonra düz bakan yüz görüntülerinden morfleme yöntemi ile erkek, kadın ve erkek-kadın yaş modelleri üretilmiştir. Şekil 2.33'te ise FG-NET ve PAL veritabanlarında önerilen yaş grupları için üretilen yaş modelleri görülmektedir. Sınıflandırma aşamasında her yaş grubu için bir kadın, bir erkek olmak üzere iki yaş modeli ve her sınıf için tek (erkek-kadın birleşik) yaş modeli kullanılarak eğitim gerçekleştirilmiştir. Diğer yandan önerilen yöntemin cinsiyete göre değerlendirilmesi amacıyla sadece erkek ve sadece kadın test örnekleriyle sınıflandırma gerçekleştirilmiştir.



Şekil 2.32. Yaş modellerinin üretilmesi

YG	FGNET Veritabanı			YG	PAL Veritabanı		
	Erkek	Kadın	Erkek-Kadın		Erkek	Kadın	Erkek-Kadın
0-12				13-19			
13-19				20-39			
20-39				40-64			
40-64				≥65			

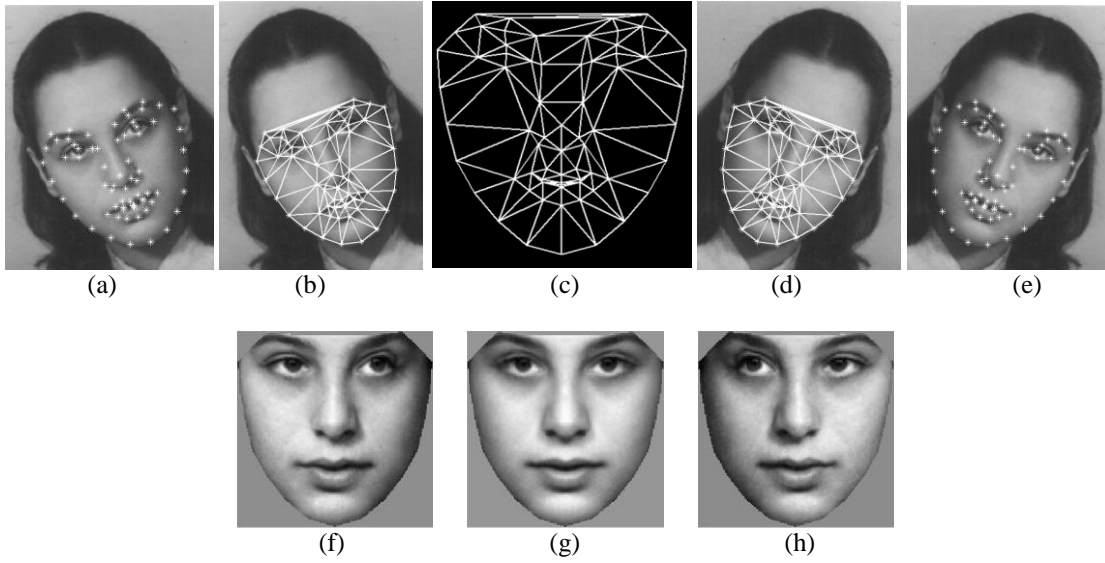
Şekil 2.33. FG-NET ve PAL veritabanları için üretilen yaş modelleri (YG: Yaş Grubu)

Herhangi bir test örneğinin bu modeller üzerinden sınıflandırılabilmesi için ön işleme aşamasından geçmesi gerekmektedir. Ön işleme aşamasında görüntülerdeki kafa pozü, bakış açısı gibi farklılıkların ortadan kaldırılması ve düz bakan yüz görüntülerinin

üretilmesi hedeflenmiştir. Yaş modellerinin üretilmesinde de kullanılan ön işleme aşaması, bir sonraki bölümde açıklanmaktadır.

2.6.2. Görüntü Önışleme


Yüz görüntülerindeki kafa pozu, yüz ifadesi, arka plan, çözünürlük, aydınlatma koşulları gibi farklılıklar tanıma sistemlerinin performansını kötü etkilemektedir. Bu kötü etkilerin azaltılması ve görüntülerdeki ölçek, kafa pozu, arka plan gibi farklılıkların ortadan kaldırılması amacıyla eğitim ve test kümelerindeki tüm görüntüler için ön işleme gerçekleştirilmiştir. Çalışmada görüntü morfleme yöntemi, yaş modellerinin üretilmesinin yanında, ön işleme aşamasında düz bakan yüz görüntülerinin oluşturulmasında da kullanılmıştır. Düz bakan görüntülerin üretilmesi aşamaları Şekil 2.34'te görülmektedir.



Şekil 2.34. Ön işleme aşamaları (a) Orijinal görüntü ve 68 kontrol noktası (b) Orijinal görüntüde Delaunay üçgenlemesi ise oluşturulan bölgeler (c) $\alpha = 0.5$ alınarak üretilen ara kontrol noktaları ve bölgeler (ortalama şekil) (d) Sağa yansıtılmış görüntüde Delaunay üçgenlemesi ise oluşturulan bölgeler (e) Sağa yansıtılmış görüntü ve 68 kontrol noktası (f) Orijinal görüntünün ortak şekle eğriltilmesi sonucu (g) Morfleme sonrası üretilen düz bakan yüz görüntüsü (h) Sağa yansıtılmış görüntünün ortak şekle eğriltilmesi sonucu

Öncelikle orijinal görüntüler, yüzün çevresini, kaş, göz, burun, ağız kenarlarını belirleyen 68 nokta ile etiketlemiştir (Şekil 2.34.a). Daha sonra görüntüler bu noktalar üzerinden Delaunay üçgenlemesi (Berg vd., 1997) ile üçgen bölgelere ayrılmıştır (Şekil

2.34.b). Kafa pozunu ve bakış açısını düzeltmek için orijinal görüntüler sağa yansıtılmış ve yine 68 nokta ile etiketlenmiştir (Şekil 2.34.e). Yansıtılmış görüntü yine kontrol noktaları üzerinden Delaunay üçgenlemesi ile üçgen bölgelere ayrılmıştır (Şekil 2.34.d). Daha sonra $\alpha = 0.5$ alınarak üretilecek ara görüntü için kontrol noktaları üretilmiştir. Burada $\alpha = 0.5$ olduğu için üretilen ara kontrol noktaları, orijinal ve yansıtılmış görüntülerin kontrol noktalarının ortalamasıdır. Üretilen ara kontrol noktaları ve bu noktalar üzerinden oluşturulan üçgen bölgeler Şekil 2.34.c'de görülmektedir. Ortalama şekle ait nokta koordinatları için de üçgen bölgeler üretildikten sonra, orijinal görüntü ve yansıtılmış görüntü bu ortak şekle eğriltilmiş ve böylece kontrol noktalarının eşleşmesi sağlanmıştır (Şekil 2.34.f ve Şekil 2.34.h). Son olarak eğriltilen görüntülerin piksel parlaklık değerleri üzerinde $\alpha = 0.5$ ile interpolasyon gerçekleştirilerek ortalama görüntü elde edilmiştir (Şekil 2.34.g). Şekilden görüldüğü gibi morfleme işlemi sonucunda görüntünün kafa pozu ve bakış açısı düzeltilmiştir. Diğer yandan arka plan, kıyafet gibi yüz olmayan bölgelerin maskelenmesi sağlanmıştır. Örnek görüntüler için düz bakan görüntülerin üretilmesi sonuçları Şekil 2.35'te verilmiştir.



Şekil 2.35. Görüntü önileme (a) Orijinal görüntüler (b) Düz bakan yüz görüntüleri

Önerilen model tabanlı yaş tahmini sisteminde düz bakan yüz görüntülerinin üretilmesinin ardından gerçekleştirilen öznetelik çıkarma işlemi bir sonraki bölümde açıklanmaktadır.

2.6.3. Öznitelik Çıkarma

Ön işleme aşamasından geçen görüntülerden özniteliklerin çıkarılması için daha önce açıklanan ve iyi bir yaş tahmini başarımı sağlayan LBP yöntemi kullanılmıştır. LBP öznitelikleri yine bölgesel LBP histogramlarının birleştirilmesiyle üretilmiştir. Bu öznitelik çıkarma yöntemi daha önce detaylı olarak açıklandığı için burada açıklanmamıştır. Yaş gruplarına ait yaş modellerinden ve ön işleme aşamasından geçen test örneğinden özniteliklerin çıkarılmasından sonra, test örneğinin yaş modellerine olan uzaklıkları çeşitli uzaklık ölçütleri ile hesaplanmakta ve puanlamaya dayalı bir sınıflandırma işlemi gerçekleştirilmektedir. Sınıflandırma sistemi bir sonraki bölümde açıklanmaktadır.

2.6.4. Sınıflandırma

Önerilen model tabanlı yaş tahmini yaklaşımının sınıflandırma aşamasında basit ve hızlı bir yöntem olan en yakın komşuluk sınıflayıcısı kullanılmıştır. Ön işleme aşamasından geçen ve öznitelikleri çıkarılan bir test örneğinin yaş modellerine olan uzaklığı, farklı uzaklık ölçütleri ile hesaplanmıştır. Uzaklık ölçütlerinin her birinin sınıflandırma başarımları yaş gruplarında farklılık göstermektedir. Bazı yaş gruplarında test örneklerinin iyi bir şekilde sınıflandırılmasını sağlayan ölçüt, diğer bir yaş grubunda iyi bir sonuç vermeyebilir. En yakın komşuluk sınıflayıcısı kullanıldığında, test örneği, hesaplanan uzaklıklardan en küçüğüne sahip olan sınıfa sınıflandırılmaktadır. Fakat üretilen uzaklıklar arasında çok büyük farklılıklar bulunmayabilir. Yani minimum uzaklık değeri ile bir sonraki minimum uzaklık arasındaki fark çok küçük olabilir ve bu da sınıflandırma sonucunun yanlış olmasına neden olabilir. Bu nedenle test örneğinin tüm yaş gruplarına olan uzaklıkları birlikte değerlendirilmelidir. Temelde her bir sınıflayıcı olası sınıf etiketlerini hesaplanan uzaklıklara göre bir sıraya sokmaktadır. Bu sıralamada en küçük mesafeye sahip sınıf birinci konumda, bir sonraki en küçük mesafeye sahip sınıf ikinci konumda ve en büyük mesafeye sahip sınıf son konumda bulunmaktadır. Sistemin sınıflandırma performansının artırılması ve farklı uzaklık ölçütlerinin sonuçlarının birlikte değerlendirilmesi için oylamaya dayalı bir puanlama sistemi kullanılmıştır. Sınıflandırma aşamasında kullanılan uzaklık ölçütleri ve oylama yöntemi alt başlıklarda açıklanmaktadır.

2.6.4.1. Uzaklık Ölçütleri

Test görüntülerine ait öznitelik vektörleriyle, yaş grupları için üretilen yaş modellerinden çıkarılan öznitelik vektörleri arasındaki uzaklığın hesaplanmasında Öklid, Manhattan, Chebyshev ve Ki-karesi uzaklık ölçütleri kullanılmıştır. Bu uzaklık ölçütleri sırasıyla aşağıdaki denklemlerle ifade edilmektedir.

$$D_{\text{öklid}} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (2.57)$$

$$D_{\text{Manhattan}} = \sum_{i=1}^n |p_i - q_i| \quad (2.58)$$

$$D_{\text{Chebyshev}} = \max_i (|p_i - q_i|) \quad (2.59)$$

$$\chi^2(P, Q) = \sum_i \frac{(p_i - q_i)^2}{p_i + q_i} \quad (2.60)$$

Her bir uzaklık ölçütü ile hesaplanan uzaklıklar, en yakın komşuluk sınıflayıcısı ile birlikte kullanılarak test örneğinin sınıflandırılması sağlanmıştır. Diğer yandan bu ölçütlerle hesaplanan uzaklıkların birlikte değerlendirilebilmesi için bir sonraki bölümde açıklanan puanlama sistemi kullanılmış ve böylece sınıflandırma doğruluğunun artırılması hedeflenmiştir.

2.6.4.2. Borda Oylama Yöntemi ile Sınıflandırma Sonuçlarının Birleştirilmesi

Oylama ve oy sayma yöntemlerine küme elemanlarının sıralılığının değerlendirilmesi örneği gibi de bakılabilir. Farklı yöntemlerde problemin tüm girdileri aynı olmasına rağmen oy sayma ve değerlendirme yöntemlerinin farklılaşmasıyla kazananlarda değişmektedir. Bu nedenle probleme sezgisel puanlamaya dayalı çok kişili oyun olarak ta bakılabilir.

İki veya daha fazla seçeneğin bulunduğu ve bu seçeneklerden hangisinin en iyi (kazanan) olduğunun belirlenmesi gibi durumlarda oylama ve oy sayma yöntemleri önem kazanmakta ve en iyiyi belirlemede etkin rol oynamaktadır. Öyle ki değişik oylama ve oy

sayma yöntemleri yine değişik birincileri ortaya çıkarmaktadır. Çalışmada sınıflandırma yöntemlerinin sonuçlarının değerlendirilmesinde Borda sayısı yöntemi kullanılmıştır.

Borda sayısı ikiden daha fazla aday grubundan kazananın seçilmesi için tasarlanan bir oylama yöntemidir (Miller vd., 2011). Borda sayısının temel avantajı, tüm seçenekler arasından seçmenlerin tercihlerini dikkate alması ve böylece geniş desteğe sahip olan seçenekleri öne çıkarmasıdır. Tersi olarak çoğunluk kuralı sadece ilk tercihleri dikkate almakta ve bu nedenle çoğunluk tarafından tercih edilmeyen seçeneklerin seçilmesi sonucuna neden olabilmektedir. Genel olarak N aday için, oylamadaki 1. sıra N , 2. sıra $N-1$, ... ve son sıra ise 1 puan değerindedir. Bu puanlama sonucu en fazla puanı alan aday seçimi kazanmaktadır. Örnek bir oylama örneği Şekil 2.36'da verilmiştir. Şekilde seçenekler A, B, C, D ve E ile ifade edilmiştir. Her bir seçmenin bu seçenekleri tercih sıralamasına göre puanlar belirlenmiştir. Her bir seçenek için Borda puanlaması yapıldığında en çok puanı alan A seçeneği kazanan olarak belirlenmiştir. Seçmenlerin ilk tercihleri dikkate alındığında C seçeneği ön plana çıkarken, genel tercihlerde A seçeneği seçimi kazanmaktadır.

Seçmenlerin tercihleri					Adaylar	
Puanlar	Seçmen1	Seçmen2	Seçmen3	Seçmen4	Borda sayısı	
5	D	A	C	C	A	4+5+4+4=17
4	A	B	A	A	B	2+4+2+1=9
3	E	C	D	E	C	1+3+5+5=14
2	B	E	B	D	D	5+1+3+2=11
1	C	D	E	B	E	3+2+1+3=9

Şekil 2.36. Borda sayısı ile puan hesaplama örneği

Çalışmada seçmenler uzaklık ölçütleri, adaylar ise yaş gruplarıdır. Kullanılan uzaklık ölçütlerinin sayısı M , yaş gruplarının sayısı N , i . ölçüt tarafından j . yaş grubuna verilen puan $r_{i,j}$ ile temsil edilirse, j . yaş grubu için Borda sayısı (BS_j) aşağıdaki şekilde hesaplanabilir.

$$BS_j = \sum_{i=1}^M r_{i,j} \quad j = 1, \dots, N \quad (2.61)$$

Bir test örneği için tüm yaş gruplarına ait Borda sayıları hesaplanır ve test örneği en yüksek puana sahip olan gruba aşağıdaki denklem kullanılarak sınıflandırılır.

$$t \in \{YG_k \mid \max_j BS_j = BS_{YG_k}\} \quad j = 1, \dots, N \quad (2.62)$$

Denklemden t test örneğini, YG_k herhangi bir yaş grubunu, BS_j j . yaş grubuna ait Borda sayısını ifade etmektedir.

3. BULGULAR VE İRDELEME

3.1. Giriş

Bu bölümde öncelikle tez çalışmasında, üzerinde deneyler gerçekleştirilen veritabanları açıklanmıştır. İkinci olarak çalışmada incelenen öznelik çıkarma yöntemlerinin tek başlarına ve birleştirilerek kullanılması sonucu elde edilen yaş tahmini sonuçları verilmiş ve irdelenmiştir. Daha sonra oluşturulan hiyerarşik yaş tahmini sistemindeki, yaş grubuna sınıflandırma ve yaş grupları altında yaş etiketinin belirlenmesi aşamalarında elde edilen sonuçlar literatürle kıyaslanarak yorumlanmıştır. Son olarak önerilen model tabanlı yaş tahmini sistemi ile elde edilen performans değerlendirilmiştir.


3.2. Veritabanları

Tez çalışmasında önerilen yöntemlerin performans değerlendirmesinde üç adet veritabanı kullanılmıştır. Bunlar FG-NET (Face and Gesture Recognition Research Network) yaşlanma veritabanı, MORPH-I veritabanı ve PAL veritabanıdır. Bu veritabanları aşağıda açıklanmaktadır. Çalışmada FERET veritabanı üzerinde de deneyler gerçekleştirilmesi düşünülmüştür. FERET veritabanı daha çok kişi tanıma uygulamalarında kullanılmaktadır. Bu veritabanındaki görüntüler genellikle 10 ve katlarındaki yaşlara sahip kişilere ait olup, ara yaşlarda görüntü içermediğinden yaş tahmini uygulamaları için pek elverişli değildir. Aynı zamanda literatürde bu veritabanı üzerinde deney gerçekleştiren çalışma sayısı da yok denecek kadar azdır. Bu nedenlerden dolayı FERET veritabanı deneylerde kullanılmamıştır.

3.2.1. FG-NET Veritabanı

FG-NET veritabanı, yaşları 0 ile 69 arasında değişen 82 kişiden alınmış 1002 resimden oluşmaktadır (URL-1). Veritabanında her bir kişinin 6 ile 18 arasında görüntüsü bulunmaktadır. Görüntüler kişilerin albümlerinden, tarama yolu ile elde edilmiştir. Bu nedenle bu görüntüler, aydınlatma, kafa pozunu, yüz ifadesi, arka plan, çözünürlük ve

taramadan doğan gürültü gibi pek çok farklılıklara sahiptir. Diğer yandan veritabanında yaşa göre dağılım Şekil 3.1’de görüldüğü gibi düzgün değildir. Veritabanındaki görüntülerin yaklaşık olarak %70’i 0-20 yaş aralığındadır. Buna rağmen bu veritabanı kişiler için kronolojik sırada yaşlanma görüntüsü sunan tek veritabanı olduğundan, yaş tahmini çalışmalarında sıklıkla kullanılmaktadır. FG-NET veritabanındaki yaşlanma görüntülerinin genel özellikleri Tablo 3.1’de verilmiştir.



Şekil 3.1. FG-NET veritabanındaki görüntülerin yaş etiketlerine göre dağılımı

Tablo 3.1. FG-NET veritabanının genel özellikleri


Toplam resim sayısı	1002	
Kişi sayısı	82	
Kişi başına düşen resim sayısı	6 - 18 (ortalama olarak 12 resim/kişi)	
En küçük yaş	0	
En büyük yaş	69	
Resim türü	JPEG görüntüler, renkli ya da gri seviyeli	
Resim Çözünürlüğü	Değişken	
Veritabanındaki resimlerde karşılaşılan çeşitli durumlar	Aydınlatma	Değişken
	Poz	Değişken
	İfade	Değişken
	Bıyık	Var
	Sakal	Var
	Gözlük	Var
	Şapka	Var

3.2.2. MORPH Veritabanı

MORPH veritabanı (Ricanek ve Tesafaye, 2006) Wilmington Kuzey Carolina Üniversitesi'nde yüzdeki yaşlanma üzerinde çalışan bir grup tarafından, yüz biyometrisi ile ilgili uygulamalarda kullanılması amacıyla oluşturulmuştur. Bu veritabanı iki albüm halinde düzenlenmiş olup yaş cinsiyet, boy, kilo, ırk gibi bilgilerini sunmaktadır. Çalışmada Albüm1 üzerinde deneyler gerçekleştirilmiştir. Albüm-1 1962 ile 1998 yılları arasında çekilmiş, 631 kişiye ait 1690 resim içermektedir. Yaş dağılımı ise 15 ile 68 yaş arasında değişmektedir. MORPH-I veritabanındaki yaşlanma görüntülerinin yaş etiketlerine göre dağılımı Şekil 3.2'de, görüntülerin genel özellikleri ise Tablo 3.2'de verilmiştir. Şekilden görüldüğü gibi bu veritabanında da görüntülerin yaş dağılımı dengeli değildir. Veritabanındaki görüntülerin yaklaşık olarak %70'i 15-30 yaş aralığındadır.

3.2.3. PAL Veritabanı

PAL veritabanı (Minear ve Park, 2004) veritabanı yaşları 18 ile 93 arasında değişen 580 kişiden alınmış 580 görüntüden oluşmaktadır. Doğal aydınlatma koşullarında dijital kamera ile elde edilen görüntülerde gülümseme, üzüntü, kızgınlık gibi ifade farklılıkları bulunmaktadır. Veritabanı, Afrika, Amerika, Asya, Kafkas, Hint, İspanyol gibi çok farklı etnik kökenden kişilere ait görüntülerden oluşmaktadır.

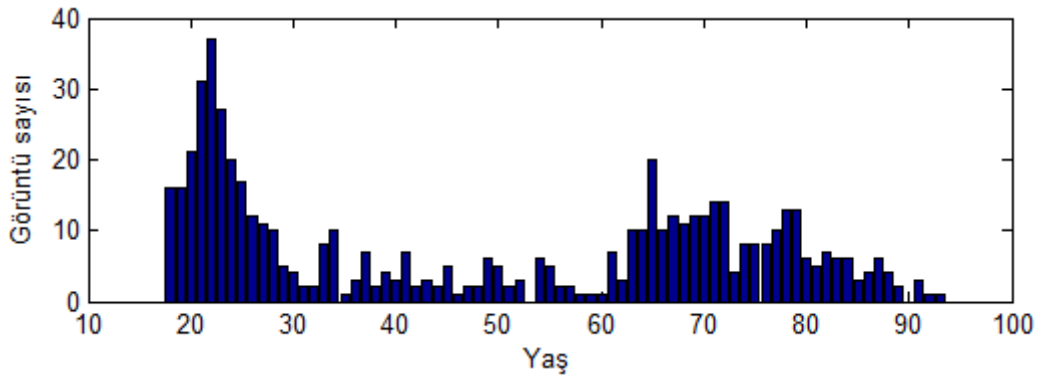


Şekil 3.2. MORPH-I veritabanındaki görüntülerin yaş etiketlerine göre dağılımı

Tablo 3.2. MORPH-I veritabanının genel özellikleri

Toplam resim sayısı	1690	
Kişi sayısı	631	
Kişi başına düşen resim sayısı	1-4 (ortalama olarak 3 resim/kişi)	
En küçük yaş	15	
En büyük yaş	68	
Resim türü	JPEG görüntüler, gri seviyeli	
Resim Çözünürlüğü	400x500	
Veritabanındaki resimlerde karşılaşılan çeşitli durumlar	Aydınlatma	Değişken
	Poz	Değişken
	İfade	Değişken
	Bıyık	Var
	Sakal	Var
	Gözlük	Var
	Şapka	Var

PAL veritabanındaki görüntülerin yaş etiketlerine göre dağılımı Şekil 3.3'te görülmektedir. Veritabanının genel özellikleri ise Tablo 3.3'te verilmiştir. PAL veritabanındaki görüntülerin yaş etiketlerine göre dağılımı incelendiğinde, görüntülerin %40'ının 18-30 yaş, %45'inin ise 60-93 yaş aralığında olduğu görülmektedir. 30-60 yaş aralığındaki görüntüler veritabanının sadece %15'ini oluşturmaktadır.



Şekil 3.3. PAL veritabanındaki görüntülerin yaş etiketlerine göre dağılımı

Tablo 3.3. PAL veritabanının genel özellikleri

Toplam resim sayısı	580	
Kişi sayısı	580	
Kişi başına düşen resim sayısı	1	
En küçük yaş	18	
En büyük yaş	93	
Resim türü	JPEG görüntüler, renkli	
Resim Çözünürlüğü	640x480	
Veritabanındaki resimlerde karşılaşılan çeşitli durumlar	Aydınlatma	Standart
	Poz	Önden çekim
	İfade	Değişken
	Bıyık	Var
	Sakal	Var
	Gözlük	Yok
	Şapka	Yok

Çalışmada kullanılan veritabanlarından alınan örnek görüntüler Şekil 3.4'te görülmektedir. Şekil 3.4.a FG-NET veritabanındaki bir kişiye ait görüntü dizisini içermektedir. Görüldüğü gibi görüntülerde aydınlatma koşulları, poz, ölçek açısından büyük farklılıklar mevcuttur. Ayrıca görüntülerin taranması sırasında oluşan gürültü de oluşturulan sistemlerin performansını etkilemektedir.

3.3. Öznitelik Çıkarma Yöntemleri ile Tek Aşamalı Yaş Tahmini Sonuçları

Bu bölümde öznitelik çıkarma yöntemlerinin yaş tahminindeki başarımları değerlendirilmektedir. Bu amaçla her bir yöntemle veritabanlarındaki tüm görüntüler için çıkarılan öznitelikler kullanılarak yaşlanma süreci modellenmiştir. Yaşlanma sürecinin modellenmesinde karesel regresyon fonksiyonları kullanılmıştır. Tüm görüntülerin kullanılması ile olası yaş etiketi sayısı fazla olduğundan yöntemlerin en kötü senaryodaki başarımlarının karşılaştırılması mümkün olmaktadır. Başarımın değerlendirilmesinde FG-NET veritabanı için LOPO yöntemi kullanılırken, MORPH-I ve PAL veritabanlarında 3-kat çapraz doğrulama yöntemi kullanılmıştır. Burada her adımda örneklerin 2/3'ü eğitim

kümesi, geriye kalan $1/3$ 'ü ise test kümesi olarak kullanılmaktadır. Yöntemlerin yaş tahmini performansları MAE ve $CS(j)$ ölçütleri ile değerlendirilmiştir. MAE tahmin edilen yaşlarla gerçek yaş etiketleri arasındaki farkların ortalaması iken, $CS(j)$ j yıla kadar hata toleransı tanındığında yaşı doğru tahmin edilen görüntü sayısının toplam görüntü sayısına oranıdır. İlerleyen bölümlerde sırasıyla tüm öznelik çıkarma yöntemleriyle elde edilen yaş tahmini sonuçları verilmiştir.



(a)



(b)



(c)

Şekil 3.4. Veritabanlarından örnek görüntüler (a) FGNET (b) MORPH-I (c) PAL veritabanı

3.3.1. AAM Öznitelikleriyle Yaş Tahmini Sonuçları

AAM ile çıkarılan öznitelikler şekil, parlaklık ve birleşik şekil-parlaklık model parametrelerini (b_s, b_g, b_c) içermektedir. Bu vektörler yaş tahmini sistemlerinde yaşlanma ile ilgili öznitelikler olarak kullanılmaktadır. Çalışmada FG-NET ve PAL veritabanlarındaki görüntüler için AAM ile öznitelik çıkarma işlemi gerçekleştirilmiş ve her bir vektörle elde edilen yaş tahmini sonuçları Tablo 3.4'te verilmiştir.

Tablo 3.4. AAM özniteliklerinin FG-NET ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)


Öznitelik	FG-NET	PAL
b_s	6.41	9.57
b_g	6.22	6.66
b_c	6.02	6.61

Tablo 3.4 incelendiğinde, FG-NET veritabanında şekil özniteliklerinin yaş tahmini performansının diğer özniteliklere yakın olduğu, fakat PAL veritabanında oldukça kötü bir başarıya sahip olduğu görülmektedir. Benzer şekilde şekil ve parlaklık özniteliklerinin birleştirilmesi ve tekrar PCA uygulanması sonucu üretilen b_c öznitelikleri FG-NET tabanında b_s ve b_g 'ye göre bir iyileşme sağlarken, PAL veritabanında önemli bir değişime neden olmamıştır. Bunun nedeni veritabanlarındaki görüntülerin yaş dağılımlarıyla ilgilidir. FG-NET veritabanındaki görüntülerin yaklaşık %70'i 20 yaş altındaki kişilerden oluşmaktadır (Şekil 3.1). Bu yaş aralığı insan yüzünün şekil olarak en fazla değiştiği dönem olduğundan b_s 'nin iyi sonuç vermesi ve b_g ile birleştirildiğinde (b_c) genel olarak yaş tahmini performansının artması beklenen bir sonuçtur. Diğer yandan PAL veritabanındaki görüntüler 18-93 yaş aralığındadır. Bu yaş aralığında insan yüzünde şekil yönünden çok fazla bir değişim olmayacağı için, b_g 'nin belirgin bir şekilde yaş tahmininde daha başarılı olduğu görülmektedir. Bu veritabanı için b_c başarıyı çok fazla değiştirmese de vektör boyutu b_g 'ye göre daha küçük olduğu için tercih edilmiştir. Bu nedenle ilerleyen kısımlarda AAM ile çıkarılan öznitelikler ifadesi b_c 'yi ifade etmektedir. AAM

öznitelikleriyle FG-NET ve PAL veritabanlarında sırasıyla 6.02 yıl ve 6.61 yıl MAE ile yaş tahmini gerçekleştirilmiştir.

3.3.2. DCT Öznitelikleriyle Yaş Tahmini Sonuçları

Çalışmada öznitelik çıkarma yöntemi olarak kullanılan DCT’de, 8x8 bloklara uygulanan dönüşüm ile üretilen 64 katsayıdan, zig-zag tarama yöntemi ile kaç tanesinin öznitelik vektörüne aktarılacağı deneysel olarak belirlenmiştir. Bu amaçla üretilen katsayılardan sırasıyla 1, 3, 6, 10, 15, 21, 28 ve 36 tanesi kullanılarak elde edilen öznitelik vektörlerinin yaş tahmini performansı değerlendirilmiştir. FG-NET, MORPH-I ve PAL veritabanları için DCT katsayı sayısının değişimine bağlı olarak yaş tahmini başarımı Şekil 3.5’te verilmiştir. Şekilden görüldüğü gibi FG-NET ve MORPH-I veritabanlarında her bölge 3 DCT katsayısı ile temsil edildiğinde en iyi yaş tahmini performansı elde edilmektedir. PAL veritabanında ise her bölge 6 katsayı ile temsil edildiğinde en iyi sonuç elde edilmiştir. Fakat şekilden de görüldüğü gibi PAL veritabanında, bölgeler için kullanılan katsayı sayısı 2 katına çıktığı halde, yaş tahmini başarımında belirgin bir artış olmamıştır. Bu nedenle tüm veritabanları için her bir bölgenin 3 DCT katsayısı ile temsil edilmesi yoluna gidilmiş ve bu şekilde üretilen öznitelik vektörleriyle yaş tahmini gerçekleştirilmiştir. Üretilen DCT öznitelik vektörünün boyutu $11 \times 11 \times 3 = 363$ iken, PCA (%99) ile boyut küçültüldüğünde FG-NET veritabanı için 172, MORPH veritabanı için 161, PAL veritabanı için 129 elemanlı öznitelik vektörleri elde edilmiştir. DCT öznitelikleriyle elde edilen yaş tahmini sonuçları Tablo 3.5’te verilmiştir.



Şekil 3.5. DCT katsayı sayısının değişimine bağlı yaş tahmini başarımı

Tablo 3.5. Veri sıkıştırma mantığına dayalı DCT özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)

Öznitelik	FG-NET	MORPH-I	PAL
DCT ($k=3$)	7.48	5.82	8.13

Tablodan görüldüğü gibi DCT öznitelikleri MORPH-I veritabanında, diğer veritabanlarına göre daha iyi bir yaş tahmini performansına sahiptir. DCT öznitelikleriyle FG-NET veritabanında 7.48 yıl, MORPH-I veritabanında 5.82 yıl, PAL veritabanında ise 8.13 yıl MAE ile yaş tahmin edilmektedir.


DCT dönüşümünün bilinen filtreleme yöntemiyle uygulanması sonucu elde edilen yaş tahmini başarımları ise Tablo 3.6’da görülmektedir. Burada görüntü yine 8x8 bloklara ayrılmış, her bir bölge için üretilen 8x8 boyutlu katsayılar matrisinden sırasıyla sol üst köşedeki 2x2, 3x3 ve 4x4’lük bölgedeki DCT katsayıları alınarak bir vektörde birleştirilmiştir. Bu şekilde üretilen öznitelik vektörleriyle elde edilen yaş tahmini başarımları FG-NET ve MORPH veritabanı için 4 DCT katsayısının yeterli olduğunu, PAL veritabanı için ise 16 katsayı ile daha iyi bir yaş tahmini performansı elde edildiğini göstermektedir. Diğer yandan çalışmada FG-NET ve PAL veritabanları için, veri sıkıştırma mantığına dayalı olarak elde edilen DCT özniteliklerinin, bilinen filtreleme yöntemiyle üretilen DCT özniteliklerine göre yaş tahmininde daha başarılı olduğu görülmektedir. MORPH veritabanı için ise 363 (11x11x3) elemanlı DCT öznitelik vektörü ile elde edilen 5.82 yıl MAE sonucu 484 (11x11x4) elemanlı DCT öznitelik vektörü ile elde edilen 5.78 yıl MAE’den çok büyük bir başarımların artışı sağlamamaktadır. Bu nedenle çalışmada kullanılan veri sıkıştırma mantığına dayalı DCT özniteliklerinin, daha az sayıda özniteliklerle daha iyi bir yaş tahmini başarımlarını sağladığı söylenebilir.

Tablo 3.6. Filtrelemeye dayalı DCT özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)

Öznitelik	FG-NET	MORPH-I	PAL
DCT (2x2 katsayı)	7.81	5.78	9.05
DCT (3x3 katsayı)	7.76	5.93	8.98
DCT (4x4 katsayı)	7.97	5.92	8.83

3.3.3. Radon Öznitelikleriyle Yaş Tahmini Sonuçları

Radon dönüşümüyle öznitelik çıkarılırken, yüz görüntüleri çeşitli açılarda döndürülüp iz düşümleri üretilmekte ve bu iz düşüm vektörleri birleştirilerek görüntüye ait öznitelik vektörü elde edilmektedir. Radon dönüşümünün uygulanması sırasında kullanılan açı değerleri için çalışmada bir değerlendirme yapılmıştır. Bu amaçla 0-180 dereceleri arasında sırasıyla 1, 2, 3, 4, 5, 6, 9, 10, 12, 15, 18, 20, 30, 60 ve 90 derece artımlarla üretilen Radon dönüşümlerinin yaş tahminindeki başarısı ölçülmüştür. FG-NET, MORPH-I ve PAL veritabanlarında elde edilen sonuçlar Şekil 3.6'da verilmiştir.



Şekil 3.6. Radon dönüşümündeki açının artım miktarına bağlı yaş tahmini başarımı

Şekilden görüldüğü gibi Radon dönüşümündeki açının artım miktarı 15 dereceyi geçtiğinde yaş tahmini başarımında düşüş meydana gelmektedir. Veri kaybını önlemek ve öznitelik vektör boyutunun çok büyük olmasını engellemek için çalışmada Radon dönüşümünü uygulanması sırasında yüz görüntüleri 0 ile 180 derece arasında 15 derecelik artımlarla döndürülerek izdüşümleri alınmış ve bu izdüşüm vektörleri tek bir vektörde birleştirilerek öznitelik vektörleri elde edilmiştir. Üretilen Radon öznitelik vektörünün boyutu $129 \times 12 = 1548$ iken, PCA (%99) ile boyut küçültüldüğünde FG-NET veritabanı için 45, MORPH veritabanı için 24, PAL veritabanı için 20 elemanlı öznitelik vektörleri elde edilmiştir. Bu öznitelik vektörlerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları Tablo 3.7'de verilmiştir.


Tablo 3.7. Radon özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)

Öznitelik	FG-NET	MORPH-I	PAL
Radon ($\theta = 15$)	7.53	6.09	8.93

Tablodan görüldüğü gibi Radon dönüşümü ile üretilen öznitelik vektörleriyle FG-NET, MORPH-I ve PAL veritabanlarında sırasıyla 7.53 yıl, 6.09 yıl ve 8.93 yıl MAE ile yaş tahmini gerçekleştirilmektedir.

3.3.4. LBP Öznitelikleriyle Yaş Tahmini Sonuçları

LBP öznitelikleriyle yaşın tahmininde, LBP histogramları yüzün bütününden çıkarılabileceği gibi, yerel bölgelerden çıkarılan LBP histogramlarının birleşimi kullanılarak yerel doku bilgisi elde edilebilir. Çalışmada LBP öznitelikleri için bölge sayısına bağlı olarak yaş tahmini başarımını değerlendirmek amacıyla, normalizasyon aşamasında 88x88 boyutuna ölçeklenen görüntüler sırasıyla 2x2, 4x4 ve 8x8 bölgeye ayrılıp bölgesel LBP histogramları üretilmiştir. Bu özniteliklerin yaş tahmini başarımının değişimi Şekil 3.7’de verilmiştir. Şekilden görüldüğü gibi bölge sayısının artması ile birlikte görüntüde üzerinde yerel olarak kenarlar, benekler, düz alanlar gibi mikro-örüntülerle ilgili bilgiler daha iyi temsil edildiğinden, yaş tahmini başarımı artmaktadır. Bu nedenle çalışmada LBP özniteliklerinin çıkarılmasında, yüz görüntüleri 8x8 bölgeye ayrılmış, her bölgeden çıkarılan LBP histogramları birleştirilmiştir. Diğer yandan bölgelere önem derecelerine göre katsayılar verilmiştir. Yüz üzerindeki yaşlanma etkileri dikkate alındığında örneğin alın, gözaltları, ağız kenarları ve yanak bölgeleri yaşlanma etkilerini belirgin bir şekilde ifade ettiğinden bu bölgelere daha yüksek katsayılar atanmıştır. Üretilen LBP öznitelik vektörü $8 \times 8 \times 59 = 3776$ elemanlıdır. PCA (%99) ile boyut küçültme işlemi gerçekleştirildiğinde FG-NET veritabanı için 816, MORPH veritabanı için 955, PAL veritabanı içinse 363 elemanlı vektörler elde edilmiştir. LBP öznitelikleri kullanılarak FG-NET, MORPH-I ve PAL veritabanlarında elde edilen yaş tahmini başarımları Tablo 3.8’de görülmektedir.



Şekil 3.7. LBP dönüşümündeki bölge sayısına bağlı yaş tahmini başarımı

Tablo 3.8. LBP özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)

Öznitelik	FG-NET	MORPH-I	PAL
LBP (8x8 bölge)	7.02	5.65	7.8

Tablo 3.8'deki sonuçlar 8x8 bölgeye ayrılan görüntülerden çıkarılan LBP özniteliklerinin, yüzdeki doku bilgisini daha iyi temsil ettiği için, daha önceki öznitelik çıkarma yöntemlerine göre daha iyi bir yaş tahmini performansına sahip olduğunu göstermektedir. Bölgesel LBP özniteliklerinin FG-NET veritabanındaki yaş tahmini başarımı 7.02 yıl MAE iken, MORPH-I ve PAL veritabanlarındaki başarımı sırasıyla 5.65 yıl ve 7.8 yıl MAE'dir.

3.3.5. Gabor Öznitelikleriyle Yaş Tahmini Sonuçları

Çalışmada kullanılan son öznitelik çıkarma yöntemi Gabor filtreleridir. Yüz görüntülerine 4 yön ve 6 ölçekte uygulanan 24 Gabor filtresinin sonucunun birleştirilmesiyle üretilen öznitelik vektörlerinin yaş tahmini başarımları Tablo 3.9'da verilmiştir. Burada öznitelik vektörünün orijinal boyutu filtrelenmiş görüntülere 4x4 altörnekleme işlemi uygulandığı için küçültülerek $22 \times 22 \times 24 = 11616$ olarak elde edilmiştir. Gabor öznitelik vektörünün boyutu PCA(%99) ile küçültüldüğünde ise FG-NET, MORPH ve PAL veritabanları için vektör boyutları sırasıyla 827, 937 ve 355'tir. Tablodan

görüldüğü gibi Gabor filtreleri ile elde edilen MAE'ler FG-NET veritabanı için 6.55 yıl, MORPH-I veritabanı için 5.35 yıl ve PAL veritabanı için 7.37 yıl olup bu sonuçlar tüm doku öznitelik çıkarma yöntemleri değerlendirildiğinde elde edilen en iyi yaş tahmini başarımlarıdır.

Tablo 3.9. Gabor özniteliklerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)

Öznitelik	FG-NET	MORPH-I	PAL
Gabor (4 ölçek x 6 yön)	6.55	5.35	7.37


Çalışmada Gabor yönteminin yüz görüntülerine bölgesel olarak uygulanması ile üretilen özniteliklerin yaş tahmini başarımları da incelenmiştir. Elde edilen sonuçlar yaş tahmini başarımlarında herhangi bir iyileşme sağlamamakla birlikte hesaplama yükünü büyük ölçüde arttırmaktadır. Bu nedenle bu yöntemle yüzün bütününden öznitelik çıkarılması yöntemi tercih edilmiştir.

3.3.6. Öznitelik Çıkarma Yöntemlerinin Yaş Tahmini Başarımlarının Değerlendirilmesi

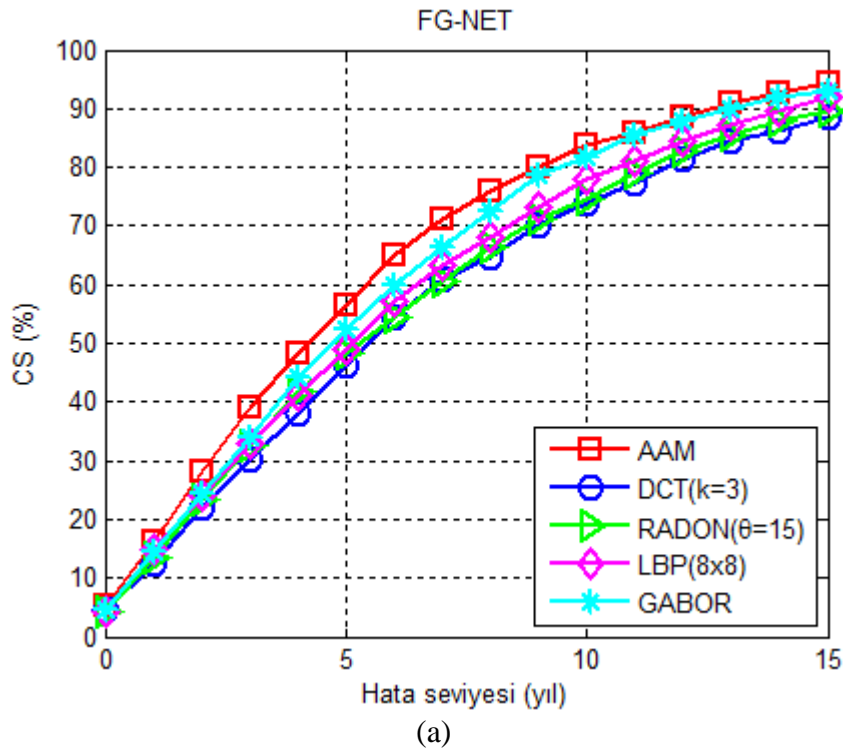
Önceki bölümlerde detayları verilen öznitelik çıkarma yöntemlerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini başarımları Şekil 3.8'de verilmiştir. Şekilden görüldüğü gibi yüzün bütünsel bilgisini içeren AAM öznitelikleri, FG-NET ve PAL veritabanlarında geniş bir yaş aralığına sahip görüntüler için doku özniteliklerine göre yaş tahmininde daha başarılıdır. Yüz görüntülerindeki doku bilgisini çıkarmada kullanılan yöntemlerin yaş tahmini başarımları incelendiğinde ise, yine veritabanlarındaki tüm görüntüler için LBP histogramları ve Gabor filtreleri ile çıkarılan özniteliklerin daha yüksek doğrulukla yaşı tahmin ettiği görülmektedir.

Öznitelik çıkarma yöntemlerinin FG-NET, MORPH-I ve PAL veritabanlarındaki CS grafikleri ise Şekil 3.9'da görülmektedir. CS grafikleri yöntemlerin sınıflandırma doğruluğu olarak düşünülebilir. Grafiklerde yatay esken hata toleransını yıl olarak belirtmektedir. Dikey eksen ise, yatay eksenle karşılık gelen yıl kadar hata toleransı tanındığında yaşı doğru olarak tahmin edilen örneklerin yüzdesini göstermektedir. Şekil 3.9 incelendiğinde yaş tahmini için elde edilen MAE değerleriyle paralel bir şekilde

FGNET ve PAL veritabanlarında en yüksek CS değerlerinin AAM öznitelikleriyle, MORPH-I veritabanında ise Gabor öznitelikleriyle elde edildiği görülmektedir.





Şekil 3.8. Öznitelik çıkarma yöntemlerinin FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini başarımları



Şekil 3.9. Öznitelik çıkarma yöntemleri için CS grafikleri (a) FG-NET veritabanı (b) MORPH-I veritabanı (c) PAL veritabanı

Şekil 3.9'un devamı



Yine bu grafiklerden görüldüğü gibi 10 yıl hata toleransı tanındığında AAM öznitelikleriyle FG-NET veritabanındaki görüntülerin %83.73'ünün yaşı doğru tahmin edilirken, PAL veritabanında bu oran %79.13'tür. MORPH-I veritabanında ise 10 yıl hata toleransı tanındığında Gabor öznitelikleriyle görüntülerin %88.52'sinin yaşı doğru olarak belirlenmektedir.

3.4. Karma Özniteliklerle Tek Aşamalı Yaş Tahmini Sonuçları

Çalışmada yüz görüntülerinin AAM ile çıkarılan genel özniteliklerinin, DCT, LBP, Radon dönüşümü veya Gabor filtreleriyle çıkarılan doku öznitelikleriyle birleştirilmesi sonucu üretilen karma özniteliklerin yaş tahmini başarımı bu bölümde değerlendirilmektedir. Birleştirme işlemi hem öznitelik seviyesinde hem de karar seviyesinde yapılmıştır. Öznitelik seviyesinde birleştirme işleminde, herhangi bir yöntemle üretilen öznitelik vektörleri, z-skor normalizasyonu ile normalize edildikten sonra birleştirilmiştir. Daha sonra birleştirilmiş özniteliklerle yaş tahmini gerçekleştirilmiştir. Karar seviyesinde birleştirme aşamasında ise her bir yöntemin ayrı olarak tahmin ettiği yaş değerlerinin ortalaması alınarak kişinin yaşı belirlenmiştir.

Karma özniteliklerin FG-NET, PAL ve MORPH-I veritabanlarındaki yaş tahmini performansları Tablo 3.10 ve Tablo 3.11'de verilmiştir. Bu tablolardan, çalışmada çeşitli yöntemlerle çıkarılan özniteliklerin karar seviyesinde birleştirilmesi ile elde edilen karma özniteliklerin yaş tahmini başarımının, bu özniteliklerin öznitelik seviyesinde birleştirilmesi ile elde edilen yaş tahmini başarımından daha iyi olduğu görülmektedir. Bu nedenle çalışmada özniteliklerin karar seviyesinde birleştirilmesine dayalı bir yapı kullanılmıştır.

Tablo 3.10. Öznitelik seviyesinde birleştirmeye dayalı karma özniteliklerin FG-NET ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)


Veritabanı	AAM+DCT	AAM+Radon	AAM+LBP	AAM+Gabor
FG-NET	6,56	6,3	6,01	6,09
PAL	7,04	7,2	6,41	6,57

Tablo 3.11. Karar seviyesinde birleştirmeye dayalı karma özniteliklerin FG-NET ve PAL veritabanlarındaki yaş tahmini sonuçları (MAE)

Veritabanı	AAM+DCT	AAM+Radon	AAM+LBP	AAM+Gabor
FG-NET	5.83	5.81	5.39	5.23
PAL	6.93	7.13	5.96	5.70

Öznitelik çıkarma yöntemleri tek başlarına kullanıldığında, FG-NET veritabanında 6.02 yıl MAE ile AAM öznitelikleri en iyi yaş tahmini performansı sağlamaktadır. Daha önce de bahsedildiği gibi AAM yaşın tahmininde genel olarak başarılı bir yöntemdir. Fakat AAM piksel parlaklıklarını kullandığından doku bilgisini kodlayan bir yöntem değildir. Bu özniteliklerin herhangi bir yöntemle üretilen doku öznitelikleriyle birleştirilmesi ile başarımlar artmaktadır. Tablo 3.11'deki MAE değerleri incelendiğinde AAM ile çıkarılan özniteliklerle doku özniteliklerinin birleşiminin yaş tahmini performansını arttırdığı görülmektedir. Tablodaki sonuçlara göre, AAM öznitelikleriyle LBP ya da Gabor özniteliklerinin birleşimi, yaş tahmini performansını büyük ölçüde arttırmaktadır (Şekil 3.10). Benzer şekilde PAL veritabanı için de AAM öznitelikleri tüm öznitelikler arasında 6.61 yıl MAE ile en iyi performansı sağlamaktadır. PAL veritabanında DCT ve Radon dönüşümü ile üretilen doku öznitelikleri diğer yöntemlerle üretilen doku özniteliklerine göre tek aşamalı yaş tahmininde daha düşük bir performansa sahiptir. Bu nedenle bu öznitelikler, AAM öznitelikleriyle birleştirildiğinde yaş tahmini başarımları artsa da AAM özniteliklerinin tek başlarına sağladığı performanstan daha iyi bir sonuç vermemektedir. PAL veritabanı için de AAM özniteliklerinin LBP ya da Gabor öznitelikleriyle birleştirilmesi ile daha iyi MAE sonuçlarına ulaşılmıştır (Şekil 3.10).

Tablo 3.11'deki sonuçlar dikkate alındığında AAM özniteliklerinin LBP ya da Gabor öznitelikleriyle birleştirilmesiyle, hem FG-NET hem de PAL veritabanında yaş tahmini başarımlarının büyük ölçüde arttığı görülmektedir. LBP yüz görüntülerindeki kenar, benek, leke gibi mikro-örüntülerle ilgili bilgi sunarken Gabor filtreleri kırışıklık bilgisini çıkarmaktadır. Daha iyi bir yaş tahmini performansı elde etmek amacıyla AAM öznitelikleri LBP ve Gabor öznitelikleriyle hem öznitelik hem de karar seviyesinde birleştirilmiş ve FG-NET ve PAL veritabanları için elde edilen sonuçlar Tablo 3.12'de verilmiştir. Tablodaki sonuçlara göre AAM+LBP+Gabor özniteliklerinin yine karar seviyesinde birleştirilmesiyle FG-NET veritabanında 4.87 yıl, PAL veritabanında 5.38 yıl MAE başarı ile yaş tahmin edilmektedir.




Şekil 3.10. Karma özniteliklerin FG-NET ve PAL veritabanlarındaki yaş tahmini başarımları

Tablo 3.12. Öznitelik ve karar seviyesinde birleştirilen AAM+LBP+Gabor ve LBP+Gabor özniteliklerinin FG-NET, PAL ve MORPH-I veritabanlarındaki yaş tahmini başarımları (MAE)

Öznitelikler	LBP+Gabor		AAM+LBP+Gabor	
	Öznitelik Seviyesinde	Karar Seviyesinde	Öznitelik Seviyesinde	Karar Seviyesinde
FG-NET	5.73	5.76	5.46	<u>4.87</u>
MORPH-I	4.64	<u>4.51</u>	-	-
PAL	6.45	6.44	5.87	<u>5.38</u>

Çalışmada MORPH-I veritabanı için AAM öznitelikleri üretilmediğinden, DCT ve Radon özniteliklerine göre daha iyi performans sağlayan LBP ve Gabor özniteliklerinin birleştirilmesi ile yaş tahmini performansının değişip değişmeyeceği incelenmiştir (Şekil 3.11). Tablo 3.12'den görüldüğü gibi MORPH-I veritabanında LBP ve Gabor özniteliklerinin karar seviyesinde birleşimi, 4.51 yıl MAE ile daha iyi bir başarımlı sağlamıştır. FG-NET ve PAL veritabanlarında ise LBP ve Gabor özniteliklerinin birleştirilmesi ile elde edilen sonuç AAM+LBP+Gabor öznitelikleriyle elde edilen sonuçtan daha kötüdür.





Şekil 3.11. Karma özniteliklerin MORPH-I veritabanındaki yaş tahmini başarımları

Karma özniteliklerle veritabanları için elde edilen CS grafikleri ise Şekil 3.12'de görülmektedir. Şekil 3.12.a'da görüldüğü gibi FG-NET veritabanında AAM özniteliklerinin herhangi bir doku öznitelikleriyle birleştirilmesi sonucunda CS artış göstermektedir. Öznitelikler ayrı olarak kullanıldığında FG-NET veritabanında 10 yıl hata toleransı tanındığında en yüksek CS performansı %83.73 ile AAM özniteliklerine aittir. Yine 10 yıl hata toleransı tanındığında bu veritabanında elde edilen CS değerleri AAM+DCT için %84.93, AAM+Radon için %85.62, AAM+LBP için %86.82, AAM+Gabor için %88.62'dir. AAM+LBP+Gabor öznitelikleri ise aynı koşullarda FG-NET veritabanındaki görüntülerin %89.92'sinin yaşını doğru bir şekilde tahmin etmektedir.


PAL veritabanı için karma özniteliklere bağlı CS değişimini gösteren grafik Şekil 3.12.b'de verilmiştir. Grafik incelendiğinde AAM'in DCT ya da Radon öznitelikleriyle birleştirilmesinin sınıflandırma doğruluğunu arttırmadığı görülmektedir. 10 yıl hata toleransı tanındığında CS sonuçları AAM+DCT için %76.21, AAM+Radon için %76.55'tir. Bu değerler AAM öznitelikleriyle elde edilen %79.13'ten küçüktür. Bu sonuç elde edilen yaş tahmini başarımlarıyla da uyumludur. AAM+LBP ve AAM+Gabor öznitelikleri için CS değerleri sırasıyla %82.83 ve %84.31 olarak elde edilmiş ve başarımın arttığı görülmüştür. PAL veritabanında da FG-NET veritabanında olduğu gibi en iyi sınıflandırma başarımı AAM+LBP+Gabor öznitelikleri ile %85.86 olarak elde edilmiştir.

MORPH-I veritabanı için LBP ve Gabor özniteliklerinin birleştirilmesiyle, sınıflandırma doğruluğu 10 yıl hata toleransı tanındığında %90.68'e çıkarılmıştır (Şekil 3.12.c). Bu öznitelik vektörlerinin ayrı olarak sınıflandırma doğrulukları sırasıyla %86.86 ve %88.52'dir.



Şekil 3.12. Karma öznelikler için CS grafikleri (a) FG-NET veritabanı (b) PAL veritabanı (c) MORPH-I veritabanı

Şekil 3.12'nin devamı



Çalışmada önerilen, farklı özneliklerin karar seviyesinde birleştirilmesine dayalı tek aşamalı yaş tahmini yönteminin sonuçları Tablo 3.13, Tablo 3.14 ve Tablo 3.15'te literatürle kıyaslanmıştır. Tablo 3.13'te FG-NET veritabanı için elde edilen sonuçlarla önceki çalışmalarda rapor edilen sonuçlar karşılaştırıldığında, elde edilen sonucun bu alandaki en temel yöntemlerle elde edilen sonuçlardan daha iyi olduğu görülmektedir. Diğer yandan benzer özneliklerle yaş tahmini gerçekleştiren Choi vd.'nin (2011) rapor ettiği 5.31 MAE'den çok daha iyi bir yaş tahmini başarımı elde edilmiştir. MORPH-I veritabanı ve PAL veritabanı için sonuçların literatürle karşılaştırması sırasıyla Tablo 3.14 ve Tablo 3.15'te verilmiştir. Benzer şekilde bu veritabanları için de yaş tahmini başarımları literatürdeki çalışmalardan daha iyidir. Tablo 3.14'teki 4.34 yıl MAE sonucu MORPH-II veritabanında yapılan deneylerde elde edilmiştir. Çalışmada elde edilen 4.51 yıl MAE, MORPH-I veritabanında rapor edilen en iyi sonuçtur.

Tablo 3.13. FG-NET veritabanı için tek aşamalı yaş tahmini sonuçlarının literatürle kıyaslaması

Yöntem	MAE	Yöntem	MAE
AAS (Geng vd., 2006)	14.83	Ju ve Wang (2010)	6.85
WAS (Geng vd., 2007)	8.06	Geng ve Miles (2009)	5.36
AGES (Geng vd., 2007)	6.77	Yang vd. (2010)	5.67
AGESİda (Geng vd., 2007)	6.22	Suo vd. (2010)	5.97
RUN (Yan vd., 2007b)	5.33	RMIR (Ni vd., 2011)	8.37
Guo vd. (2008a)	5.16	Liang vd. (2011)	5.45
RPK (Yan vd., 2008b)	4.95	Lu ve Tan (2011)	5.75
BIF (Guo vd., 2009a)	4.77	Choi vd. (2011)	5.31
Yan vd. (2009)	5.21	Wu vd. (2012)	5.89
Xiao vd. (2009)	4.93	Geng vd. (2013)	4.76
Long (2009)	5.08	Ma vd. (2015)	8.00
Tez Çalışması			4.87

Tablo 3.14. MORPH-I veritabanı için tek aşamalı yaş tahmini sonuçlarının literatürle kıyaslaması

Yöntem	MAE	Yöntem	MAE
WAS (Geng vd., 2007)	9.32*	RMIR (Ni vd., 2011)	7.13*
AGES (Geng vd., 2007)	8.83*	Geng vd. (2013)	4.87**
AGESİda (Geng vd., 2007)	8.07*	Geng vd. (2014)	4.34**
Mokadem vd. (2010)	7.61**	Ma vd. (2015)	8.60*
Tez çalışması			4.51*

*:MORPH-I veritabanı

**:MORPH-II veritabanı

Tablo 3.15. PAL veritabanı için tek aşamalı yaş tahmini sonuçlarının literatürle kıyaslaması

Yöntem	MAE		
Choi vd. (2010)	8.44	Chen vd. (2011)	6.18
Tez çalışması			5.38

3.5. Hiyerarşik Sınıflayıcı ile Yaş Tahmini Sonuçları


Tez çalışmasında oluşturulan hiyerarşik sınıflayıcıda, test görüntüsü öncelikle belirlenen yaş gruplarından birine sınıflandırılmakta, daha sonra bu grup altında eğitilen yaşlanma fonksiyonu kullanılarak yaş etiketi belirlenmektedir. Sınıflandırma aşamasında oluşan hata, yaş etiketinin belirlenmesi aşamasındaki başarıyı doğrudan etkileyeceği için yaş gruplarının belirlenmesi ve sınıflandırma yönteminin seçilmesi önem taşımaktadır. Çalışmada önerilen yaş grupları kullanılarak çeşitli yöntemlerle gerçekleştirilen sınıflandırma sonuçları bir sonraki bölümde verilmiştir.

3.5.1. Yaş Gruplarına Sınıflandırma Sonuçları


Yaş gruplarına sınıflandırma aşamasında öncelikle önerilen yaş grupları için hangi sınıflandırma yönteminin kullanılacağı değerlendirilmiştir. Bu amaçla bir önceki bölümde en iyi yaş tahmini başarılarını sağlayan AAM, LBP ve Gabor öznitelikleriyle ayrı ayrı sınıflandırma gerçekleştirilmiştir. Şekil 3.13'te görüldüğü gibi FG-NET, MORPH-I ve PAL veritabanlarında, AAM, LBP ve Gabor öznitelik çıkarma yöntemleri için en iyi CA SVM ile elde edilmiştir. Bu nedenle tez çalışmasında SVM ile sınıflandırma gerçekleştirilmiştir. Şekilden ayrıca yaş grubunun belirlenmesinde, FG-NET veritabanında AAM ile çıkarılan genel özniteliklerin, yerel özniteliklere göre daha iyi bir CA'ya sahip olduğu görülmektedir. Diğer yandan PAL veritabanında LBP ve Gabor filtreleri ile çıkarılan yerel öznitelikler, AAM ile çıkarılan genel özniteliklere göre yaş grubunun belirlenmesinde daha başarılıdır. Burada veritabanlarındaki görüntülerin yaş dağılımı ve görüntüleme koşullarından doğan gürültüler ve görüntü kalitesi büyük önem taşımaktadır.

Sınıflandırma aşamasında da karma bir yapının oluşturulması ve buna bağlı olarak sınıflandırma başarımının artırılması hedeflenmiştir. Burada da yine karar seviyesinde birleştirme işlemi uygulanmıştır. Bu amaçla FG-NET ve PAL veritabanlarında AAM, LBP ve Gabor öznitelikleriyle eğitilen 3 adet SVM sınıflayıcısının sonuçlarının ortalaması ile test örneğinin ait olduğu yaş grubuna karar verilmiştir.


Herhangi bir test örneği sınıflandırma aşamasında herhangi bir yaş grubuna sınıflandırıldıktan sonra o yaş grubu içerisinde yaşı tahmin edilmektedir. Burada üç yöntemin sonuçları birlikte değerlendirilirken en iyi durum bir test örneği için üç sınıflayıcının da aynı sınıf etiketini üretmesidir. (111, 222, 333, 444, gibi). Bunun



(a)



(b)



(c)

Şekil 3.13. Sınıflandırma yöntemlerinin AAM, LBP ve Gabor öz nitelikleriyle sınıflandırma başarımları (a) FG-NET (b) MORPH-I (c) PAL veritabanı

haricindeki durumlarda bir test örneğinin en kötü ihtimalle 1 yakın komşuluğundaki sınıfa sınıflandırılması gerekmektedir. (112, 122, 223, 334, 443 gibi). Bu durumlarda ortalama alındığında örnek zaten çoğunluğun bulunduğu sınıfa sınıflandırılmaktadır. 113 gibi durumlarda ise test örneğinin sınıflandırılmasında bir kararsızlık olduğu düşünüldüğü için 1 ya da 3 nolu sınıfa sınıflandırmak yerine ortalama alınarak 2 nolu sınıfa sınıflandırılması ile yaş tahmini kısmındaki hatanın küçültülmesi hedeflenmiştir. Daha açık bir ifade ile örneğin 21 yaşındaki bir örnek için 113 sonucu elde edilmiş ise örnek için 0-12 aralığında bir yaş tahmini yapılması yerine, 13-19 yaş aralığında bir yaş tahmini yapılması, sistemin toplamdaki yaş tahmini hatasını azaltacaktır. Diğer yandan çalışmadaki temel prensiplerden biri hem yaş gruplarının belirlenmesi hem de uygulanacak yöntem açısından değerlendirildiğinde, veritabanlarından bağımsız genel bir yaş tahmini sisteminin oluşturulmasıdır. Burada puanlamaya dayalı bir sistemin oluşturulması yolu düşünülmüş fakat farklı veritabanlarında ve yaş gruplarında yöntemlerin farklı ağırlıklara sahip olması nedeniyle tüm yöntemlere eşit ağırlık verilmiştir.

MORPH-I veritabanı içinse Gabor öznitelikleriyle eğitilen 1 SVM sınıflayıcısının sonucu alınmıştır. Çünkü bu veritabanında LBP ve Gabor özniteliklerinin birleştirilmesi sonucu sınıflandırma başarımında bir iyileşme sağlanmamıştır. Bu şekilde elde edilen CA'lar Tablo 3.16'da verilmiştir. Tablodan görüldüğü gibi, oluşturulan karma sınıflandırma sistemi ile FG-NET veritabanında %79.64, MORPH-I veritabanında %80.62, PAL veritabanında ise %87.43 CA elde edilmiştir. Öznitelik çıkarma yöntemleri tek başlarına kullanıldığında elde edilen en iyi CA'lar, FG-NET veritabanında AAM öznitelikleriyle %76.65, PAL veritabanında Gabor öznitelikleriyle %83.77 ve MORPH-I veritabanında yine Gabor öznitelikleriyle %80.62'tir. Görüldüğü gibi karar seviyesinde birleştirme işlemi ile sınıflandırma doğruluğunda bir iyileşme sağlanmıştır.

Tablo 3.16. AAM+LBP+Gabor öznitelikleri ile FG-NET, MORPH-I ve PAL veritabanlarındaki sınıflandırma başarımları

VeriTabanı	CA (%)
FG-NET	79.64
MORPH-I	80.62
PAL	87.43

Çalışmada elde edilen sınıflandırma sonuçlarının literatürle kıyaslaması Tablo 3.17’de verilmiştir. Tabloda çeşitli veritabanları üzerinde çeşitli yaş gruplarını kullanarak sınıflandırma gerçekleştiren çalışmaların sonuçları listelenmiştir. Literatür incelendiğinde yaş gruplarına sınıflandırma konusunda yapılan çalışmaların genellikle sempozyumlardaki çalışmalar olduğu görülmüştür. Bazı makalelerde yaş gruplarının deneysel belirlendiğini ifade edilmiştir. Birkaç makalede yaş sınırı 20, 21 olacak şekilde iki gruba sınıflandırma gerçekleştirilmiştir. Bu nedenle sınıflandırma aşamasında oluşturulan bu karşılaştırma tablosundaki çalışmalar ağırlıklı olarak sempozyumlarda yayınlanmış çalışmalardır. Tablo incelendiğinde özellikle FG-NET veritabanı üzerinde değerlendirme yapan çalışmalarda çok çeşitli yaş gruplarının kullanıldığı görülmektedir. Sınıflandırmada kullanılan yaş gruplarının sınırları, sınıflandırma başarımını doğrudan etkileyen bir faktördür. Çünkü insan yüzündeki değişim yaşa göre farklılık göstermektedir. Bu nedenle yaş gruplarının, yüz üzerinde yaşa bağlı olarak meydana gelen değişikliklere uygun bir şekilde seçilmesi, sistemin ayırt etme gücünü arttıracaktır. Bunun dışında yaş sınıflandırma problemi gerçek dünya uygulamalarında, özellikle reklamcılık ve pazarlama gibi alanlarda büyük önem taşımaktadır. Örneğin bir pazarlama şirketi ürünlerinin tercih edildiği yaş grubunu belirlemek isteyebilir. Benzer şekilde akıllı bir reklam panosu, çevresinde bulunan kişilerin ait olduğu yaş grubuna göre ürün reklamı gösterebilir. Bu problemlerde görüntülerin örneğin 20 yaşa göre iki sınıfa sınıflandırılması ya da 20 yaşındaki kişi ile 60 yaşındaki kişinin aynı sınıfa dahil edilmesi herhangi bir bilgi sağlamayacaktır. Burada görüntülerin ergen, genç, orta yaşlı ya da yaşlı olarak sınıflandırılması istenen sonuca ulaşmada yardımcı olacaktır.

Dikkat edilmesi gereken diğer bir husus ise, oluşturulacak yaş gruplarının sadece deneylerde kullanılan veritabanındaki görüntülerin yaş aralığına göre değil, insanın doğumundan ölümüne kadar tüm yaşamını kapsayacak şekilde düzenlemesi gerektiğidir. Böylece yaş gruplarının veritabanından bağımsız olarak kullanılabilmesi ve genel bir yaş tahmini sisteminin oluşturulması mümkün hale gelir. Yaş gruplarının bu şekilde belirlenmesi, veritabanına bağlı yaş grubu oluşturma problemini ortadan kaldırdığı gibi yapılan çalışmaların karşılaştırılabilir olmasını sağlayacaktır.

Tablo 3.17. Sınıflandırma sonuçlarının literatürle kıyaslaması

Yöntem	Veritabanı	Resim sayısı	Resim Yüzdesi (%)	CA (%)	Yaş Grupları
Wang vd. (2009b)	FGNET MORPH-I	2726	5	96.4	0-12, 12-21, 22-60, ≥61
Chen vd. (2010)	FGNET FERET	180	5	87.8	çocuk, yetişkin, yaşlı
Higashi vd. (2011)	FGNET	261	26	60.69	0-9, 10-19, 20-34, 35-64
Zhou vd. (2011)	FGNET	1002	100	75	0-20, 21-69
Zhan vd. (2011)	FGNET	1002	100	58 60.9	0-5, 6-11, 12-17, 18-29, 40-44 0-19, 20-29, 30-39, 40-69
Tonchev vd. (2011)	FGNET	1002	100	77.73	0-16, 17-69
Guo vd. (2011)	FGNET	1002	100	-	0-14, 15-29, 30-49, 50-69
Liu vd. (2012)	FGNET	250	25	79.2	0-2,3-10,11-18,19-39,40-69
Nithyashri ve Kulanthaivel (2012)	FGNET	-	-	94.28	0-12, 13-18, 19-59, 60-69
Izadpanahi ve Toygar (2012)	FGNET İran VT.	854	17	90	0-2, 3-7, 8-19, 20-39, 40-60
Kohli vd. (2013)	FGNET	1002	100	84	0-21, 22-69
Kalansuriya ve Dharmaratne (2013)	FGNET FERET	750	18	74.8	8-13, 14-25, 26-45, 46-63
Luo vd. (2013)	FGNET MORPH-I	1666	61	79.89 (K) 73.90 (E)	0-9, 10-19, 20-29, 30-39, 40-49, 50-59, ≥60
Tharwat vd. (2013)	FGNET	933	93	-	0-9, 10-19, 20-29, 30-39
Liang vd. (2013)	FGNET	1002	100	-	0-9, 10-19, 20-29, 30-39, 40-69
Liu vd. (2014)	FGNET	1002	100	95.1	0-3, 4-19, 20-59
Weixing vd. (2014)	FGNET kendi vt.	1600	-	85.75	0-17, 18-45, 46-60, 60-69
Sai vd. (2015)	FGNET PAL	383	24	75	0-10, 11-19, 20-60, >60
Txia ve Huang (2009)	MORPH-I	251	14	72.52	21-30, 31-40, 41-50, 51-60
Zhou vd. (2011)	MORPH-I	1724	100	86	0-20, 21-68
Liu vd. (2014)	MORPH- II	55134	100	93.7	16-19, 20-59, 60-77
Tez Çalışması	FGNET	1002	100	79.64	0-12, 13-19, 20-39, 40-64, ≥65
	MORPH-I	1690	100	80.62	
	PAL	580	100	87.43	

Tablo 3.17’de daha önce yapılan çalışmalarda kullanılan veritabanları, görüntü sayıları, veritabanlarındaki görüntülerin kullanım yüzdesi, sınıflandırma başarımları ve yaş grupları verilmiştir. Resim yüzdesi sütunu, ilgili çalışmada kullanılan görüntü sayısının veritabanındaki toplam görüntü sayısına oranını belirtmektedir. Bu alan dikkate alındığında, pek çok çalışmada rapor edilen CA’ların veritabanının küçük bir bölümü kullanılarak elde edildiği görülmektedir (Wang vd., 2009b; Chen vd., 2010; Higashi vd., 2011; Liu vd., 2012; Nithyashri ve Kulanthaivel, 2012; Izadpanahi ve Toygar, 2012; Kalansuriya ve Dharmaratne, 2013; Luo vd., 2013; Weixing vd., 2014; Sai vd., 2015). Bu çalışmalarda hangi görüntülerin seçildiğini bilmek mümkün olmadığından tez çalışması ile kıyaslama yapılması mümkün olmamaktadır. Zhou vd. (2011), Tonchev vd. (2011) ve Kohli vd. (2013) görüntüleri sırasıyla 20, 16 ve 21 yaş sınır olacak şekilde iki yaş grubuna sınıflandırmıştır. Zhou vd.’nin (2011) ve Tonchev vd.’nin (2011) iki sınıflı sınıflandırma probleminde elde ettiği CA, çalışmada 4 sınıflı sınıflandırma problemi için elde edilen CA’da daha düşüktür. Kohli vd.’nin (2013) iki sınıflı sınıflandırma probleminde elde ettiği CA ise çalışmanın CA’sından çokta büyük değildir. Tablodaki diğer çalışmalardan Tharwat vd. (2013), veritabanındaki 40 yaş ve altı görüntüler için yaş grupları oluşturmuş ve herhangi bir CA rapor etmemiştir. Liu vd.’nin (2014) çalışmalarında ise oluşturulan yaş grupları dengeli bir dağılıma sahip değildir ve FG-NET ve MORPH-I veritabanı için farklı yaş grupları oluşturulduğundan bir genellik taşımamaktadır. Bütün bu açıklamalar ışığında çalışmada önerilen yaş grupları ile yapılan sınıflandırmanın sonuçlarının, farklı yaş grupları kullanıldığında nasıl değişeceğini görmek amacıyla, Zhan vd.’nin (2011) ve Guo vd.’nin (2011) çalışmalarındaki yaş grupları ile sınıflandırma gerçekleştirilmiş ve elde edilen sonuçlar Tablo 3.18’de verilmiştir. Sonuçlar çalışmada önerilen yaş gruplarının, çıkarılan öznelikler için, tüm veritabanlarında diğer yaş gruplarına göre daha yüksek bir CA elde edilmesini sağladığını göstermektedir.

Tablo 3.18. FG-NET, MORPH-I ve PAL veritabanlarında yaş gruplarına göre CA (%) değişimi

Yaş Grubu	FG-NET	MORPH-I	PAL
Zhan vd. (2011)	78.41	60.32	81.15
Guo vd. (2011)	79.47	79.52	84.29
Önerilen	79.64	80.62	87.43

3.5.2. Yaş Grupları Altında Yaş Tahmini Sonuçları

Herhangi bir görüntünün ait olduğu yaş grubu belirlendikten sonra, o yaş grubu altında eğitilen yaşlanma fonksiyonu kullanılarak kesin yaş etiketi belirlenmektedir. Bu bölümde öncelikle sınıflandırma kısmında oluşan hata yok sayılarak, yaş grupları altında yaş tahmini gerçekleştirilmiş ve elde edilebilecek en iyi MAE'ler belirlenmiştir. Tek aşamalı yaş tahmini bölümünde en iyi başarıyı gösteren AAM, LBP ve Gabor öznitelikleriyle bu şekilde üretilen yaş tahmini sonuçları Tablo 3.19'da görülmektedir. Yaş gruplarında gerçekleştirilen yaş tahmini sonuçlarının ağırlıklı ortalamalarına göre, tek aşamalı yaş tahmininde olduğu gibi en iyi yaş tahmini performansı FG-NET ve PAL veritabanlarında AAM+LBP+Gabor öznitelikleriyle, MORPH-I veritabanında ise LBP+Gabor öznitelikleriyle elde edilmiştir. Bu özniteliklerin yaş gruplarındaki yaş tahmini sonuçları ise Tablo 3.20'de verilmiştir. Tablodan görüldüğü gibi FG-NET, MORPH-I ve PAL veritabanlarında en iyi yaş tahmini başarımları sırasıyla 2.40, 3.17 ve 4.01 yıl MAE'dir. Diğer yöntemlerin yaş grupları altındaki başarımları ise Ek-3'te verilmiştir.

Tablo 3.19. FG-NET, MORPH-I ve PAL veritabanlarında AAM, LBP ve Gabor özniteliklerinin yaş tahmini başarımları (MAE)

Veritabanı	AAM	LBP	Gabor	AAM+LBP	AAM+Gabor	LBP+Gabor	AAM+LBP+Gabor
FG-NET	2.81	2.91	2.66	2.49	2.45	2.53	<u>2.40</u>
MORPH-I	-	3.68	3.43	-	-	<u>3.17</u>	-
PAL	4.42	4.30	4.28	4.12	4.07	4.10	<u>4.01</u>

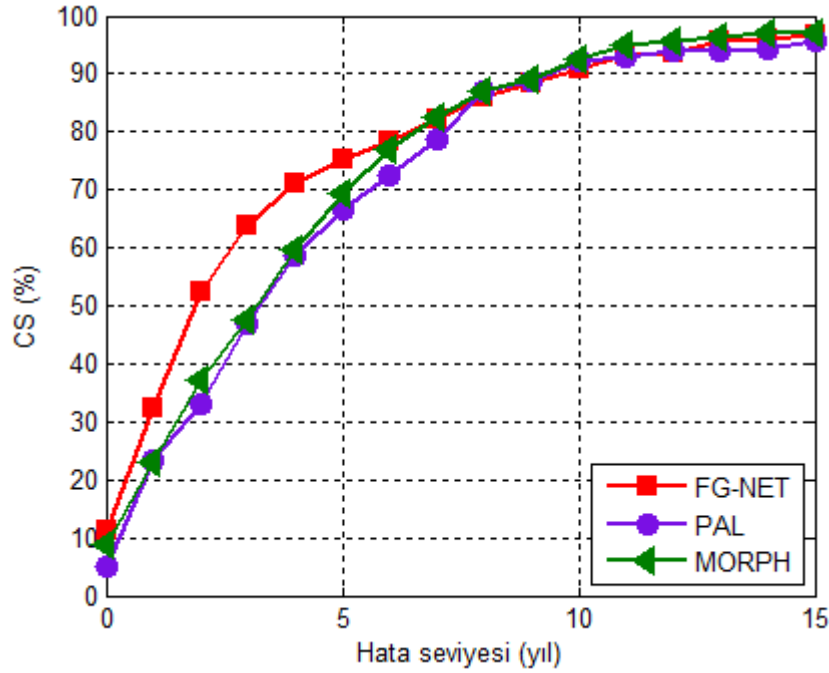
Tablo 3.20. Karma özniteliklerin yaş grupları altındaki yaş tahmini başarımları (MAE)

Yaş Grubu	FG-NET	MORPH-I	PAL
0-12	1.72	-	-
13-19	1.55	0.98	0.52
20-39	4.10	3.74	3.33
40-64	4.58	3.64	5.71
65-93	-	-	4.55
Ortalama MAE	2.40	3.17	4.01

Çalışmada oluşturulan hiyerarşik yaş tahmini sistemi yaş gruplarına sınıflandırma ve yaş gruplarının altında kesin yaşın belirlenmesi aşamalarından oluşmaktadır. FG-NET ve PAL veritabanlarında, hem sınıflandırma hem de yaşın tahmini aşamalarında AAM, LBP ve Gabor özniteliklerinin birleşiminden oluşan karma bir sistem tasarlanmıştır. Sınıflandırmada AAM, LBP ve Gabor öznitelikleriyle ayrı ayrı eğitilmiş SVM sınıflayıcılarının sonuçlarının ortalaması ile örneğin dahil olduğu yaş grubuna karar verilmiştir. Yaşın tahmininde ise yine bu özniteliklerle ayrı olarak eğitilen yaşlanma fonksiyonlarının sonuçlarının ortalaması alınarak yaş etiketi belirlenmiştir. MORPH-I veritabanı içinse sınıflandırma aşamasında Gabor öznitelikleriyle eğitilen bir SVM sınıflayıcısı kullanılırken, yaşın tahmininde LBP ve Gabor öznitelikleriyle eğitilen yaşlanma fonksiyonlarının sonuçlarının ortalaması kullanılmıştır. Hiyerarşik yaş tahmini sisteminin FG-NET, MORPH-I ve PAL veritabanı üzerindeki yaş tahmini başarımları Tablo 3.21’de, CS grafikleri Şekil 3.14’te görülmektedir. Görüldüğü gibi hiyerarşik sınıflayıcı ile FG-NET veritabanında 4.13, MORPH-I veritabanında 4.35, PAL veritabanında ise 4.67 yıl hata ile yaş tahmini gerçekleştirilmiştir. Hiyerarşik sınıflayıcı için 10 yıl hata ile yaşı doğru tahmin edilebilecek örneklerin oranı FG-NET veritabanında %90.88, MORPH-I veritabanında %92.50 ve PAL veritabanında %92.17 olarak elde edilmiştir. 5 yıl hata toleransı tanındığında ise veritabanlarındaki örneklerin sırasıyla %75.37, %69.47 ve %66.48’inin yaşı doğru tahmin edilebilmektedir. Tek aşamalı yaş tahmininde bu değerler FG-NET için %65.46, MORPH-I için %65.08 ve PAL için %56.37 olarak elde edilmiştir.

Tablo 3.21. Hiyerarşik yaş tahmini sisteminin FG-NET, MORPH-I ve PAL veritabanları için yaş tahmini başarımları

Veritabanı	MAE
FG-NET	4.13
MORPH-I	4.35
PAL	4.67



Şekil 3.14. Hiyerarşik yaş tahmini sisteminin FG-NET, MORPH-I ve PAL veritabanları için CS grafikleri

Hiyerarşik sınıflayıcı ile üretilen yaş tahmini başarımlarının literatürle karşılaştırılması Tablo 3.22, Tablo 3.23 ve Tablo 3.24'te görülmektedir. Tablo 3.22'de FG-NET veritabanı üzerinde yapılan çalışmalarda elde edilen sonuçlar görülmektedir. Sonuçlar incelendiğinde çalışmada elde edilen 4.13 yıl MAE değerinin şimdiye kadar rapor edilen en iyi sonuçlardan biri olduğu görülmektedir. Ayrıca Choi vd.'nin (2011) yaptığı öznetelik seviyesinde birleştirme (feature level fusion) gerçekleştiren benzer bir çalışmadan daha iyi bir yaş tahmini performansı elde edilmiştir. Egyptian Informatics Journal'da yayınlanan El-dib ve Onsi'ye (2011) ait çalışmada rapor edilen 3.71 MAE için CS(10) değerinin %80 civarında olması elde edilen sonuçların bütünlüğü açısından çelişki oluşturmaktadır. Diğer yandan bu çalışmada kullanılan yöntemi ilk öneren Guo vd.'nin (2009a) çalışmalarında (Tablo 3.13), yaş tahmini başarımları 4.77 yıl MAE ile CS(10) değeri %89 seviyesindedir. Kohli vd. (2013) çalışmalarında ise rapor edilen 3.85 yıl MAE 802 örneğin eğitim, 200 örneğin test aşamasında kullanılması ile elde edilen bir sonuçtur. Çalışmada FG-NET veritabanı için değerlendirme yöntemi olarak, literatürdeki çalışmaların büyük çoğunluğunda kullanılan LOPO yöntemi kullanılmıştır. MORPH-I veritabanı üzerinde yaş tahmini yapan çalışmalarda ise, Tablo 3.23'te görüldüğü gibi, çalışmada elde edilen 4.35 yıl MAE şimdiye kadar rapor edilen en iyi yaş tahmini başarımlarıdır.

Tablo 3.22. FG-NET veritabanı için hiyerarşik yaş tahmini sonuçlarının literatürle kıyaslaması

Yöntem	MAE	Yöntem	MAE
LARR (Guo vd., 2008b)	5.07	Luu vd. (2011b)	4.12
PFA (Guo vd., 2008c)	4.97	Li vd. (2012)	4.32
Luu vd. (2009)	4.37	Kohli vd. (2013)	3.85
Choi vd. (2011)	4.65	Chao vd. (2013)	4.38
El-Dib ve Onsi (2011)	3.71	Tharwat vd. (2013)	6.60
Guo vd. (2011)	4.18	Liang vd. (2013)	5.37
Luu vd. (2011a)	4.22	Han vd. (2014)	4.80
Tez çalışması			4.13

Tablo 3.23. MORPH-I veritabanı için hiyerarşik yaş tahmini sonuçlarının literatürle kıyaslaması

Yöntem	MAE
Han vd. (2014)	6.38
Tez çalışması	4.35

Tablo 3.24. PAL veritabanı için hiyerarşik yaş tahmini sonuçlarının literatürle kıyaslaması

Yöntem	MAE
Luu vd. (2011a)	7.17
Luu vd. (2011b)	6.00
Choi vd. (2011)	4.32
Tez çalışması	4.67


PAL veritabanı için literatürle karşılaştırma Tablo 3.24'te yapılmıştır. Bu tabloda Choi vd.'nin (2011) ürettiği 4.32 yıl MAE, çalışmada elde edilen başarımdan daha iyidir. Fakat Choi vd. (2011), oluşturdukları hiyerarşik sistemde yaş gruplarını veritabanları için deneysel olarak belirlediklerini ve yüz ifadelerinin yaş tahminine olumsuz etkisini ortadan kaldırmak için, ifadesiz yüzler üzerinde deneyler gerçekleştirdiklerini ifade etmiştir. Tez

çalışmasının bu kısmındaki amaç veritabanından bağımsız olarak her durumda iyi sonuç verebilecek genel bir yaş tahmini sisteminin oluşturulmasıdır. Bu nedenle çalışmada yaş gruplarının her bir veritabanı için deneysel olarak en iyi sonucu verecek şekilde belirlenmesi yoluna gidilmemiştir. Diğer yandan farklı yüz ifadelerine sahip resimlerden oluşan veritabanlarındaki tüm görüntüler üzerinde yöntem sonuçları rapor edilmiştir.


3.6. Yaş Modelleriyle Yaş Grubuna Sınıflandırma Sonuçları

Çalışmada önerilen morflemeyle dayalı model tabanlı yaş tahmini yaklaşımının sonuçları bu bölümde verilecektir. Yöntemde test görüntüleri, üretilen yaş modelleri üzerinden sınıflandırılmaktadır. Sınıflandırma işlemi yaş modellerinden çıkarılan özniteliklerle, ön işleme aşamasından geçen test örneklerinden çıkarılan özniteliklerin çeşitli uzaklık ölçütlerine göre karşılaştırılması ile gerçekleştirilmektedir.


Çalışmada önerilen yöntemin hem yaş gruplarına göre hem de cinsiyete göre başarımları değerlendirilmiştir. Öncelikle yaş gruplarını temsil etmek için, seçilen görüntülerden bir erkek bir kadın yaş modeli üretilmiş ve her bir yaş grubu iki yaş modeli ile temsil edildiğinde sınıflandırma başarımları hesaplanmıştır. Daha sonra her yaş grubunun, o yaş grubundan seçilen erkek ve kadın görüntülerin birleşiminden oluşan bir erkek-kadın yaş modeli ile temsil edilmesi sonucu, sınıflandırma başarımlarındaki değişim incelenmiştir. FG-NET ve PAL veritabanları için elde edilen sonuçlar Şekil 3.15'te verilmiştir. Şekilde verilen sonuçlar veritabanlarındaki tüm yaş grupları için uzaklık ölçütlerinden elde edilen en iyi sınıflandırma başarımlarıdır. Buradaki amaç yaş gruplarının temsilinde kullanılacak yaş modellerinin cinsiyete bağlı olarak başarımları nasıl etkilediğinin belirlenmesidir. Bu nedenle tüm uzaklık ölçütlerinin sonuçları ayrı ayrı verilmemiştir. Şekilden görüldüğü gibi, yaş gruplarının temsil edilmesinde o yaş grubundan dengeli olarak seçilen örneklerin cinsiyetten bağımsız şekilde birleştirilmesiyle üretilen yaş modellerinin kullanımı, genel olarak sınıflandırma başarımlarını arttırmaktadır.



(a)




(b)



(c)

Şekil 3.15. Yaş modellerine göre sınıflandırma başarımları (a) FG-NET veritabanı erkek örnekler (b) FG-NET veritabanı kadın örnekler (c) PAL veritabanı erkek örnekler (d) PAL veritabanı kadın örnekler


Şekil 3.15'in devamı



(d)

FG-NET veritabanındaki erkek örnekler için elde edilen sonuçlara göre, sınıflandırma sistemi tüm yaş gruplarında bir erkek-kadın yaş modeli ile az da olsa daha iyi bir performansa sahiptir. FG-NET veritabanındaki kadın örnekler için ise 40-64 yaş grubu için tek yaş modelinin kullanımı sınıflandırma başarımını düşürmektedir. Ama genel olarak bu veritabanı için tek yaş modelinin kullanımı daha iyi bir başarımın elde edilmesini sağlamaktadır. Benzer şekilde PAL veritabanı için erkek örneklerde ≥ 65 yaş grubu için tek yaş modelinin kullanımı sınıflandırma başarımını biraz düşürse de, genel olarak yaş gruplarının temsilinde tek yaş modelinin kullanımı ile daha iyi bir performans elde edilmektedir. Bu nedenle çalışmada önerilen model tabanlı yaş tahmini sisteminde yaş gruplarının tek yaş modeli ile temsil edilmesi ve bu yaş modelleri üzerinden sınıflandırma yapılması yoluna gidilmiştir. Yine Şekil 3.15'ten hem FG-NET hem de PAL veritabanındaki yaş gruplarında, erkek örnekler için elde edilen sınıflandırma başarımının kadın örnekler için elde edilenden daha yüksek olduğu görülmektedir. Genel olarak veritabanlarındaki tüm görüntüler için cinsiyete bağlı yaş tahmini performansı Şekil 3.16'da verilmiştir. Şekilden görüldüğü gibi FG-NET ve PAL veritabanındaki tüm yaş etiketleri dikkate alındığında erkek örneklerin yaş grubu kadın örneklere göre daha başarılı bir şekilde belirlenmektedir. Kadın örnekler, kullandıkları kozmetik ürünler nedeniyle, erkek örneklere göre çok daha çeşitli yaşlanma özelliklerine sahip olduğundan, bu sonuç doğadaki gerçeğin bir yansımasıdır. Bu sonuç aynı zamanda cinsiyetin yaş tahmini başarımına etkisini inceleyen çalışmalar tarafından da desteklenmektedir (Nguyen vd., 2014). Bu aşamada FG-NET veritabanında erkek örnekler için %81.79, kadın örnekler


için %75.89 CA elde edilirken, PAL veritabanında erkek ve kadın örnekler için sırasıyla %79.67 ve %69.89 CA sonucuna ulaşılmıştır. Veritabanlarındaki tüm örnekler için CA hesaplandığında ise FG-NET için %79.24, PAL için %73.68 değerleri elde edilmiştir.




Şekil 3.16. FG-NET ve PAL veritabanlarında cinsiyete göre sınıflandırma başarımı

Sınıflandırma aşamasında kullanılan çeşitli uzaklık ölçütleriyle elde edilen sonuçlar ise Şekil 3.17’de görülmektedir. Şekilden görüldüğü gibi sınıflandırma aşamasında kullanılan uzaklık ölçütlerinin sınıflandırma başarımı yaş gruplarına ve cinsiyete göre farklılık göstermektedir. Bir yaş grubunda en iyi sonucu veren uzaklık ölçütü diğer bir yaş grubunda en kötü performansa sahip olabilmektedir. Burada dikkati çeken diğer bir husus ise FG-NET veritabanında genel olarak, hem erkek hem de kadın örnekler için 20-39 yaş grubu için sınıflandırma başarımı diğer yaş gruplarına göre belirgin bir şekilde daha düşüktür. Bunun nedeni bu yaş grubundaki örneklerin yaşlanma karakteristikleri açısından çevredeki gruplara benzetilme olasılıklarının daha fazla olması olabilir.


Benzer şekilde PAL veritabanında erkek örnekler için 20-39 yaş grubundaki sınıflandırma başarımı diğer yaş gruplarına oranla daha düşüktür. PAL veritabanındaki kadın örnekler için ise 20-39 ve 40-64 yaş gruplarındaki başarımın, diğer yaş gruplarına göre daha düşük olduğu gözlenmiştir. Bu ise, PAL veritabanındaki görüntülerin, görüntüleme koşullarının FG-NET’e göre daha iyi olması nedeniyle, kadın örneklerdeki makyaj, kozmetik ürün kullanımının etkilerinin, sistem başarımını daha belirgin bir şekilde etkilemesinden kaynaklanmaktadır.



(a)




(b)



(c)

Şekil 3.17. Uzaklık ölçütlerinin yaş gruplarındaki sınıflandırma başarımı (a) FG-NET veritabanı erkek örnekler (b) FG-NET veritabanı kadın örnekler (c) PAL veritabanı erkek örnekler (d) PAL veritabanı kadın örnekler

Şekil 3.17'nin devamı

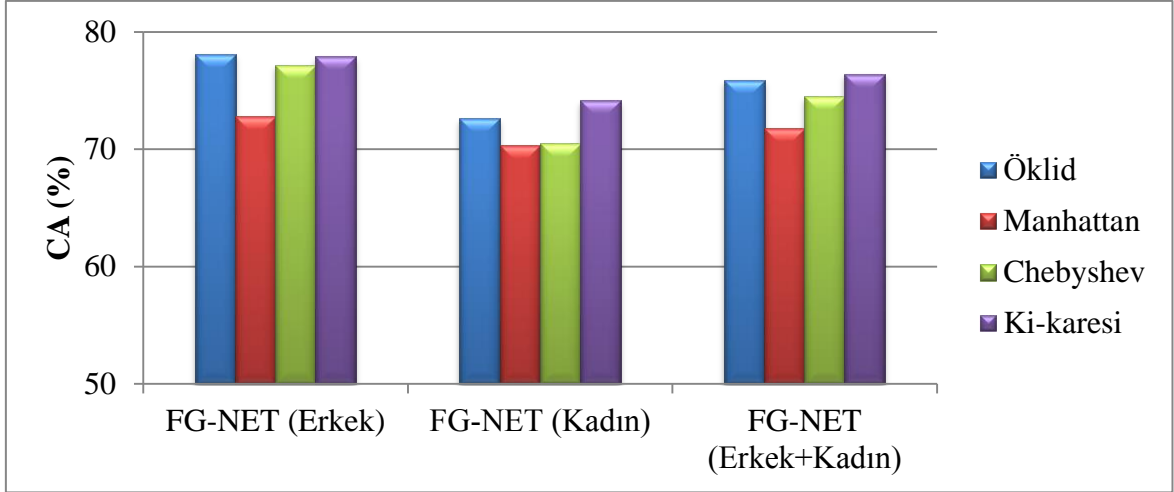


(d)


Sınıflandırmada kullanılan uzaklık ölçütlerinin FG-NET ve PAL veritabanlarındaki tüm yaş aralığı için, cinsiyete bağlı ve cinsiyetten bağımsız olarak elde edilen sınıflandırma başarımları Şekil 3.18'de görülmektedir. Şekilde farklı uzaklık ölçütleri için kadın örneklerin sınıflandırma başarımının erkek örneklere göre daha düşük olduğu, bunun da sistemin toplam başarımını düşürdüğü görülmektedir. Diğer yandan uzaklık ölçütlerinin sınıflandırma başarımlarının büyük bir farklılık göstermediği dikkat çekmektedir. Tek başlarına kullanıldıklarında FG-NET veritabanı için Ki-karesi ölçütü ile %76.41, PAL veritabanı için ise Öklid uzaklığı ile %70.21 CA elde edilmiştir.

3.7. Oylamaya Dayalı Sınıflandırma Sonuçları

Bu bölümde, sistemin sınıflandırma performansının artırılması ve farklı uzaklık ölçütlerinin sonuçlarının birlikte değerlendirilmesi için çalışmada önerilen oylamaya dayalı puanlama sistemi ile elde edilen sınıflandırma sonuçları verilmektedir. Öncelikle yaş grupları altında cinsiyete göre sınıflandırma başarımları incelenmiştir. Şekil 3.19'da verilen sonuçlar bir önceki bölümde verilen sonuçlarla karşılaştırıldığında, farklı uzaklık ölçütlerinin sonuçlarının oylamaya dayalı bir puanlama sistemi ile birleştirilmesinin yaş tahmini performansını arttırdığını göstermektedir. Genel olarak her iki veritabanında erkek örnekler kadın örneklere göre daha başarılı bir şekilde sınıflandırılmaktadır. Diğer yandan her iki veritabanında 20-39 yaş aralığı en kötü performansın elde edildiği yaş grubudur.




(a)



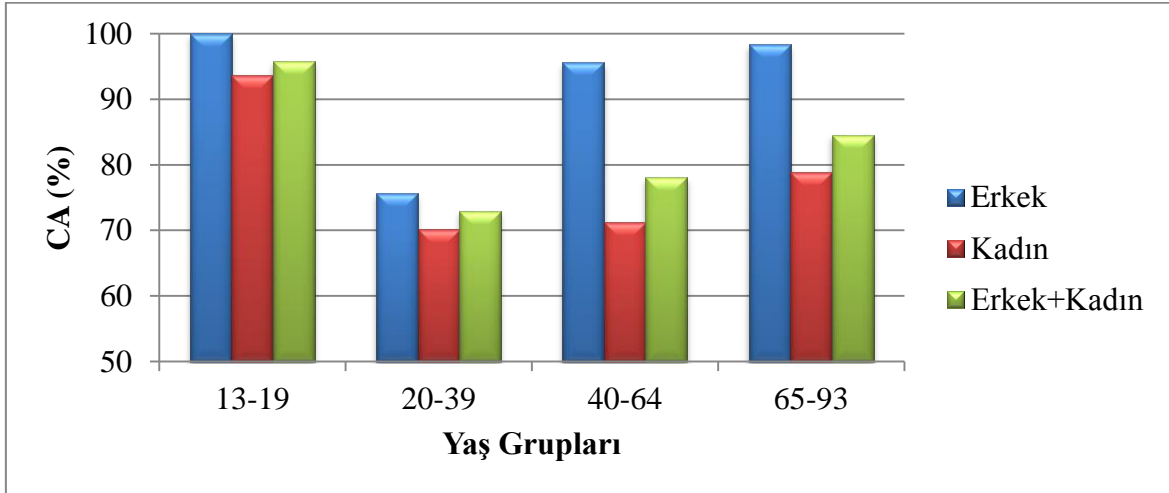
(b)

Şekil 3.18. Uzaklık ölçütlerinin sınıflandırma başarımları (a) FG-NET veritabanı (b) PAL veritabanı

Tez çalışmasında önerilen sınıflandırma yaklaşımının sonuçları Tablo 3.25'te verilmiştir. Sonuçlara göre sistem FG-NET veritabanında erkek örnekler için %86.67, kadın örnekler için %79.48 CA'ya sahiptir. PAL veritabanında ise erkek ve kadın örnekler için sırasıyla %85.37 ve %75.44 CA elde edilmiştir. Önerilen sistem FG-NET veritabanındaki görüntülerin yaş gruplarına sınıflandırılmasında %83.73 başarıya sahipken, PAL veritabanında ise görüntülerin %79.30'u yaş gruplarına doğru bir şekilde sınıflandırılmaktadır.



(a)



(b)

Şekil 3.19. Oylamaya dayalı sınıflandırma sonuçları (a) FG-NET veritabanı (b) PAL veritabanı

Tablo 3.25. Model tabanlı yaş tahmini yönteminin sınıflandırma başarımı

Veritabanı	Erkek (%)	Kadın (%)	Erkek+Kadın (%)
FG-NET	86.67	79.48	83.78
PAL	85.37	75.44	79.30

Görüldüğü gibi model tabanlı yaş tahmini sistemi ile elde edilen sonuçlar, kadın örneklerin yaşının tahmininin erkek örneklere göre daha zor olduğunu göstermektedir. Bunun nedeni kadınların kullandığı yaşlanma karşıtı kozmetik ürünler ve makyajdan dolayı yüzlerindeki yaşlanma etkilerinin görünürlüğünün azalmasıdır. Bu ise sistemin

genel performansını dűűrmektedir. Dięer yandan eűitli yűntemlerle elde edilen sınıflandırma sonularının (Ŗekil 3.18) puanlamaya dayalı olarak birleűtirilmesiyle, cinsiyetten baęımsız olarak baűarımın arttıęı gűrűlmektedir. Model tabanlı yaű tahmini yaklaűımının kullanımı, sınıflandırma sisteminin ok sayıda rnekle eęitilen karmaűık bir sisteme gre daha basit ve hızlı bir űekilde sınıflandırma yapabilmesini saęlamaktadır.

4. SONUÇLAR

Bu çalışmada temassız olarak, sadece kişilerin yüz görüntülerinden faydalanılarak otomatik bir yaş tahmini sistemi önerilmiş ve performans değerlendirilmesi gerçekleştirilmiştir. Yaşın tahmini, bir yüz görüntüsünün otomatik olarak bir yaş grubu ya da bir yaş etiketi ile ilişkilendirilmesi anlamına gelmektedir. Her yaş etiketi ayrı bir küme olarak ele alındığında problem, çok-kararlı bir sınıflandırma problemi olarak değerlendirilebilir. Özellikle 2000'li yıllardan sonra ciddi çalışmalar yapılmaya başlanan alan, gerçek hayatta kullanılabilecek çok sayıda uygulamaya sahip olması nedeniyle her geçen gün daha fazla ilgi çekmektedir.

Yaş tahmini çalışmaları genellikle iki önemli kısımdan oluşmaktadır. Bunlar yaşla ilgili özniteliklerin çıkarılması ve sınıflayıcının tasarımıdır. Her iki kısım da, sınıflandırma başarımını doğrudan etkilemektedir. Fakat yüz görüntülerinin karakteristiği problemin çözümünü zorlaştırmaktadır. Görüntülerdeki aydınlatma, arka plan, poz, yüz ifadesi gibi etkenler tüm yüz görüntüsü işleme sistemlerinin ortak problemleridir. Bunların yanında, yüz üzerindeki gerçek yaşlanma etkilerinin kişiden kişiye farklılık göstermesi, yüz görüntülerinde doğrudan yaşı temsil eden öznitelik türlerinin belirlenmesini zorlaştırmaktadır. Bu nedenle yaşla ilişkili özniteliklerin iyi bir şekilde seçilememesi en güçlü sınıflayıcıların bile başarısız olmasına neden olabilmektedir. Diğer yandan yaş tahmininin, büyük bir yaş aralığına sahip görüntüler kullanılarak yapılması, aralıktaki olası yaş etiketi sayısının fazla olması nedeniyle düşük bir başarıım elde edilmesine neden olmaktadır. Bunun yerine, öncelikle kişinin yaş grubunun belirlenmesi ile olası yaş etiketlerinin sayısının azaltılması ve daha küçük bir küme içerisinde yaş tahmininin yapılması başarıımı arttırmaktadır. Burada kullanılacak yaş gruplarının sınırlarının belirlenmesi önem taşımaktadır. Fakat yapılan çalışmalar aynı ölçeğe oturtulmadığından, farklılıklar gösterebilmektedir. Çalışmalarda, veri kümesine göre grupların belirlenmesi, genel bir yaş tahmini sisteminin oluşturulmasını ve sistem başarımlarının karşılaştırılmasını zorlaştırmaktadır. Bu nedenle yaş gruplarındaki farklılıkların ortadan kaldırılarak tek bir platforma oturtulması gereksinimi ortaya çıkmaktadır.

Bu problemler göz önünde bulundurularak, yapılan tez çalışmasında karma özniteliklere dayalı hiyerarşik bir yaş tahmini sistemi geliştirilmiştir. Ayrıca model tabanlı bir sınıflandırma sistemi oluşturulmuş, oylamaya dayalı bir puanlama sistemi kullanılarak

sınıflandırma sonuçları iyileştirilmiştir. Bu sisteme ilişkin sonuçlar kısaca aşağıdaki şekilde özetlenebilir.

1. Yaş tahmini çalışmalarında sınıflandırmada aşamasında kullanılan yaş gruplarının sınırları, sistem başarımı doğrudan etkileyen bir faktördür. Oluşturulacak grupların sadece deneylerde kullanılan veritabanındaki görüntülerin yaş aralığına göre değil, insanın doğumundan ölümüne kadar tüm yaşamını kapsayacak şekilde düzenlenmesi gerekir. Böylece yaş gruplarının veritabanından bağımsız olarak kullanılabilmesi ve genel bir yaş tahmini sisteminin oluşturulması mümkün hale gelir. Yaş gruplarının bu şekilde belirlenmesi veritabanına bağlı yaş grubu oluşturma problemini ortadan kaldırdığı gibi yapılan çalışmaların karşılaştırılabilir olmasını sağlayacaktır. Çalışmada bu amaçla, yaş grupları için Erikson'a dayalı bir ölçeğin kullanılması önerilmiştir. Yaş grupları çocuk (0-12), ergen (13-19), genç yetişkin (20-39), orta yaşlı (40-64) ve yaşlı (≥ 65) olarak belirlenmiştir. Çalışmada bu yaş grupları kullanılarak karma özniteliklere dayalı hiyerarşik bir yaş tahmini sistemi önerilmiştir. Öznitelik çıkarma aşamasında AAM, DCT, Radon dönüşümü, LBP ve Gabor filtreleri kullanılmış ve başarımlar değerlendirilerek yapılarak sistemin tasarımı gerçekleştirilmiştir. Bu öznitelik çıkarma yöntemleriyle ilgili sonuçlar aşağıda verilmiştir.
2. Yüz görüntülerinden AAM ile çıkarılan genel öznitelikler, şekil modeli parametreleri ve parlaklık modeli parametrelerinden oluşmaktadır. FG-NET ve PAL veritabanlarındaki görüntüler için çıkarılan bu öznitelikler ile gerçekleştirilen yaş tahmininde, şekil öznitelikleri FG-NET veritabanında PAL veritabanına göre çok daha iyi bir başarıma sahiptir. Çünkü FG-NET veritabanındaki görüntülerin %70'i, yüzün şekil yönünden en fazla değiştiği dönem olan 20 yaş altındaki kişilerden oluşmaktadır. PAL veritabanındaki görüntülerin yaş aralığı 18-93 olduğu ve bu veritabanındaki yüzlerde şekil yönünden çok fazla bir değişim olmadığı için, parlaklık öznitelikleri ile elde edilen yaş tahmini başarımı şekil öznitelikleriyle elde edilen yaş tahmini başarımından çok daha iyidir. Sonuç olarak, AAM ile çıkarılan özniteliklerin yaş tahmini başarımı veritabanındaki görüntülerin yaş dağılımına göre değişim göstermektedir.

3. Yaşlanma ile ilgili olarak yüzdeki kırışıklıklar ve derideki değişimler önemli bilgi taşıdığından, yüzün doku analizinin yapılmasını gerektirmektedir. AAM yöntemi görüntüdeki parlaklık değerlerini uzaysal bir komşuluk dikkate almadan kodladığından, yüzdeki doku bilgisini tanımlayamaz. Bu nedenle deride meydana gelen değişikliklerin belirlenmesi ve yerel doku analizine ihtiyaç duyulmaktadır. Çalışmada yüz görüntülerindeki doku bilgisini kodlamak için DCT, Radon dönüşümü, LBP ve Gabor filtreleri kullanılmıştır. Deneylerde kullanılan tüm veritabanlarında, LBP histogramları ve Gabor filtreleri ile çıkarılan doku özniteliklerinin, diğer yöntemlerle çıkarılan özniteliklere göre daha iyi bir yaş tahmini performansı sağladığı görülmüştür. LBP yüz derisinde yaşlanma ile ortaya çıkan kenar, benek, leke gibi doku özelliklerini gri seviyeden bağımsız olarak kodlayabilen bir yöntem olduğundan, yaş tahmininde başarılıdır. LBP'nin yüzün tümüne uygulanması yerine, bölgesel olarak üretilen LBP histogramlarının birleştirilmesi ile üretilen öznitelik vektörü, resim üzerinde bölgesel olarak kenarlar, benekler, düz alanlar gibi mikro-örüntülerle ilgili bilgi taşıdığından, yaş tahmini başarımları daha yüksektir. Diğer yandan yüz görüntülerine çeşitli yön ve ölçekteki Gabor filtrelerinin uygulanması sonucu, yüz üzerinde çeşitli bölgelerde meydana gelen ve kişinin yaşına göre ince ya da derin olabilen farklı yönlere sahip çizgilerin belirlenmesi sağlanmıştır. Bu nedenle Gabor öznitelikleri ile elde edilen yaş tahmini başarımları diğer yöntemlere göre en iyi sonucu vermiştir. Dolayısıyla ile yaşlanma sürecinde deri bölgesinde ortaya çıkan kırışıklıklar, benekler ve lekeler yaşın belirlenmesinde etkin özelliklerdir.
4. Yaşlanma ile ilgili özniteliklerin çıkarılması, yaş tahmini sistemlerinde başarımları etkileyen en önemli faktördür. Bu nedenle yaş tahmini sistemlerinin tasarımında yaşla ilişkili özniteliklerin iyi bir şekilde belirlenmesi gerekmektedir. Çalışmada çeşitli yöntemlerle çıkarılan özniteliklerin birleştirilmesi sonucu, yöntemlerin iyi yönlerinin bir araya getirilmesi ve böylece başarımların artırılması düşüncesi ile, karma özniteliklere dayalı bir yaş tahmini sistemi tasarlanmıştır. Bu amaçla yüz görüntülerinin AAM ile çıkarılan genel öznitelikleri, DCT, LBP, Radon dönüşümü veya Gabor filtreleriyle çıkarılan doku öznitelikleriyle birleştirilerek, karma özniteliklere dayalı yaş tahmini gerçekleştirilmiştir. Birleştirme işlemi karar seviyesinde gerçekleştirilmiştir. FG-NET ve PAL veritabanlarında AAM öznitelikleriyle LBP ya da Gabor özniteliklerinin birleşimi, yaş tahmini

performansını büyük ölçüde arttırmıştır. MORPH veritabanında ise LBP ile çıkarılan doku öznitelikleri, Gabor filtreleri ile çıkarılan kırışıklık öznitelikleriyle birleştirilerek yaş tahmini performansı iyileştirilmiştir. Sonuç olarak karma öznitelikler, farklı yöntemlerin iyi yönlerinin birleştirilmesini ve başarımın arttırılmasını sağlamaktadır.

5. Yaş tahmininin, büyük bir yaş aralığına sahip görüntüler kullanılarak yapılması, aralıktaki olası yaş etiketi sayısının fazla olması nedeniyle düşük bir başarım elde edilmesine neden olmaktadır. Bunun yerine, öncelikle kişinin yaş grubunun belirlenmesi ile olası yaş etiketlerinin sayısının azaltılması ve daha küçük bir küme içerisinde yaşın tahmini, yaş tahmini doğruluğunu arttırmaktadır. Çalışmada tasarlanan hiyerarşik sistemde, görüntülerin sınıflandırılması aşamasında k NN, SVM ve LDA yöntemleri kullanılmış ve en iyi sınıflandırma başarısı SVM ile elde edilmiştir. Sınıflandırma aşamasında tek bir özniteliğe bağlı olarak sınıflandırma yapmak yerine, yaş tahmininde olduğu gibi karma bir sınıflandırma sisteminin oluşturulması, sınıflandırma doğruluğunu arttırmıştır. Kişinin yaşının tahmininde, karma öznitelikler kullanılarak yaş grubuna özel olarak üretilen yaşlanma fonksiyonlarının kullanımı, sistem başarımını arttırmıştır.
6. Sınıflandırma yöntemlerinin performansı, seçilen eğitim örneklerine bağlı olarak farklılık gösterebilmektedir. Ayrıca sistem performansını arttırmak amacıyla büyük miktarda eğitim örneğinin kullanılması, sınıflandırma sisteminin eğitimini daha karmaşık ve zaman alıcı yapmaktadır. Farklı ve büyük eğitim kümelerinin etkilerini ortadan kaldırmak ve daha basit bir sınıflandırma sistemi oluşturmak için, çalışmada ilk kez, yaş gruplarının ortalama yaş bilgisini temsil eden morflemeye dayalı yaş modellerinin üretilmesi önerilmiştir. Önerilen model tabanlı yaş tahmini yaklaşımının cinsiyete bağlı olarak sınıflandırma başarımı değerlendirildiğinde erkek örnekler için daha başarılı olduğu görülmüştür. Bu sonuç, kadın örneklerdeki makyaj, kozmetik ürün kullanımının yaşlanma etkilerinin belirlenmesinde zorluk oluşturması nedeniyle sistem başarımını düşürdüğünü göstermektedir.
7. Sistemin sınıflandırma performansının arttırılması ve farklı yöntemlerle elde edilen sınıflandırma sonuçlarının birlikte değerlendirilmesi için oylamaya dayalı

bir puanlama sistemi kullanılmıştır. Bu sistem ile sınıflandırma başarımında artış sağlanmıştır.

Sonuç olarak yapılan tez çalışmasında karma ve hiyerarşik yöntemler bir arada kullanılarak oldukça kapsamlı ve başarılı bir yaş tahmini sistemi oluşturulmuştur. Bunun yanında literatürde sınıflandırma aşamasında daha önce kullanılmayan, yaş gruplarının ortak karakteristiklerini temsil eden yaş modellerinin üretilmesi ve bu modeller üzerinden tanıma gerçekleştirilmesine dayalı, model tabanlı bir yaş tahmini yöntemi tasarlanmıştır.

5. ÖNERİLER

1. Yaş tahmininin mevcut veritabanları üzerinden yapılması, veritabanlarının yapısından dolayı zorlaşmaktadır. Bu nedenle her yaştan, benzer görüntüleme koşullarında elde edilmiş, yeterli kalitedeki resimlerden oluşan bir veritabanının oluşturulması gerekmektedir.

2. Çalışmada tasarlanan genel ve yerel özniteliklere dayalı yaş tahmini sistemi, yüzün şekil bilgisini ve doku bilgisini içeren öznitelikleri kullanmaktadır. Uygun veritabanlarının da geliştirilmesi ile birlikte, tasarlanan sistemin geometrik özniteliklerle birleştirilmesi ve böylece daha da güçlü hale getirilmesi mümkün olabilir.

3. Yaş tahmini gerçekleştiren çalışmalar genellikle kişilerin ırkını ve cinsiyetini dikkate almamaktadır. Cinsiyeti dikkate alarak yaş tahmini gerçekleştiren bazı sistemler tasarlanırsa da sayıları oldukça azdır. Demografik sınıflandırma çalışmalarına ağırlık verilerek ırk ve cinsiyete özel yaş tahmini sistemlerinin oluşturulması ve böylece coğrafik koşulların dikkate alınarak yaşın belirlenmesi, daha iyi sonuçlar verebilir.

4. Yaşlanma veritabanlarında yaş dağılımının dengeli olması gerekir. Mevcut veritabanlarından FG-NET'te görüntülerin %48'i çocuk, %23'ü ergen, %22'si genç yetişkin, %6'sı orta yaşlıdır. Bu veritabanında yaşlı sınıftaki resim sayısı sadece 2'dir. MORPH-I veritabanında bu oranlar sırasıyla %0, %20, %70 ve %9'dur. Bu veritabanında da yaşlı sınıfta sadece 1 görüntü bulunmaktadır. Çalışmada kullanılan diğer bir veritabanı olan PAL'da ise çocuk sınıftan görüntü bulunmazken, %5 ergen, %40 genç yetişkin, %15 orta yaşlı ve %38 orta yaşlı görüntü içermektedir. Bu dağılımların daha dengeli bir hale getirilmesi gerekmektedir.

5. Görüntülerdeki yüz ifadeleri, yaş tahmini başarımını etkileyen bir faktördür. Yüz ifadelerine göre alt sınıflar oluşturulup, bu sınıflar içerisinde yaş tahmini gerçekleştirilerek başarımlar artırılabilir.

6. MORPH veritabanındaki yüz görüntülerinde 68 kontrol noktasının belirlenmesi ile, bu veritabanında AAM öznitelikleri çıkarılarak yaş tahmini gerçekleştirilebilir. Diğer yandan yine bu kontrol noktalarının belirlenmesi sonucunda, model tabanlı yaş tahmini yaklaşımı bu veri tabanına da uygulanabilir.

7. Sınıflandırmada kullanılacak yaş gruplarının sınırlarının kesin hatlarla belirlenmesi yerine, bulanık tabanlı üyelik fonksiyonları ile temsil edilmesi başarıyı arttırabilir.

8. Doku analizinde yerel bölgelerden çıkarılan özniteliklere verilen ağırlıklar dinamik olarak belirlenerek daha etkin bir yaş tahmini gerçekleştirilebilir. Diğer yandan farklı öznitelik çıkarma yöntemlerinin birleştirilmesinde sezgisel katsayıların belirlenmesi sağlanabilir.

9. Çalışmada kullanılan veritabanlarında genellikle önden çekilmiş görüntüler bulunmaktadır. Kişilerin çeşitli açılardan çekilmiş görüntülerini kullanarak yaş tahmini gerçekleştiren sistemler tasarlanabilir.

10. Öznitelik uzayında veri dağılımının doğrusal olmaması göz önüne alınarak özellik çıkarmada kernel yaklaşımlar kullanılabilir. Diğer yandan öznitelik vektör boyutlarının küçültülmesi sırasında uygulanan PCA yönteminde Ek Tablo 5'te görüldüğü gibi farklı orandaki öz vektörlerin korunması ile yaş tahmini başarıyı arttırılabilir.

6. KAYNAKLAR

- Aeminov, V., 1989. Panteleev, I. F. ve Selivanov, N., A., Criminalistics, Progress Publishers, Moscow.
- Ahonen, T., Hadid, A. ve Pietikainen, M., 2006. Face Description with Local Binary Patterns: Application to Face Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28, 12, 2037-2041.
- Albert, M., Ricanek, K. ve Patterson, E., 2007. A review of the literature on the aging adult skull and face: implications for forensic science research and applications, Forensic Science International, 172, 1, 1-9.
- Alexa, M., Cohen-Or, D. ve Levin, D., 2000. As-rigid-as-possible shape interpolation, Proceedings of the 27th Annual Conference on Computer Graphics and Interactive Techniques (SIGGRAPH'00), New Orleans, LA, 157-164.
- Al-Shaykh, O.,K. ve Doherty,J.,F., 1996. Invariant Image Analysis Based on Radon Transform and SVD, IEEE Transactions on Circuits and Systems-II: Analog and Digital Signal Processing, 43, 2, 123-133.
- Beier, T. ve Neely, S., 1992. Feature-Based Image Metamorphosis, Proceedings of the 19th Annual Conference on Computer Graphics and Interactive Techniques (SIGGRAPH'92), 26, 35-42.
- Berg, M., Kreveld, M., Overmars, M. ve Schwarzkopf, O., 2000. Computational Geometry, Algorithms and Applications, Second Edition, Springer-Verlag.
- Boulgouris, N., V. ve Chi, Z., X., 2007. Gait recognition using radon transform and linear discriminant analysis, IEEE Transactions on Image Processing, 16, 3, 731-740.
- Cai, D., He, X., Han, J. ve Zhang, H., J., 2006. Orthogonal Laplacianfaces for Face Recognition, IEEE Transactions on Image Processing, 15, 11, 3608-3614.
- Chang, T. ve Kuo, C., -C., J., 1993. Texture analysis and classification with tree-structured wavelet transform, IEEE Transactions on Image Processing, 2, 4, 429-441.
- Chao, W., -L., Liu, J., -Z. ve Ding, J., -J., 2013. Facial age estimation based on label-sensitive learning and age oriented regression, Pattern Recognition, 43, 628-641.
- Chen, C., Yang, W., Wang, Y., Ricanek, K. ve Luu, K., 2011. Facial Feature Fusion and Model Selection for Age Estimation, IEEE International Conference on Automatic Face & Gesture Recognition and Workshops (FG'11), Santa Barbara, CA, 200-205.

- Chen, W., Er, M., J. ve Wu, S., 2006. Illumination compensation and normalization for robust face recognition using discrete cosine transform in logarithm domain, IEEE Transactions on Systems, Man and Cybernetics, Part B: Cybernetics, 36, 458-466.
- Chen, Y., -W., Han, M., -J., Song K., -T. ve Ho, Y., -L., 2010. Image-Based Age-Group Classification Design Using Facial Features, 2010 International Conference on System Science and Engineering (ICSSE'2010), Taipei, 548-552.
- Choi, S., E., Lee, Y., L., Park K., R. ve Kim, J., 2010. A Comparative Study of Local Feature Extraction for Age Estimation, 11th International Conference on Control, Automation, Robotics and Vision, Singapore, 1280-1283.
- Choi, S., E., Lee, Y., J., Lee, S., J., Park, K., R. ve Kim, J., 2011. Age estimation using a hierarchical classifier based on global and local facial features, Pattern Recognition, 44, 1262-1281.
- Cootes, T., Edwards, G. ve Taylor, C., 2001. Active Appearance Models, IEEE Transactions on Pattern Analysis and Machine Intelligence, 23, 6, 681-685.
- Cortes, C. ve Vapnik, V., 1995. Support-vector network, Machine Learning, 20, 3, 273-297.
- Cui, P., Li, J., Pan, Q. ve Zhang, H., 2006. Rotation and scaling invariant texture classification based on radon transform and multi scale analysis, Pattern Recognition Letters, 27, 5, 408-413.
- Dace, M., Human Proportion II.2. http://www.dace.co.uk/proportion_child_2.htm 10 Mayıs 2015.
- Dehshibi, M., M. ve Bastanfard, A., 2010. A new algorithm for age recognition from facial images, Signal Processing, 90, 8, 2431-2444.
- El-Dib, M., Y. ve El-Saban, M., 2010. Human Age Estimation Using Enhanced Bio-inspired Features, IEEE 17th International Conference on Image Processing, Hong Kong, 1589-1592.
- El-Dib, M., Y. ve Onsi, H., M., 2011. Human age estimation framework using different facial parts, Egyptian Informatics Journal, 12, 1, 53-59.
- Erikson, E., 1968. Identity, Youth and Crisis, New York: Norton.
- Fang, H., Grant, P. ve Chen, M., 2010. Discriminant Feature Manifold for Facial Aging Estimation, IEEE 20th International Conference on Pattern Recognition (ICPR'10), İstanbul, 593-596.
- Farkas, L., 1994. Anthropometry of the Head and Face, Raven Press, New York.

- Fu, T. ve Foroosh, H., 2004. Expression Morphing from Distant Viewpoints, International Conference on Image Processing (ICIP'04), 3519-3522.
- Fu, Y., Xu, Y. ve Huang, T., S., 2007. Estimating Human Age by Manifold Analysis of Face Pictures and Regression on Aging Features, Proceedings of IEEE International Conference on Multimedia and Expo, Beijing, 1383-1386.
- Fu, Y. ve Huang, T., S., 2008. Human Age Estimation with Regression on Discriminative Aging Manifold, IEEE Transactions on Multimedia, 10,4, 578-584.
- Fukai, H., Takimoto, H., Mitsukura, Y. ve Fukumi, M., 2007. Apparent Age Estimation System Based on Age Perception, Proceedings of SICE 2007 Annual Conference, Takanatsu, 2808-2812.
- Fukai, H., Takimoto, H., Mitsukura, Y. ve Fukumi, M., 2010. Age and Gender Estimation by Using Facial Image, 2010 11th IEEE International Workshop on Advanced Motion Control, Nagaoka, Niigata, Japan, 179-184.
- Fukunaga, T. ve Hayashi, J., 2011. A Method for Age Estimation based on Co- occurrence Histogram, 2011 17th Korea-Japan Joint Workshop on Frontiers of Computer Vision, Ulsan, 1-5.
- Gao, F. ve Ai, H., 2009. Face Age Classification on Consumer Images with Gabor Feature and Fuzzy LDA Method, Proceedings of 3rd International Conference on Advances in Biometrics, LNCS'5558, Alghero, Italy, 132-141.
- Gashtasby, A., 1986. Piecewise linear mapping functions for image registration, Pattern Recognition, 19, 6, 459-466.
- Geng, X., Zhou, Z., H., Zhang, Y., Li, G. ve Dai, H., 2006. Learning From Facial Aging Patterns for Automatic Age Estimation, Proceedings of 14th ACM International Conference on Multimedia, 307-316.
- Geng, X., Zhou, Z., H. ve Miles, K., S., 2007. Automatic Age Estimation Based on Facial Aging Patterns, IEEE Transactions on Pattern Analysis and Machine Intelligence, 29,12, 2234-2240.
- Geng, X. ve Smith-Miles, K., 2009. Facial Age Estimation by Multilinear Subspace Analysis, IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP'09), Taipei, 865-868.
- Geng, X., Yin, C. ve Zhou, Z.,-H., 2013. Facial Age Estimation by Learning from Label Distributions, IEEE Transactions on Pattern Analysis and Machine Intelligence, 35, 10, 2401-2412.
- Geng, X., Wang, Q. ve Xia, Y., 2014. Facial Age Estimation by Adaptive Label distribution Learning, IEEE 22nd International Conference on Pattern Recognition (ICPR 2014), Stockholm, Sweden, 4465-4470.

- Gonzalez-Ulloa, M. ve Flores, E., S., 1965. Senility of the face-Basic study to understand its causes and effects, Plastics & Reconstructive Surgery, 36, 2, 239-246.
- Guo, G., Fu, Y., Huang, T., S. ve Dyer, C., R., 2008a. Locally Adjusted Robust Regression for Human Age Estimation, IEEE Workshop on Applications of Computer Vision (WACV'08), Copper Mountain, CO, 1-6.
- Guo, G., Fu, Y., Dyer, C., R. ve Huang, T., S., 2008b. Image-Based Human Age Estimation by Manifold Learning and Locally Adjusted Robust Regression, IEEE Transactions on Image Processing, 17,7, 1178-1188.
- Guo, G., Fu, Y., Dyer, C., R. ve Huang, T., S., 2008c. A Probabilistic Fusion Approach to Human Age Prediction, IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPRW'08), Anchorage, AK, 1-6.
- Guo, G., Mu, G., Fu, Y. ve Huang, T., S., 2009a. Human Age Estimation Using Bio-Inspired Features, Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR'09), Miami, FL, 112-119.
- Guo, G., Mu, G., Fu, Y., Dyer, C. ve Huang, T., S., 2009b. A Study on Automatic Age Estimation Using a Large Database, Proceedings of IEEE 12th International Conference on Computer Vision, Kyoto, 1986-1991.
- Guo, G. ve Mu, G., 2014. A framework for joint estimation of age, gender and ethnicity on a large database, Image and Vision Computing, 32, 761-770.
- Guo, J. ,-M., Liou, Y., -M. ve Nguyen, H., -S., 2011. Human Face Age Estimation with Adaptive Hybrid Features, 2011 International Conference on System Science and Engineering, Macua, China, 55-58.
- Günay, A. ve NabiyeV, V., V., 2008. Automatic age classification with LBP, 23rd International Symposium on Computer and Information Sciences (ISCIS'08), İstanbul, 1-4.
- Günay, A. ve NabiyeV, V., V., 2009. Morphing faces for age estimation, Proceedings of International Symposium on Innovations in Intelligent Systems and Applications (INISTA'09), Trabzon, 80-84.
- Günay, A. ve NabiyeV, V., V., 2012. Age Estimation Based on Local Radon Features of Facial Images, Computer and Information Sciences III: 27th International Symposium on Computer and Information Sciences, Springer, 183-190.
- Günay, A. ve NabiyeV, V., V., 2015. Age Estimation Based on AAM and 2D-DCT Features of Facial Images, International Journal of Advanced Computer Science and Applications, 6, 2, 113-119.

- Hadid, A., Pietikainen, M. ve Ahonen, T., 2004. A Discriminative Feature Space for Detecting and Recognizing Faces, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR'04), 2, Washington D.C., 797-804.
- Hajizadeh, M., A. ve Ebrahimnezhad, H., 2011. Classification of Age Groups from Facial Image Using Histograms of Oriented Gradients, 2011 7th Iranian Machine Vision and Image Processing, Tehran, 1-5.
- Han, H., Otto, C., Liu, X. ve Jain, A., K., 2014. Demographic Estimation from Face Images: Human vs. Machine Performance, IEEE Transactions on Pattern Analysis and Machine Intelligence, doi: 10.1109/TPAMI.2014.2362759.
- Hayashi, H., Yasumoto, M., Ito, H., Niwa, Y. ve Koshimizu, H., 2002. Age and Gender Estimation from Facial Image Processing, Proceedings of 41st SICE Annual Conference, Osaka, 1:13-18.
- He, L., Zou, C., Zhao, L. ve Hu, D., 2006. An Enhanced LBP Feature Based on Facial Expression Recognition, 27th Annual Conference of the Engineering in Medicine and Biology Society (IEEE-EMBS'05), Shanghai, 3300-3303.
- He, X., Yan, S., Hu, Y. ve Niyogi, P., 2005. Face Recognition Using Laplacianfaces, IEEE Transactions on Pattern Analysis and Machine Intelligence, 27,3, 328-340.
- Higashi, A., Yasui, Y., Fukumizu, Y. ve Yamauchi, H., 2011. Local Gabor Directional Pattern Histogram Sequence (LGDPHS) for Age and Gender Classification, 2011 IEEE Statistical Signal Processing Workshop, Nice, 505-508.
- Hjelmas, E. ve Low, B., K., 2001. Face Detection: A Survey, Computer Vision and Image Understanding, 88, 3, 236-274.
- Hornig, W.,-B., Lee, C.,-P. ve Chen, C.,-W., Classification of Age Groups Based on Facial Features, Tamkang Journal of Science and Engineering, 4, 3 (2001) 183-192.
- Iga, R., Izumi, K., Hayashi, H., Fukano, G. ve Ohtani, T., A., 2003. A Gender and Age Estimation System from Face Images, SICE 2003 Annual Conference in Fukui, Fukui University, Japan, 756-761.
- Izadpanahi, S. ve Toygar, Ö., 2012. Geometric Feature Based Age Classification Using Facial Images, IET Conference on Image Processing (IPR 2012), London, 1-5.
- Jadhav, D., V. ve Holambe, R., S., 2010. Rotation, illumination invariant polynomial kernel Fisher discriminant analysis using Radon and discrete cosine transforms based features for face recognition, Pattern Recognition Letters, 31, 1002-1009.
- Jeon, J., H., Lee, J.,Y., Bae, J., S. ve Kim, J., O., 2014. Gradient Local binary Patterns for Age Group Estimation, 18th IEEE International Symposium on Consumer Electronics (ISCE 2014), JeJu Island, 1-2.

- Jobson, J., D., 1991. Multiple Linear Regression, Applied Multivariate Data Analysis, Springer Text in Statistics, 219-398.
- Ju, C., H. ve Wang, Y., H., 2009. Automatic Age Estimation Based on Local Feature of Face Image and Regression, 2009 International Conference on Machine Learning and Cybernetics, Baoding, 885-888.
- Kalansuriya, T., R. ve Dharmaratne, A., T., 2013. Facial Image Classification Based on Age and Gender, 2013 International Conference on Advances in ICT for Emerging Regions (ICTer), Colombo, 44-50.
- Karungaru, S., Fukumi, M. ve Akamatsu, N., 2004. Morphing Human Faces: Automatic Control Points Selection and Color Transition, Transactions on Engineering, Computing and Technology, 1, 224-227.
- Kass, M., Witkin, A. ve Terzopoulos, D., 1988. Snakes: Active Contour Models, International Journal of Computer Vision, 321-331.
- Kim, M., Kumar, S., Pavlovic, V. ve Rowley, H., 2008. Face Tracking and Recognition with Constraints in Real-World Videos, IEEE Conference on Computer Vision and Pattern Recognition, CVPR'2008, Anchorage, AK, 1-8.
- Kohli, S., Prakash, S. ve Gupta, P., 2013. Hierarchical age estimation with dissimilarity-based classification, Neurocomputing, 120, 164-176.
- Kwon, Y., H. ve Lobo, N., V., 1999. Age Classification from Facial Images, Computer Vision and Image Understanding, 74,1, 1-21.
- Lanitis, A., Taylor, C. ve Cootes, T., 2002. Toward Automatic Simulation of Aging Effects on Face Images, IEEE Transactions on Pattern Analysis and Machine Intelligence, 24, 4, 442-455.
- Lanitis, A., Draganova, C. ve Christodoulou, C., 2004. Comparing Different Classifiers for Automatic Age Estimation, IEEE Transactions on System, Man and Cybernetics, 34, 1, 621-628.
- Li, C., Liu, Q., Dong, W., Zhu, X., Liu, J. ve Lu, H., 2014. Human Age Estimation Based on Locality and Ordinal Information, IEEE Transactions on Cybernetics, doi: 10.1109/TCYB.2014.2376517.
- Li, W., Wang, Y. ve Zhang, Z., 2012. A Hierarchical Framework for Image-based Human Age Estimation by Weighted and OHRanked Sparse Representation-based Classification, 5th IAPR International Conference on Biometrics (ICB 2012), New Delhi, 19-25.
- Lian, H., C. ve Lu, B., L., 2006. Multi-view Gender Classification Using Local Binary Patterns and Support Vector Machines, LNCS 3972, 202-209.

- Liang, Y., Liu, L., Xu, Y., Xiang, Y. ve Zou, B., 2011. Multi-Task GLOH Feature Selection for Human Age Estimation, 18th IEEE International Conference on Image Processing (ICIP'2011), Brussels, 546-568.
- Liang, Y., Wang, X., Zhang, L. ve Wang, Z., 2013. A Hierarchical System for Age Estimation based on Appearance Feature and Ranking-KNN, 2013 4th International Conference on Intelligent Systems Design and Engineering Applications, Zhangjiajie, 1-4.
- Liu, K., -H., Yan, S. ve Kuo, C.,-C., J., 2014. Age Group Classification via Structured Fusion of Uncertainty-driven Shape Features and Selected Surface Features, IEEE Winter Conference on Applications of Computer Vision (WACV 2014), Steamboat Springs, CO, 445-452.
- Liu, L., Liu, J. ve Cheng, J., 2012. Age-Group Classification of Facial Images, 11th International Conference on Machine Learning and Applications (ICMLA'12), Boca Raton, FL, 693-696.
- Long, Y., 2009. Human Age Estimation by Metric Learning for Regression Problems, IEEE 2009 6th International Conference on Computer Graphics, Imaging and Visualization, Tianjin, 343-348.
- Lu, J. ve Tan, Y., P., 2010. Ordinary Preserving Manifold Analysis for Human Age Estimation, 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, San Francisco, CA, 90-95.
- Lu, J. ve Tan, Y., - P., 2011. Fusing Shape and Texture Information for Facial Age Estimation, IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP'11), Prague, 1477-1480.
- Lu, J. ve Tan, Y., P., 2013. Ordinary Preserving Manifold Analysis for Human Age and Head Pose Estimation, IEEE Transactions on Human Machine Systems, 43, 2, 249-258.
- Luo, R., C., Chang, L. ve Chou, S., C., 2013. Human Age Classification Using Appearance Images for Human-Robot Interaction, 39th Annual Conference of the IEEE Industrial Electronics Society (IECON 2013), Vienna, 2426-2431.
- Luu, K., Ricanek Jr., K., Bui, T., D. ve Suen, C., Y., 2009. Age Estimation using Active Appearance Models and Support Vector Machine Regression, IEEE 3rd International Conference on Biometrics: Theory, Applications and Systems, Washington, DC, 1-5.
- Luu, K., Bui, T., D. ve Suen, C., Y., 2011a. Kernel Spectral Regression of Perceived Age from Hybrid Facial Features, 2011 IEEE International Conference on Automatic Face & Gesture Recognition and Workshop, Santa Barbara, CA, 1-6.

- Luu, K., Seshadri, K., Savvides, M., Bui, T., D. ve Suen, C., Y., 2011b. Contourlet Appearance Model for Facial Age Estimation, 2011 International Joint Conference on Biometrics Compendium, Washington, DC, 1-8.
- Ma, B., Shan, S., Chen, X. ve Gao, W., 2008. Discriminant Analysis for Perceptually Comparable Classes, 8th IEEE International Conference on Automatic Face and Gesture Recognition, Amsterdam, 1-6.
- Ma, Y., Liu, J., Yang, Y. ve Zheng, N., 2015. Double layer multiple task learning for age estimation with insufficient training samples, Neurocomputing, 147, 380-386.
- Makinen, E. ve Raisamo, R., 2008. Evaluation of Gender Classification Methods with Automatically Detected and Aligned Faces, IEEE Transactions on Pattern Analysis and Machine Intelligence, 30, 3, 541-547.
- Miller, C., D., Heeren, V., E. ve Hornsby, J., E., 2011. Mathematical Ideas, 12th Edition, Addison Wesley.
- Minear, M. ve Park, D., C., 2004. A lifespan database of adult stimuli, Behavior Research Methods, Instruments and Computers, 36,4, 630-633.
- Mokadem, A., Charbit, M., Chollet, G. ve Bailly, K., 2010. Age Regression based on Local Image Features, 2010 Fourth Pacific-Rim Symposium on Image and Video Technology, Singapore, 88-93.
- Nabiyev, V., V. ve Günay, A., 2011. LBP Yardımıyla Görüntüdeki Kişinin Yaşının Bulunması, Çankaya University Journal of Science and Engineering, 8, 1, 27-41.
- Ni, B., Song, Z. ve Yan, S., 2009. Web Image Mining Towards Universal Age Estimator, Proceedings of 17th ACM International Conference on Multimedia, Beijing, 85-94.
- Ni, B., Song, Z. ve Yan, S., 2011. Web Image and Video Mining Towards Universal and Robust Age Estimator, IEEE Transactions on Multimedia, 34, 6, 1217-1228.
- Nithyashri, J. ve Kulanthaivel, G., 2012. Classification of Human Age based on Neural Network Using FG-NET Aging Database and Wavelets, IEEE 4th International Conference on Advanced Computing (ICoAC 2012), Chennai, 1-5.
- Nguyen, D., T., Cho, S., R., Shin, K., Y., Bang, J., W. ve Park, K., R., 2014. Comparative Study of Human Age Estimation with or without Preclassification of Gender and Facial Expression, The Scientific World Journal.
- Nöllenburg, M., Merrick, D., Wolff, A. ve Benkert, M., 2008. Morphing polylines: A step towards continuous generalization, Computers, Environment and Urban Systems, 32, 248-260.

- Ojala, T., Pietikäinen, M. ve Maenpää, T., 2002. Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns, IEEE Transactions on Pattern Analysis and Machine Intelligence, 24,7, 971-987.
- Pang, Y., W., Zhang, L., Liu, Z., K., Yu, N., H. ve Li, H., Q., 2005. Neighborhood Preserving Projections (NPP): A Novel Linear Dimension Reduction Method, International Conference on Intelligent Computing, Hefei, China, 117-125.
- Parramon, J., M., 2000. Baş ve Portre Çizme Sanatı, çev. Erol Erduran, Remzi Kitabevi, İstanbul, Temmuz.
- Pennebaker, W. ve Mitchell, J., 1992. JPEG: Still image data compression standard, Kluwer Academic Publishers, Norwell, MA.
- Quanjer, P., H., Become an Expert in Spirometry. <http://www.spirxpert.com/refvalueschild3.htm> 10 Mayıs 2015.
- Radon, J., 1983. The Radon Transform and Some of Its Applications, Wiley.
- Rao, K. ve Yip, P., 1990. Discrete cosine transform, Algorithms, Advantages, Applications, Academic Press, Boston, MA.
- Ricanek Jr, K. ve Tesafaye, T., 2006. MORPH: A Longitudinal Image Database of Normal Adult Age-Progression, IEEE 7th International Conference on Automatic Face and Gesture Recognition, Southampton, UK, 341-345.
- Sai, P., K., Wang, J., G. ve Teoh, E., K., 2015. Facial age range estimation with extreme learning machines, Neurocomputing, 149, 364-372.
- Shan, C., Gong, S. ve McOwen, P., W., 2009. Facial expression recognition based on Local Binary Patterns: A comprehensive study, Image and Vision Computing, 27, 6, 803-816.
- Shen, L. ve Bai, L., 2006. A review on Gabor wavelets for face recognition, Pattern Analysis and Applications, 9, 2-3, 273-292.
- Shen, L., L. ve Ji, Z., 2008. Modelling Geometric Features for Face Based Age Classification, 7th International Conference on Machine Learning and Cybernetics, Kunming, 2927-2931.
- Shih, F., Y. ve Chuang, C., 2004. Automatic Extraction of Head and Face Boundaries and Facial Features, Information Sciences, 158, 117-130
- Suo, J., Min, F., Zhu, S., Shan, S. ve Chen, X., 2007. A Multi-Resolution Dynamic Model for Face Aging Simulation, Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR'07), Minneapolis, MN, 1-8.

- Suo, J., Wu, T., Zhu, S., Shan, S., Chen, X. ve Gao, W., 2008. Design Sparse Features for Age Estimation Using Hierarchical Face Model, Proceedings of 8th IEEE International Conference on Automatic Face & Gesture Recognition (FG'08), Amsterdam, 1-6.
- Suo, J., Zhu, S., C., Shan, S. ve Chen, X., 2010. A Compositional and Dynamic Model for Face Aging, IEEE Transactions on Pattern Analysis and Math. Intelligence, 32, 3, 385-401.
- Tharwat, A., Ghanem, A., M. ve Hassanien, A., E., 2013. Three different classifiers for facial age estimation based on K-nearest neighbor, 2013 9th International Computer Engineering Conference (ICENCO 2013), Giza, 55-60.
- Tonchev, K., Paliy, I., Boumbarov, O. ve Sokolov, S., 2011. Human Age-Group Classification of Facial Images with Subspace Projection and Support Vector Machines, IEEE 6th International Conference On Intelligent Data Acquisition and Advanced Computing Systems, Prague, 439-443.
- Turk, M., A. ve Pentland, A., P., 1991. Face recognition using eigenfaces, IEEE Computer Science Conference on Computer Vision and Pattern Recognition (CVPR'91), Maui, HI, 586-591.
- Txia, J., -D. ve Huang, C., -L., 2009. Age Estimation using AAM and Local Facial Features, IEEE 5th International Conference on Intelligent Information Hiding and Multimedia Signal Processing, Kyoto, 885-888.
- Ueki, K., Hayashida, T. ve Kobayashi, T., 2006. Subspace-based Age-group Classification Using Facial Images under Various Lighting Conditions, Proceedings of the 7th International Conference on Automatic Face and Gesture Recognition (FGR'06), Southampton, 43-48.
- Ueki, K., Miya, M., Ogawa, T. ve Kobayashi, T., 2008. Class Distance Weighted Locality Preserving Projection for Automatic Age Estimation, 2nd IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS 2008), Arlington, VA, 1-5.
- URL-1, FG-NET Aging Database, <http://sting.cycollege.ac.cy/~alanitis/fgnetaging/>, 22 Mayıs 2006.
- Valinskiy, A., F., 1999. Kriminoloji, Yur nauki, Russia.
- Wang, C., Su, Y., Hsu, C., Lin, C. ve Liao, H., Y., 2009a. Bayesian Age Estimation on Face Images, IEEE International Conference on Multimedia and Expo (ICME'09), New York, NY, 282-285.
- Wang, J., G., Yau, W., Y. ve Wang, H., L., 2009b. Age Categorization via ECOC with Fused Gabor and LBP Features, Proceedings of the IEEE Workshop on Applications of Computer Vision (WACV), Snowbird, UT, 313-318.

- Weixing, L., Haijun, S., Feng, P., Qi, G. ve Shaoyan, G., 2014. Facial Age Classification Based on Weighted Decision Fusion, Proceedings of the 33rd Chinese Control Conference, Nanjing, China, 4870-4874.
- Wu, J., -D. ve Ye, S., -H., 2009. Driver identification using finger-vein patterns with radon transform and neural networks, Expert Systems with Applications, 36, 3, 5793-5799.
- Wu, T., Turaga, P. ve Chellappa, R., 2012. Age Estimation and Face Verification Across Aging Using Landmarks, IEEE Transactions on Information Forensics and Security, 7, 6, 1780-1788.
- Xiao, B., Yang, X. ve Xu, Y., 2009. Learning Distance Metric for Regression by Semi-definite Programming with Application to Human Age Estimation, Proceedings of 17th ACM International Conference on Multimedia, Beijing, 451-460.
- Yan, S., Wang, H., Tang, X. ve Huang, T., S., 2007a. Learning Auto-Structured Regressor from Uncertain Nonnegative Labels, IEEE 11th International Conference on Computer Vision (ICCV 2007), Rio de Janeiro, 1-8.
- Yan, S., Wang, H., Huang, T., S., Yang, Q. ve Tang, X., 2007b. Ranking with Uncertain Labels, Proceedings of IEEE International Conference on Multimedia and Expo, Beijing, 96-99.
- Yan, S., Liu, M. ve Huang, T., S., 2008a. Extracting Age Information from Local Spatially Flexible Patches, Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP'08), Las Vegas, NV, 737-740.
- Yan, S., Zhou, X., Liu, M., H.-Johnson, M. ve Huang, T., S., 2008b. Regression from Patch Kernel, IEEE Conference on Computer Vision and Pattern Recognition (CVPR'08), Anchorage, AK, 1-8.
- Yan, S., Wang, H., Fu, Y., Yan, J., Tang, X. ve Huang, T., S., 2009. Synchronized Submanifold Embedding for Person- Independent Pose Estimation and Beyond, IEEE Transactions on Image Processing, 18, 1, 202-210.
- Yang, P., Zhong, L. ve Metaxas, D., 2010. Ranking Model for Age Estimation, 2010 20th International Conference on Pattern Recognition (ICPR2010), İstanbul, 3404-3407.
- Yang, Z. ve Ai, H., 2007. Demographic Classification with Local Binary Patterns, Proceedings of International Conference on Advances in Biometrics, LNCS'4642, Seoul, Korea, 464-473.
- Yannick, L., L., Djamel, M., Sebastian, P. ve Bernard, F., 2013. Combining regression and classification methods for age band estimation from human faces, 8th International Symposium on Image and Signal Processing and Analysis (ISPA 2013), Trieste, Italy, 136-141.

- Ylioinas, J., Hadid, A. ve Pietikainen, M., 2012. Age Classification in Unconstrained Conditions Using LBP Variants, 21st International Conference on Pattern Recognition (ICPR 2012), Tsukuba, Japan, 1257-1260.
- Zhan, C., Li, W. ve Ogunbona, P., 2011. Age Estimation Based on Extended Non-negative Matrix Factorization, IEEE 13th International Workshop on Multimedia and Signal Processing (WMSP 2011), Hangzhou, 1-6.
- Zhou, H., Miller, P. ve Zhang, J., 2011. Age classification using Radon transform and entropy based scaling SVM, Proceedings of the 22nd British Machine Vision Conference, Dundee, UK, 28.1-28.12.
- Zhuang, X., Zhou, X., H.-Johnson, M. ve Huang, T., 2008. Face Age Estimation Using Patch-based Hidden Markov Model Supervectors, IEEE International Conference on Pattern Recognition (ICPR'08), Tampa, FL, 1-4.

7. EKLER

Ek-1. Dişlerin Durumuna Göre Yaş Tahmini

Yaşın belirlenmesinde kişinin çeşitli özelliklerinden faydalanılmaktadır. Bunlardan biri olan diş bilgisi, özellikle bebeklik ve çocukluk dilimlerinin belirlenmesine yardımcı olmaktadır. Bebeğin 6-8. aylarında alt çenedeki orta kesici dişleri, 8-9. aylarında üst çenedeki orta kesici dişleri, 9-11. Aylarında üste çene yan kesici dişleri, 10-12. aylarında ise alt çene yan kesici dişleri çıkmaktadır. Çocuğun 2-3 yaşlarında 20 adet süt dişinin oluşumu tamamlanmaktadır. 6-7 yaşlarında ise süt dişlerinin daimi dişlerle değişim süreci başlamaktadır. Bu süreç 13 yaşta tamamlanmakta ve sağlıklı bir çocuğun ağızda 28 adet diş bulunmaktadır. 20 yaş dişi olarak adlandırılan dişlerin oluşma süreci 18-25 yaş aralığı olsa da, çoğunlukla bu dişlerin daha geç oluştuğu görülmektedir.

Dişlerde meydana gelen sürtünme izleri genellikle 20 yaşından sonra ortaya çıkmakta ve yaş ilerledikçe de bu izler derinleşmektedir. Dişlerde ilk olarak mine, daha sonra dentin kısmı bozulmaya başlamaktadır. Aşağıdaki tabloda M.M. Gerasimov'a göre yaşa ilişkin olarak dişlerin sürtünme dereceleri verilmiştir.

Ek Tablo 1. Dişlerin yaşa göre sürtünme dereceleri (0-bozulma yok, 1-mine dış tabakasında bozulma var, 2-mine iç tabakasında bozulma var, 3- dentin kısmında bozulma var, 4-diş kanalı tahrip olmuş, 5-diş tacı bozulmuş, 6-diş tacı tümüyle tahrip olmuş)


Yaş	Kesici dişler	Köpek dişleri	Küçük azı dişleri	1. büyük azı dişleri	2. büyük azı dişleri
10-13	0	0	0	0	0
13-14	0-1	0	0	0	0
14-16	1	0	1	0	0
16-18	1-2	1	1	1	0
18-20	2-3	2	2	2	1
20-25	2-3	2	2	2	2
25-30	3	2	2-3	2-3	2
30-35	3	2-3	2-3	3	2-3
35-40	3	3	3	3-4	3
40-50	3-4	3-4	3-4	4	3-4
50-60	4-5	4	4	5	4-5
60-70	5-6	5	5-6	5-6	6

Ek-2. İnsan Vücudunun ve Yüzünün Geometrik Yapısı

Ek-2.1. Kanon Değerleri ve Antropometri

İnsan mükemmel bir yapıya sahiptir. İnsan bedeninde Kanon olarak adlandırılan ve değişmeyen belirli oranlar ve sabitler vardır. Kanon tanım olarak, bir ölçü biriminden yararlanarak insan vücudunun oran ve boyutlarını saptayan bir ölçme sistemidir (Parramon, 2000). Örneğin Alman sanatçı Albrecht Dürer insan vücudunun orantılarını ve ideal boyu sekiz başlık ölçü üzerine kurmuştur. Yunanlı heykeltıraş Doryphoros ise kusursuz orantılara sahip bir insanın boyunun, başının yedi buçuk katı olduğunu açıklamıştır.

Tanıma sistemlerinde bahsi geçen ölçülerden özellikle kesimleme aşamasında faydalanılır. İnsanlardaki bu ortak yapıya rağmen insanlar birbirinden farklı özelliklere sahiptir. Tanıma sistemleri bu farklılıkları ortaya çıkarmaya çalışmaktadır. Ek Şekil 1’de insan bedeninin, çeşitli yaşlardaki oransal gelişim değerleri verilmiştir (Quanjer, 2015).



Ek Şekil 1. İnsan bedeni kanonu

Bir tanıma sisteminde kesimleme işlemi sırasında ortak özellikler kullanılmasına rağmen tanıma aşamasında ayırt edici özelliklere bakılır. 1879 yılında Fransız polisi tarafından suçluların tespitinde kullanılan bu yöntem Antropometri olarak adlandırılmış ve insan vücudunun veya bir bölümünün ölçülerini ve orantılarını incelemek olarak tanımlanmıştır (Parramon, 2000). Morfoloji ve anatomiye tamamlayan bir bilim dalı olan antropometri ırk, cinsiyet ve yaş açısından binlerce vücudun incelenmesi ile ortaya çıkmıştır. Örneğin Von Lange adlı bir bilim adamı bir milyona yakın insanın boyunu

Ek-2'nin devamı,

ölçmüş ve ortalama olarak 300.000'inin boyunun 165 cm olduğunu, 400.000'inin boyunun 175 cm olduğunu, geri kalanın boyunun ise 175 cm üstünde olduğunu bulmuştur. Lange aynı zamanda 21.5 cm ile 24 cm arasında değişen baş yüksekliğinin tüm vücut ölçüleri içinde en az değişen ölçü olduğunu kanıtlamış ve baş yüksekliğini 22,5cm olarak kabul etmiştir.

Ek-2.2. Çocuk Bedeni

Çocuklarda ve yetişkinlerde genel olarak geçerli bir oran vardır. Bu oran gövdenin tüm beden içinde 3/8'lik yer kapladığıdır. Ancak yeni doğan bir bebekte kafanın bedene oranı yetişkinlerdekine göre oldukça farklıdır.

Yetişkinlerde geçerli olan orana göre, 3/8 oranında gövde ile 1/8 oranında kafa bedeninin yarısını oluşturmaktadır. Geriye kalan kısım ise bacaklardır. Bebeklerde ise kafa ile gövdenin birlikte yüksekliği tüm bedeninin 5/8'ini oluşturmaktadır. Geriye bacaklar için 3/8'lik oran kalmaktadır. Bu oranlardan faydalanılarak yaşa göre oranı veren formül $H = 2a/9 + 4$ şeklinde düzenlenmiştir (Dace, 2015). Denklemden H , beden yüksekliğinin kafa yüksekliğine oranını, a ise yaşı ifade etmektedir.

Ek-2.3. Yüz Oranları

Beden oranlarında olduğu gibi insan yüzünde de genel olarak doğruluğu kabul edilmiş belirli oranlar vardır. İnsandan insana oranları en az değişen bölüm yüz olduğu için yüz tanıma sistemleri bu oranlardan faydalanarak yüz parçalarını bulabilir. Örneğin Shih ve Chuang (2004) çalışmalarında iki göz arasındaki mesafeyi D ile ifade ederek aşağıdaki oranlardan faydalanmaktadır.

- 1) Gözlerle ağız merkezi arasındaki mesafe D 'dir.
- 2) Gözlerle burun delikleri arasındaki mesafe $0.6D$ 'dir
- 3) Ağız genişliği D 'dir
- 4) Burun genişliği $0.8D$ 'dir
- 5) Gözlerle kaşlar arasındaki mesafe $0.4D$ 'dir.

Ek-2'nin devamı,

6) Yüz elipsinin merkezi gözbebeklerinin arasındaki noktadan 0.4D aşağıda olup eksenler sırasıyla 3D ve 2D uzunluğundadır.

Fakat çocuklar ve yetişkinler vücutlarının fiziksel orantıları açısından birbirlerinden çok farklıdır.

- Çocuğun başı bedeniyle karşılaştırıldığında ve kafatası yüzüyle karşılaştırıldığında daha büyüktür.
- Çocuğun gözleri yetişkinlerdeki gibi oval olmayıp çembere benzemektedir ve daha büyüktür. Gözleri arasındaki mesafe de daha fazladır. Diğer yandan çocuğun gözleri yüz yüksekliğinin altında kalır. Yetişkinlerde gözler tam ortadadır.
- Burun küçük ve yukarı kalkıktır.
- Çene kemikleri gelişmediğinden kıvrık görünür.
- Alınları açık ve yüksek olup kenarlarında belirgin saç çizgisi vardır.
- Kaşlar başın tam ortasındadır.
- Kulaklar daha aşağıdadır ve yüze oranla daha büyüktür.

Yukarıda verilen özellikler en çok iki yaşındaki bir çocuğa aittir. Çocuk altı yaşına geldiğinde aşağıdaki değişimler meydana gelir. Altı yaşındaki çocuk için, iki yaşındaki çocuğun kanonu kullanılabilir. Fakat yüz hatları belirli ölçüde değişmiştir.

- Saçlar daha fazla olup alın ve şakaklarda artar
- Çene kemiği daha gelişmiştir. Dolayısıyla yüz biraz daha uzamıştır.
- Gözler ve kaşlar daha yukarıdadır, kaşlar daha kalındır.
- Burun, ağız ve kulaklar daha yukarıdadır,
- Çene kemiği kavisli biçimini hala korumaktadır.

On iki yaşında baş, yetişkin başının biçimine çok daha yaklaşıyor ve yetişkinler için kullanılan kanon biraz hata payıyla kullanılabilir.

- Saç hala çoktur fakat şakaklardaki artım henüz belirginleşmemiştir.
- Gözler ve kaşlar hala tam ortaya yükselmemiştir.
- Kulaklar tam olarak gelişmiştir fakat hala yetişkinlerde olduğundan daha aşağıdadır.
- Alt çene kemik yapısı belirginleşir, çene kemiği daha az kavislidir.

Ek-2'nin devamı,

Yirmi beş yaşına gelindiğinde ise aşağıdaki özellikler gözlenecektir.

- Gözler daha oval ve birbirine daha yakındır.
- Burun, elmacık kemikleri ve çene kemiği daha belirgin ve çocuktakinden daha köşeli bir biçimdedir.

Yaşlılık döneminde yağ azalır ve deri kırıştığı için yüzün biçimi tamamıyla kemik yapısı tarafından belirlenir. Bu nedenle genel görünümde aşağıdaki değişimler oluşur.

- Saçlar azalır, kemik ortaya çıkmaya başlar, alın görülür.
- Şakaklardaki kemik yapısı belirginleşir, damarlar görülür.
- Göz çukuru ve genel olarak gözün kendisi daha çok çöker, göz çukurundaki kemikler dışarı çıkar.
- Gözlerin çevresinde torbalar ve kırışıklıklar oluşur.
- Yanaklar sarktıkça elmacık kemikleri ortaya çıkar
- Burun kemikleri belirginleşir.
- Dudaklar incelir
- Çenede ve boyunda torbacıklar ve deri sarkmaları ortaya çıkar.

Ek-3. Öznitelik Çıkarma Yöntemleriyle Yaş Grupları Altında Elde Edilen Yaş Tahmini Sonuçları

Bu ek bölümde çeşitli öznitelik çıkarma yöntemleriyle yaş grupları için elde edilen yaş tahmini başarımları ve bunların ağırlıklı ortalamaları verilmiştir. FG-NET, MORPH-I ve PAL veritabanlarına ilişkin sonuçlar aşağıdaki tablolarda görülmektedir.

Ek Tablo 2. FG-NET veritabanında yaş grupları için AAM, LBP ve Gabor özniteliklerinin yaş tahmini başarımları (MAE)

Gruplar	AAM	LBP	Gabor	AAM+LBP	AAM+Gabor	AAM+LBP+Gabor
0-12	2.13	2.21	2.04	1.80	1.80	1.72
13-19	1.81	1.70	1.62	1.63	1.55	1.55
20-39	4.51	5.09	4.49	4.21	4.11	4.10
40-64	5.43	4.85	4.59	4.80	4.73	4.58
Ortalama	2.81	2.91	2.66	2.49	2.45	2.40

Ek Tablo 3. MORPH-I veritabanında yaş grupları için LBP ve Gabor özniteliklerinin yaş tahmini başarımları (MAE)

Gruplar	LBP	Gabor	LBP+Gabor
13-19	1.01	1.05	0.98
20-39	4.43	4.07	3.74
40-64	3.93	3.78	3.64
Ortalama	3.68	3.43	3.17

Ek Tablo 4. PAL veritabanında yaş grupları için AAM, LBP ve Gabor özniteliklerinin yaş tahmini başarımları (MAE)

Gruplar	AAM	LBP	Gabor	AAM+LBP	AAM+Gabor	AAM+LBP+Gabor
13-19	0.54	0.52	0.59	0.49	0.54	0.52
20-39	3.98	3.38	3.69	3.43	3.51	3.33
40-64	6.29	6.22	5.51	5.96	5.67	5.71
65-93	4.7	5.05	4.95	4.62	4.53	4.55
Ortalama	4.42	4.3	4.28	4.12	4.07	4.01

Ek-4. Farklı Boyutlardaki Özniteliklerin Yaş Tahmini Sonuçları

Çalışmada LBP ve Gabor özniteliklerinin boyutlarının küçültülmesi sırasında uygulanan PCA yönteminde farklı oranlardaki öz vektörlerin korunması sağlanarak yaş tahmini başarımındaki değişim de incelenmiştir. Ek Tablo 5'te PCA'nın %85, %90, %95 ve %99 olarak uygulanması sonucu elde edilen yaş tahmini başarımları ve parantez içinde bu oranlardaki öznitelik sayıları verilmiştir. Sonuçlar farklı oranlar için farklı özniteliklerin daha başarılı olduğunu göstermektedir.

Ek Tablo 5. Farklı boyutlardaki LBP ve Gabor özniteliklerinin, FG-NET, MORPH-I ve PAL veritabanlarındaki yaş tahmini başarımları (MAE)

Veritabanı	Öznitelik	PCA(85%)	PCA(90%)	PCA(95%)	PCA(99%)
FG-NET	LBP	6,31 (276)	6,34 (373)	6,52 (536)	7,02 (816)
	Gabor	6,14 (292)	6,12 (393)	6,19 (556)	6,55 (827)
MORPH-I	LBP	5,01 (336)	5,07 (451)	5,31 (641)	5,65 (955)
	Gabor	4,74 (319)	4,73 (430)	4,92 (614)	5,35 (937)
PAL	LBP	7,65 (190)	7,62 (235)	7,64 (295)	7,80 (363)
	Gabor	7,33 (172)	7,33 (216)	7,19 (277)	7,37 (355)

ÖZGEÇMİŞ

Asuman GÜNAY; 1979 yılında Trabzon'da doğdu. İlköğrenimini 1989 yılında Trabzon Mimar Sinan İlkokulu'nda, orta ve lise öğrenimini sırasıyla 1993 ve 1996 yıllarında Trabzon Kanuni Anadolu Lisesi'nde tamamladı. 1996 yılında üniversite sınavı ile yerleştirildiği Karadeniz Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü'nü 2000 yılında bölüm birinciliği ile bitirdi. Aynı yıl Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı'nda başladığı yüksek lisansını 2003 yılında tamamladı. 2009 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı'nda doktora çalışmalarına başladı. 2004 yılında Öğretim Görevlisi olarak atandığı Karadeniz Teknik Üniversitesi, Trabzon Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü'nde, 25.09.2009-25.09.2012 tarihleri arasında bölüm başkanlığı görevini yürüttü ve halen bu bölümde çalışmaya devam etmektedir. Yabancı dil olarak İngilizce bilmektedir.