

Yüz Bölgelerinin Yaş Tahmini Başarımlarının Yaş Gruplarına Göre Değerlendirilmesi

Determining the Age Estimation Accuracies of Facial Regions Under Age Groups

Asuman Günay, Vasif V. Nabiye
Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
{gunaya, vasif}@ktu.edu.tr

Öz

Yaşlanma insanın yüz görünümünde büyük değişimlere neden olmaktadır. Yüzdeki yaşlanma etkileri kişiden kişiye farklılık göstermekte ve pek çok faktörden etkilenmektedir. Bu nedenle yüzün farklı bölgelerinde bulunan yaşlanma etkilerinin belirlenmesi otomatik yaş tahmini sistemlerinin tasarımında önem taşımaktadır. Diğer yandan farklı yaş gruplarında yüz bölgelerindeki yaşlanma etkileri farklılık gösterebilir. Çalışmada Erik Erikson'un gelişim teorisine göre belirlenen yaş grupları için, yüzün çeşitli bölgelerinden (göz, burun, yanak, ağız-çene, ağız kenarı) 3 farklı histogram tabanlı doku tanımlayıcısı ile (Yerel İkili Örüntüler, Yerel Faz Kuantalama, Weber Yerel Tanımlayıcısı) öznelikler çıkarılmıştır. Öznelik vektörlerinin boyutu küçültüldükten sonra çoklu lineer regresyon ile yaş tahmini yapılmıştır. FGNET ve PAL veri tabanlarında yapılan deneylerde farklı yaş gruplarında değişik bölgelerin daha etkin olduğu görülmüştür.

Anahtar Kelimeler: Yaş tahmini, yaş grupları, Yerel İkili Örüntüler, Yerel Faz Kuantalama, Weber Yerel Tanımlayıcısı.

Abstract

Aging process causes significant changes on human's face. Facial aging varies from person to person and influenced by many factors. Therefore, determining the effects of aging in different areas of the face is important in the design of automatic age estimation systems. Besides, the effects of aging in different age groups may differ from each other.

Gönderim ve kabul tarihi : 21.11.2016 - 01.06.2017

In this study, the features are extracted from the facial regions (eyes, nose, cheeks, mouth-chin, sides of mouth) using 3 different histogram based texture descriptors (Local Binary Pattern, Local Phase Quantization, Weber Local Descriptor) for the age groups determined according to Erik Erikson's development theory. After the dimensionality reduction age estimation is performed using multiple linear regression. The experiments on FGNET and PAL databases showed that different regions are more effective than others for different age groups.

Keywords: Age estimation, age groups, Local Binary Patterns, Local Phase Quantization, Weber Local Descriptor.

1 Giriş

Yaş tahmini kişinin yüz görüntüsünden elde edilen bilgilerle kişinin ya da yaş grubunun belirlenmesi işlemidir. Yaşlanma sürecinde insanın yüz görünümünde önemli değişiklikler meydana gelmektedir. Bu değişimler kişiden kişiye farklılık göstermekte ve kişinin genetik özellikleri, yaşam ve coğrafi koşulları, yeme/içme alışkanlıkları, yüz ifadelerini kullanım sıklığı gibi faktörlerden etkilenmektedir. Bu ise yaş tahmini problemini diğer yüz görüntüsü işleme problemlerinden daha zor hale getirmektedir. Bu nedenle yaş tahmini sistemlerini başarılı yeterli düzeyde değildir, öyle ki insanın yaş tahmini konusundaki yetenekleri de sınırlıdır. Bu kapsamda yüzün çeşitli bölgelerinde bulunan yaş bilgi miktarının belirlenmesi ve yaş bilgisini daha çok vurgulayan yüz bölgelerini kullanarak yaş tahmini başarımının artırılması önem taşımaktadır. Diğer yandan yaş gruplarına göre yaşın belirlenmesinde hangi bölgelerin daha etkin olduğunun tespiti de hiyerarşik yaş tahmini

sistemlerinin tasarımında önemlidir. Hiyerarşik yaş tahmini sistemlerinin tasarımında yaş gruplarının belirlenmesi ayrı bir problem oluşturmaktadır. Yapılan çalışmalarda çok farklı yaş gruplarının kullanıldığı görülmektedir. Hatta aynı veri tabanı üzerinde deneyler yapan çalışmalarda farklı yaş grupları kullanılmıştır. [1-8].

Bu çalışmada göz, burun, yanak, ağız-çene, ağız kenarı gibi yüz bölgelerinin farklı yaş gruplarındaki yaş tahmini başarımları incelenmiştir. Sistemin genel yapısı Şekil 1’de görülmektedir. Öncelikle tüm görüntüler normalize edilerek kafa pozunu, ölçek ve şekil farklılıklarını elimine edilmiş ve tüm görüntülerdeki doku bilgisi hizalanmıştır. Yaş grupları belirlendikten sonra, her yaş grubu altındaki görüntüler göz, burun, yanak, ağız-çene ve ağız kenarı bölgelerine ayrılmıştır. Bu bölgelerden çeşitli histogram tabanlı öznelik çıkarma yöntemleri (Local Binary Patterns-LBP, Local Phase Quantization-LPQ, Weber Local Descriptor-WLD) ile bütünsel ve yerel öznelikler elde edilmiştir. Özneliklerin boyutu küçültüldükten sonra çoklu lineer regresyon ile yaş tahmini gerçekleştirilmiştir. Burada her yaş grubu altında her bir yüz bölgesinden farklı öznelik çıkarma yöntemleriyle çıkarılan özneliklerle ayrı ayrı yaş tahmini gerçekleştirilmiş ve böylece yaş grupları için yaş tahmininde en çok bilgi taşıyan özneliklerin hangi bölgelerden hangi

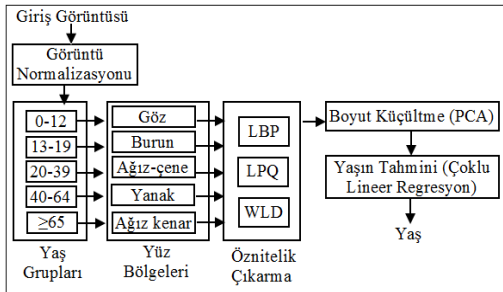
deneySEL sonuçlar ve tartışma ise dördüncü bölümde verilmiştir.

2 Yaş Tahmini Yöntemleri

Yaş tahmini sistemleri genellikle yaş görüntüsünün gösterimi ve yaşın tahmin edilmesi modüllerinden oluşmaktadır. Yaş görüntüsünün gösterimi modülünün amacı yüz görüntülerinden yaşın belirlenmesini sağlayacak şekil ya da doku tabanlı özneliklerin çıkarılmasıdır. Daha sonra bu öznelikler sınıflandırma yöntemleriyle ya da regresyon yöntemleriyle kullanılarak görüntülerin ait olduğu yaş grubu ya da yaş etiketi belirlenir.

Yüz görüntülerinin gösterimi yöntemleri beş grup altında toplanabilir. Antropometrik modeller yüzün geometrik yapısına dayalıdır. Bu modellerde yüz görüntülerindeki belirleyici noktalar arasındaki mesafeler ve bu mesafeler arasındaki oranlar hesaplanmaktadır. Bu geometrik öznelikler yalnızca küçük yaşlardaki kişiler için belirleyici olduğundan, daha yaşlı kişilerin sınıflandırma başarımını arttırmak için geometrik özelliklere ek olarak kırışıklık özellikleri kullanılmıştır [1, 2, 4].

Aktif Görünüm Modelleri (Active Appearance Models-AAM) tabanlı yaş tahmini yöntemleri hem şekil hem de görünüm bilgisini birleştirmektedir. Bu nedenle AAM’ler yaş tahmini sistemlerinde sıklıkla kullanılmaktadır [9-11]. Fakat AAM’ler, yaşlı insanlar için yüzdeki kırışıklık bilgisini iyi bir şekilde kodlayamaz. Çünkü AAM yöntemi, görüntüdeki parlaklık değerlerini, doku görüntüsünü hesaplayacak uzaysal bir komşuluk dikkate almadan kodlar. Daha yaşlı yetişkinlerin yüzlerindeki kırışıklıkları ifade etmek için yerel bölgelerin incelenmesi gerekir. Bu nedenle bazı çalışmalarda, yüz görüntülerinden global öznelikler AAM ile çıkarılmış ve yerel özneliklerle birleştirilerek daha etkin yaş tahmini sistemlerinin tasarlanması hedeflenmiştir [12].



Şekil-1: Sistemin genel yapısı

yöntemlerle çıkarılabileceği araştırılmıştır. Böylece bölge ağırlıklarının belirlenmesi ve bu yöntemlerin birleştirilmesiyle daha iyi bir yaş tahmini sisteminin oluşturulması mümkün olabilir.

Çalışmanın yapısı aşağıdaki şekildedir. İkinci bölümde yaş tahmini alanında yapılan çalışmalara kısaca değinilmiştir. Üçüncü bölümde önerilen yöntem detaylı bir şekilde anlatılmıştır. Elde edilen

Yaşlanma örüntüsü alt uzayı (Aging Pattern Subspace-AGES), yaşlanma sürecinin modellenmesinde bir kişinin farklı yaşlardaki görüntülerinin dizisini kullanan bir yöntemdir [13]. Fakat aynı kişinin çeşitli yaşlardaki görüntülerini içeren bir veri tabanının 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.

Ortak yaşlanma örüntüsünü öğrenmenin mümkün bir yolu, yaş topolojik uzayının (Age Manifold) öğrenilmesidir. Bu yöntemde, her bir yaş etiketi için elde edilen çok sayıda resimden yaşlanma eğilimini öğrenmek için, verilerin daha küçük boyutlu bir topolojik uzaya gömülmesinden (manifold embedding) yararlanılır [14, 15]. Dolayısı ile bir kişinin farklı yaşlardaki görüntülerine ihtiyaç duyulmaz. Her bir yaş etiketi için, o yaşı ifade eden pek çok farklı kişinin görüntüsü kullanılabilir.

Dokuya dayalı öznelik çıkarma yöntemleri (Appearance Models), yüz görüntülerinin bütününden genel olarak ya da çeşitli sayıdaki bloklardan genel olarak, yaşlanma ile ilişkili özneliklerin çıkarılmasını sağlamaktadır. Bunun dışında, yaşlanma sürecinde doku yapısı daha çok değişen alın, göz bölgesi, göz kenarları, yanaklar, ağız kenarları gibi bölgeler belirlenip, bu bölgelerden çıkarılan doku öznelikleri birleştirilerek kullanılabilir. Doku bilgisinin çıkarılmasında, kenar belirleme (Sobel, Canny), yerel ikili örüntüler (Local Binary Patterns - LBP), Gabor filtreleri, gradyan yönü histogramları (gradient direction histograms) gibi yöntemler kullanılmaktadır [12, 16-18].

Yukarıda bahsedilen çalışmalar incelendiğinde genellikle öznelik çıkarma aşamalarında tüm yüzün kullanıldığı görülmektedir. Fakat literatürde yüz bölgelerinin/parçalarının yaş tahmini performanslarını inceleyen yeterli sayıda çalışma mevcut değildir. Lanitis [19] yüz parçalarının yaş tahminindeki önemini araştırmıştır. Deneylerinde saç çizgisi dahil tüm yüzün, iç (internal) yüzün, yüzün üst ve alt kısımlarının yaş tahmini başarımları değerlendirilmiştir. Bu parçaların temsilinde AAM ile üretilen şekil ve görünüm model parametreleri kullanılmıştır. Elde edilen sonuçlar yüzün üst parçasının diğer parçalara göre daha düşük hata ile yaş tahmini gerçekleştirdiğini göstermiştir. El Dib ve Onsi [20] göz ve gözaltını içeren üçgenel bölgenin, iç yüzün ve tüm yüz bölgesinin yaş tahmini performansını incelemiştir. Bu bölgelerden çıkarılan biyolojiden esinlenilmiş özneliklerle (Biologically Inspired Features - BIF) yaşın tahmininde 6 SVR (Support Vector Regression) ve 1 SVM (Support Vector Machine) modeli kullanılmıştır. Elde ettikleri sonuçlar göz ve gözaltını içeren üçgenel bölgenin diğer bölgelere

kıyasla yaşla ilgili daha fazla bilgi içerdiğini göstermiştir.

3 Önerilen Yaş Tahmini Yöntemi

Önerilen yaş tahmini sistemi yaş gruplarının belirlenmesi, görüntü normalizasyonu, yüzün bölgelere ayrılması, histogram tabanlı doku tanımlayıcıları ile öznelik çıkarma, öznelik vektörlerinin boyutlarının küçültülmesi ve yaşın tahmini aşamalarını içermektedir. Bu aşamalar alt başlıklarda detaylı olarak açıklanmaktadır.

3.1 Yaş Gruplarını Belirleme

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 veri tabanlarındaki görüntülerin yaş aralığına göre belirlenmiş, insanın beklendiğinden 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 veri tabanı üzerinde deneyler gerçekleştiren farklı çalışmalarda, farklı sınırlara sahip yaş grupları kullanılmıştır. Çizelge 1’de çeşitli çalışmalarda kullanılan yaş grupları verilmiştir. Tablodan görüldüğü gibi önceki çalışmalarda kullanılan yaş gruplarının sınırları büyük bir çeşitliliğe sahiptir.

Daha önce de bahsedildiği gibi kişinin yaşlanma süreci, çeşitli genetik özelliklerinin yanında, yaşam koşullarından ve psikolojik durumundan da etkilenmektedir. Bu nedenle çalışmada kullanılacak olan yaş gruplarının sınırları, gelişim psikoloğu Erik Erikson’un, “insanın sosyal gelişim aşamaları” teorisine göre belirlenmiştir [21]. 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 sistem geliştirildiği ve yüz dokusunun küçük yaşlarda çok değişmeyeceği düşünüldüğü için 0-12 yaş grubu birlikte değerlendirilmiş,

Çizelge-1: Yaş grubuna sınıflandırma çalışmalarında kullanılan ve önerilen yaş grupları

Yöntem	Yaş Grupları
Kwon ve Lobo [1]	Bebek, genç, yaşlı
Hornig vd. [2]	0-2, 3-39, 40-59, ≥ 60
Geng vd. (2014) [3]	0-20, 21-50, 51-76
Dehshibi ve Bastanfard [4]	0-15, 16-30, 31-50, ≥ 51
Liu vd. [5]	0-2, 3-10, 11-18, 19-39, 40-69
Weixing vd. [6]	0-17, 18-45, 46-60, 61-69
Kalansuriya ve Dharmaratne [7]	8-13, 14-25, 26-45, 46-63
Sai vd.[8]	0-10, 11-19, 20-60, ≥ 61
Önerilen Yaş Grupları	0-12,13-19,20-39,40-64,≥ 65

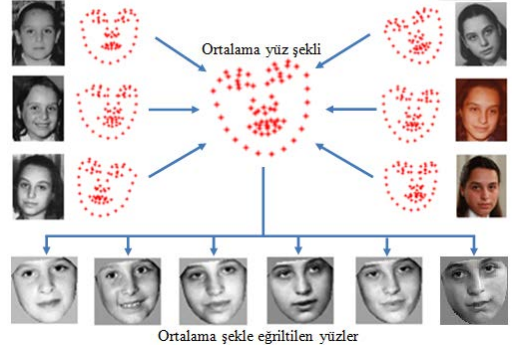
diğer yaş grupları Erikson'un teorisine uygun olarak oluşturulmuştur. Sonuç olarak çalışmada kullanılan yaş grupları, çocuk (0-12), ergen (13-19), genç yetişkin (20-39), orta yaşlı (40-64) ve yaşlı (≥ 65) olarak belirlenmiştir.

3.2 Görüntü Normalizasyonu

Görüntülerdeki kafa pozunu, ölçek, boyut gibi şekil farklılıklarını elimine etmek ve doku bilgisini hizalamak için yüz görüntülerine normalizasyon işlemi uygulanmaktadır. Şekil 2'de görüldüğü gibi görüntü normalizasyonu tüm yüzlerin eğitim kümesinden elde edilen ortalama şekle eğriltilmesi yoluyla gerçekleştirilmiştir. Öncelikle eğitim kümesindeki tüm yüz görüntüleri 68 nokta ile etiketlenir. Tüm eğitim kümesindeki nokta koordinatlarının ortalaması alınarak ortalama şekil elde edilir. Daha sonra Delaunay üçgenleri ve afin dönüşüm kullanılarak tüm görüntüler ortalama şekle eğriltilir. Böylece tüm görüntülerin noktaları ortalama şeklin noktaları ile eşleşmiş olur ve aynı zamanda doku bilgisi de hizalanır. Eğitim kümesindeki görüntülerin kafa pozunu farklı olduğundan eğriltilen görüntüler sağa ya da sola eğik olabilir. Bu nedenle göz konumlarına göre bir döndürme işlemi uygulanarak normalize edilmiş görüntüler elde edilir.

3.3 Yüz Bölgelerini Oluşturma

Yüz bölgelerinde bulunan yaş bilgisinin araştırılması yaş tahmini sistemlerinin tasarımında önemlidir. Yaş grupları için hangi bölgelerin yaşın tahmininde daha etkin olduğunun belirlenmesi, özellikle hiyerarşik yaş tahmini sistemlerinde yaş grubu belirlendikten sonra, yaş grupları altında çok daha iyi bir yaş tahmini gerçekleştirmesini mümkün hale getirir.




Şekil-2: Görüntü normalizasyonu

Çünkü yaş bilgisini vurgulayan bölgelere daha büyük ağırlıklar verilerek yaş tahmini performansı artırılabilir. Bu amaçla yüz görüntüleri 5 farklı bölgeye ayrılmış ve her bir bölgenin tüm yaş grupları için ayrı yaş tahmini performansı incelenmiştir. Çalışmada kullanılan yüz bölgeleri, Şekil 3'te görüldüğü gibi göz, burun, yanaklar, ağız-çene ve ağız kenarları şeklindedir.

3.4 Öznitelik Çıkarma

3.4.1. Yerel İkili Örnekleme

LBP sayısal görüntülerdeki doku bilgisini tanımlayan çok güçlü bir yöntemdir [22]. 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. LBP kodlarının üretilmesi aşağıdaki denklem ile gerçekleştirilmektedir.



Şekil-3: Yüz bölgeleri (a) göz (b) yanak (sol ve sağ) (c) burun (d) ağız kenarı (sol ve sağ) (e) ağız-çene

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p$$

$$u(y) = \begin{cases} 1, & y \geq 0 \text{ ise} \\ 0, & y < 0 \text{ ise} \end{cases} \quad (1)$$

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

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

$$i = 0, 1, \dots, n-1 \quad f(y) = \begin{cases} 1, & y \text{ doğru ise} \\ 0, & y \text{ yanlış ise} \end{cases} \quad (2)$$

$U(i)$ 8 komşulukta üretilen örüntülerden düzgün olan 58 tanesini tutan dizidir. Bu histogram tüm resim üzerindeki kenarlar, benekler, düz alanlar gibi mikro-örüntülerle ilgili bilgi taşımaktadır.

3.4.2. Yerel Faz Kuantalama

Yerel faz kuantalama (Local Phase Quantization-LPQ) Fourier faz spektrumunun bulanıklık değişmezliği özelliğine dayalı bir bulanıklığa duyarlı doku tanımlayıcısıdır [23]. Bu yöntemde LPQ kodları, Ayırık Fourier Dönüşümü kullanılarak yerel görüntü pencerelerinde hesaplanır ve sonuçlar histogram olarak sunulur.

\mathcal{N}_x , $f(x)$ görüntüsündeki x piksel pozisyonu etrafındaki $M \times M$ komşuluğu tanımlasın. Bu görüntünün penceresinin iki boyutlu ayırık Fourier dönüşümü,

$$F(u, x) = \sum_{y \in \mathcal{N}_x} f(x - y) e^{-j2\pi u^T y} = w_u^T f_x \quad (3)$$

ile tanımlanır. Burada w_u iki boyutlu ayırık Fourier dönüşümünün u frekansındaki temel vektörünü, f_x ise \mathcal{N}_x 'teki tüm M^2 pikseli içeren vektörü temsil etmektedir. LPQ'da sadece $u_1=[a, 0]^T$, $u_2=[0, a]^T$, $u_3=[a, a]^T$, $u_4=[a, -a]^T$ 'nin karmaşık (reel ve sanal) katsayıları dikkate alınır. Tüm pikseller için ($x \in \{x_1, x_2, \dots, x_N\}$) G_x hesaplanır ve elde edilen vektörler

$$q_j = \begin{cases} 1, & \text{eğer } g_j \geq 0 \\ 0, & \text{aksi halde} \end{cases} \quad (4)$$

ile kuantalanır. Burada g_j G_x 'in j . bileşenidir. Kuantalanan katsayılar $b = \sum_{j=1}^8 q_j 2^{j-1}$ şeklindeki ikili kodlama kullanılarak 0-255 arasındaki tamsayı değerle ifade edilir. Son olarak bu sayısal değerlerin histogramı öznitelik vektörü olarak kullanılır.

3.4.3. Weber Yerel Tanımlayıcı

Weber yerel tanımlayıcı (Weber Local Descriptor-WLD) [24] insan algılamasının, bir uyarıcı (örneğin bir ses, ışık gibi) yoğunluğundaki değişim miktarına bağlı olduğu kadar, uyarıcının orijinal yoğunluğuna dayandığı gerçeğine dayanır. Temelde WLD, bir histogram oluşturmak için kullanılan diferansiyel uyarılma (ξ) ve oryantasyon (θ) bileşenlerinden oluşur. Orijinal WLD operatörü merkez pikselin, 3×3 ($P=8$, $R=1$) komşuluğundaki piksellerle karşılaştırılması sonucu elde edilir.

Diferansiyel uyarılma bileşeni, merkez piksel parlaklığının komşularıyla olan bağıl farkının, pikselin parlaklığı arasındaki orandır. x_c merkez pikselinin diferansiyel uyarılma $\xi(x_c)$ bileşeni,

$$\xi(x_c) = \arctan \left[\frac{v_s^{00}}{v_s^{01}} \right] \quad (5)$$

ile hesaplanır. Burada $v_s^{00} = \sum_{i=0}^{p-1} (x_i - x_c)$, x_i ($i=0, 1, \dots, p-1$) x_c 'nin i . komşusunu, p komşu sayısını ve $v_s^{01} = x_c$ 'yi ifade emektedir. WLD'nin yönelim bileşeni $\theta(x_c)$, merkez piksel x_c 'nin gradyan yönelimidir ve aşağıdaki formülle hesaplanır.

$$\theta(x_c) = \arctan \left[\frac{v_s^{11}}{v_s^{10}} \right] \quad (6)$$

Denklemden v_s^{11} , x_c 'nin solunda ve sağındaki piksellerin farkı iken v_s^{10} ise x_c 'nin hemen üstündeki ve altındaki piksellerin farkıdır. Daha sonra $\xi(x_c)$ ve $\theta(x_c)$ bileşenleri kullanılarak WLD histogramı üretilir ve bu histogram doku tanımlayıcısı olarak kullanılır [24]. Bu histogramın üretimi sırasında kullanılan T parametresi baskın yön sayısını, M her baskın yön histogramındaki segment sayısını, S ise her segmentteki bölme sayısını ifade etmektedir. Bu nedenle oluşturulan WLD doku tanımlayıcısının boyutu $T \times M \times S$ 'dir.

3.5. Uzamsal Öznitelik Çıkarma

Çalışmada kullanılan doku tanımlayıcıları yüz görüntülerini doku özniteliklerini içeren histogramlar şeklinde temsil etmektedir. Bu histogramlar piksellerin uzamsal konumları dikkate alınmadan üretilmektedir. Burada görüntülerde benzer doku öznitelik değerlerine sahip olan iki farklı bölge histogramlardaki aynı bölmeye katkıda bulunmaktadır ve doku tanımlayıcı tarafından ayırt edilememektedir. Doku tanımlayıcılarının ayırt ediciliğini iyileştirmek için görüntüler belirli sayıda bloklara ayrılır, her blokta histogramlar çıkarılır ve bu histogramlar birleştirilerek uzamsal doku tanımlayıcısı elde edilir. Çalışmada her bir yüz bölgesi 6x6 bloklara ayrılmış, bu bölgelerden LBP, LPQ ve WLD yöntemleri ile öznitelik vektörleri üretilmiş ve bu vektörler birleştirilerek yaş tahmininde kullanılmıştır. Genel yaş değerlendirmesi yapılan daha önceki çalışmamızda blok boyutunun küçülmesi ile başarımın arttığı izlenmiştir [25]. Bu nedenle bu çalışmada da her bir bölge 6x6 bloklara ayrılarak uzamsal öznitelik çıkarma işlemi gerçekleştirilmiştir.

3.6. Boyut Küçültme

Çalışmada üretilen öznitelik vektörlerinin boyutunun küçültülmesinde Temel Bileşenler Analizi (Principal Component Analysis-PCA) yöntemi kullanılmıştır. PCA'daki ana düşünce verinin dağılımını en iyi şekilde yakalayan vektörlerin bulunmasıdır. Bu vektörler, veriye ait kovaryans matrisinin (S) öz vektörleridir. Bu ise $W_{opt} = \arg \max_{\|W\|=1} W^T S W$ denkleminin çözülmesi ile elde edilir. Denklem çözüldüğünde S 'nin en büyük d ($d \leq D$) öz değerine karşılık gelen öz vektörleri (W) elde edilmiş olur. Daha sonra boyut küçültme işlemi $y_i = W^T x_i$ ($y_i \in R^d$) ile gerçekleştirilir.

3.7. Yaş Tahmini

Çalışmada yaşın tahmini çoklu lineer regresyon ile gerçekleştirilmiştir. Buradaki amaç, $l = f(y)$ denklemindeki f fonksiyonunu, eğitim kümesinin yaş etiketlerini ve öznitelik vektörlerini kullanarak öğrenmektir. Çalışmada kullanılan lineer regresyon fonksiyonu $\hat{l} = \hat{\beta}_0 + \hat{\beta}_1^T y$ 'dir. Denkleminde y öznitelik vektörünü, $\hat{\beta}_0$ offset değerini, $\hat{\beta}_1$, öznitelik vektöründeki her eleman için eğitim kümesinden öğrenilen ağırlık katsayılarının birleşiminden oluşan vektörü, \hat{l} ise tahmin edilen yaşı ifade etmektedir.

4 Sonuçlar ve Öneriler

Çalışmada yüz bölgelerinin farklı öznitelik çıkarma yöntemleriyle, önerilen yaş grupları altındaki yaş tahmini başarımının değerlendirilmesinde, FGNET ve PAL veri tabanları kullanılmıştır. FG-NET veri tabanı, yaşları 0 ile 69 arasında değişen 82 kişiden alınmış 1002 resimden oluşmaktadır [26]. Görüntüler aydınlatma, kafa pozunu, yüz ifadesi, arka plan, çözünürlük ve taramadan doğan gürültü gibi pek çok farklılıklara sahiptir. Diğer yandan veri tabanında yaşa göre dağılım Şekil 4-a'da görüldüğü gibi düzgün değildir. Veri tabanındaki görüntülerin yaklaşık olarak %70'i 0-20 yaş aralığındadır. Buna rağmen bu veri tabanı kişiler için kronolojik sırada yaşlanma görüntüsü sunan tek veri tabanı olduğundan, yaş tahmini çalışmalarında sıklıkla kullanılmaktadır.

PAL veri tabanı [27] 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. PAL veri tabanındaki görüntülerin yaş etiketlerine göre dağılımı Şekil 4-b'de görülmektedir. PAL veri tabanındaki görüntülerin yaş etiketlerine göre dağılımı incelendiğinde, görüntülerin %40'ünün 18-30 yaş, %45'inin ise 60-93 yaş aralığında olduğu görülmektedir. 30-60 yaş aralığındaki görüntüler veri tabanının sadece %15'ini oluşturmaktadır.


Çalışmada kullanılan yaş tahmini sisteminin performansı n -kat çapraz doğrulama yöntemi ile değerlendirilmiştir. Bu yöntemde veri tabanındaki görüntüler rasgele olarak n adet eşit sayıda alt gruba ayrılır. Daha sonra bu alt gruplardan biri test kümesi geriye kalan $n-1$ alt grup ise eğitim kümesi olarak kullanılır. Bu işlem her alt grup test kümesi olarak kullanılacak şekilde n kez tekrarlanır. Elde edilen tüm yaş tahmini sonuçların ortalaması alınarak sistemin başarımı hesaplanır. Çalışmada $n=3$ değeri kullanılmıştır.

Sistem performansı ortalama mutlak hata (Mean Absolute Error-MAE) ölçütü ile ölçülmüştür. MAE, test kümesindeki görüntüler için tahmin edilen yaş etiketleri ile gerçek yaş etiketleri arasındaki mutlak hata değerlerinin ortalaması alınarak aşağıdaki denklemle hesaplanmaktadır.

$$MAE = \sum_{i=1}^{N_t} |y_i - \hat{y}_i| / N_t \quad (7)$$

Denkleimde \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.

Yapılan deneylerde, her bir yaş grubundaki görüntülerden histogram tabanlı doku tanımlayıcıları (LBP, WLD, LPQ) ile uzamsal öznitelikler (6x6 bloklardan) çıkarılmış, birleştirilmiş ve yaş tahmini gerçekleştirilmiştir. LBP doku tanımlayıcısında $P=8$ ve $R=1$ parametreleri kullanılmıştır. LPQ operatörü görüntüdeki her bir pikselin 5x5 komşuluğu dikkate



Şekil-4: (a) FGNET (b) PAL veri tabanındaki görüntülerin yaş etiketlerine göre dağılımı

($M=5$) alınarak uygulanmıştır. WLD operatöründe ise parametreler $P=8$, $R=1$, $T=8$, $M=6$ ve $S=5$ olarak kullanılmıştır. Çalışmada normalizasyon aşamasında kullanılan 68 nokta koordinatının belirlenmesi ayrı bir problem oluşturmaktadır. FGNET veri tabanındaki görüntüler için bu nokta koordinatları veri tabanında verilmiştir. PAL veri tabanındaki görüntüler için bu 68 nokta koordinatı elle belirlenmiştir.

Uzamsal $LBP_{8,1}$ öznitelikleri ile, FGNET ve PAL veri tabanları için, her bir yüz bölgesinin belirtilen yaş aralıklarındaki yaş tahmini başarımları Şekil 5'te görülmektedir. Şekilden görüldüğü gibi $LBP_{8,1}$ öznitelikleri ile FGNET veri tabanında 0-12 yaş grubu için 2.36 yıl MAE ve 13-19 yaş grubu için 1.85 yıl MAE ile en iyi yaş tahmini göz bölgesi ile elde edilmiştir. Diğer yandan 20-39 yaş grubunda 4.41 yıl MAE ile burun bölgesi, 40-64 yaş grubunda ise 4.89 yıl MAE ile ağız-çene bölgesi en iyi yaş

tahmini başarımını sağlamıştır. PAL veri tabanı için uzamsal $LBP_{8,1}$ özniteliklerinin sonuçları incelendiğinde, 13-19 yaş grubunda en iyi yaş tahmini 0.48 yıl MAE ile burun bölgesiyle elde edilmiştir. 20-39 yaş grubunda 3.88 yıl MAE ile ağız-çene bölgesi, 40-64 yaş grubunda 6.20 yıl MAE ile yanak bölgesi, 65-93 yaş grubunda ise 5.48 yıl MAE ile göz bölgesi en iyi yaş tahmini başarımını sağlamaktadır.

Uzamsal LPQ_5 ve $WLD_{8,1}(T=8, M=6, S=5)$ öznitelikleri ile FGNET ve PAL veri tabanları için her bir yüz bölgesinin belirtilen yaş aralıklarındaki yaş tahmini başarımları ise sırasıyla Şekil 6 ve Şekil 7'de verilmiştir. Uzamsal LPQ_5 öznitelikleri ile FGNET veri tabanında 0-12 ve 13-19 yaş gruplarında en iyi yaş tahmini sırasıyla 2.11 yıl ve 1.69 yıl MAE ile göz bölgesiyle elde edilmiştir. 20-39 yaş grubunda 4.14 yıl MAE ile burun bölgesi, 40-64 yaş grubunda ise 4.90 yıl MAE ile ağız-çene bölgesi en iyi yaş tahmini başarımı göstermiştir. PAL veri tabanında ise 13-19 ve 20-39 yaş gruplarında ağız-çene bölgesi sırasıyla 0.51 yıl ve 3.76 yıl MAE ile diğer bölgelere göre daha iyi bir yaş tahmini sağlamıştır. 40-64 ve 65-93 yaş gruplarında ise en iyi başarımları 6.80 yıl ve 5.43 yıl MAE ile yanak bölgesi göstermiştir.

Uzamsal $WLD_{8,1}(T=8, M=6, S=5)$ öznitelikleriyle ise FGNET veri tabanında, 0-12 yaş grubunda 2.33 yıl MAE ve 4.17 yıl MAE ile burun bölgesi, 40-64 yaş grubunda 4.85 yıl MAE ile ağız-çene bölgesi en iyi yaş tahminini gerçekleştirmiştir. PAL veri tabanında 13-19 yaş grubunda 0.52 yıl MAE ile burun bölgesi, 20-39 yaş grubunda 3.62 yıl MAE ile yanak bölgesi, 40-64 ve 65-93 yaş gruplarında ise sırasıyla 6.25 yıl ve 5.53 yıl MAE ile göz bölgesi en iyi yaş tahmini başarımını sağlamaktadır.


Şekil 5, 6 ve 7 incelendiğinde FGNET veri tabanında en iyi yaş tahmini başarımının tüm yöntemlerle 13-19 yaş grubunda daha sonra 0-12 yaş grubunda elde edildiği görülmektedir. FGNET veri tabanındaki görüntülerin yaşa göre dağılımı (Şekil 4-a) incelendiğinde bu yaş gruplarındaki resim sayısının diğer gruplara göre oldukça fazla olduğu görülmektedir. Benzer şekilde PAL veri tabanında en iyi yaş tahmini başarımlarının öncelikle 13-19 yaş grubunda daha sonra 20-39 ve 65-93 yaş gruplarında elde edildiği görülmektedir. 13-19 yaş grubundaki başarımın çok iyi olmasının nedeni bu aralıkta veri tabanında sadece 18 ve 19 yaşındaki kişilerin görüntülerinin bulunmasıdır. Diğer yaş gruplarındaki başarım PAL veri tabanındaki

görüntülerin yaşa göre dağılım şekli (Şekil 4-b) ile uyum göstermektedir. Buradan veri tabanlarındaki yaş gruplarında yeterli görüntünün bulunmaması, yaş tahmini başarımını kötü yönde etkilemektedir.


Yapılan deneyler sonucunda veri tabanlarındaki yaş grupları için en iyi yaş tahmini başarımının elde edilmesini sağlayan bölgeler ve öznelik çıkarma yöntemleri ve elde edilen yaş tahmini başarımları Çizelge 2’de görülmektedir. Tablodan görüldüğü gibi FGNET veri tabanında 0-12, 13-19 ve 20-39 yaş gruplarında uzamsal LPQ öznelikleri göz ve burun bölgelerinde en iyi yaş tahminini sağlamaktadır. 40-64 yaş grubunda ise kenar belirleme performansı yüksek olan WLD operatörü ağız-çene bölgesinden çıkardığı öznelikle en

Çizelge-2: Yaş gruplarındaki en iyi yaş tahmini başarımları, bölgeler ve öznelik çıkarma yöntemleri


Veri tabanı	Yaş Grubu	Bölge	Yöntem	MAE
FGNET	0-12	Göz	LPQ ₅	2.11
	13-19	Göz	LPQ ₅	1.69
	20-39	Burun	LPQ ₅	4.14
	40-64	Ağız-Çene	WLD _{8,1}	4.85
			(T=8, M=6, S=5)	
PAL	13-19	Burun	LBP _{8,1}	0.48
	20-39	Yanak	WLD _{8,1}	3.62
			(T=8, M=6, S=5)	
	40-64	Yanak	LBP _{8,1}	6.20
	65-93	Yanak	LPQ ₅	5.43



Şekil-5: Yüz bölgelerinden LBP_{8,1} ile çıkarılan özneliklerin yaş gruplarındaki yaş tahmini başarımları



Şekil-6: Yüz bölgelerinden LPQ₅ ile çıkarılan özneliklerin yaş gruplarındaki yaş tahmini başarımları



Şekil-7: Yüz bölgelerinden WLD_{8,1} (T=8, M=6, S=5) ile çıkarılan özneliklerin yaş gruplarındaki yaş tahmini başarımları

başarılı sonucu vermiştir. PAL veri tabanında küçük yaşlarda çok fazla görüntü olmaması yanak bölgesinden kenar belirlemeye yönelik öznelikleri çıkaran LBP ve WLD doku tanımlayıcılarını ön plana çıkarmıştır. Burada 20-39, 40-64 ve 65-93 yaş gruplarında yanak bölgelerinden sırasıyla WLD, LBP ve LPQ öznelikleriyle en iyi yaş tahmini başarımları elde edilmiştir. 13-19 yaş grubu içinse burun bölgesinden çıkarılan LBP öznelikleri yaş tahmininde diğerlerine göre daha başarılıdır. Elde edilen bu sonuçlar, her bir yaş grubunda yüz bölgeleriyle farklı öznelik çıkarma yöntemleriyle farklı yaş tahmini başarımları elde edildiğini göstermektedir. Bu sonuçlar kullanılarak her bir yaş grubu için bölge ağırlıklarının belirlenmesi ve bu yöntemlerin birleştirilmesiyle daha iyi bir yaş tahmini sisteminin oluşturulması, özellikle hiyerarşik yaş tahmini sistemlerinde yaş grubu belirlendikten sonra, yaş grupları altında çok daha iyi bir yaş tahmini gerçekleştirmesini mümkün hale getirebilir.

Kaynakça

- [1] Kwon, Y. H., Lobo, N. V. *Age Classification from Facial Images*, Computer Vision and Image Understanding, 74 (1):1-21, 1999
- [2] Horng, W. B., Lee, C. P. and Chen, C. W., *Classification of Age Groups Based on Facial Features*, Tamkang Journal of Science and Engineering, 4(3):183-192, 2001.
- [3] Geng, X., Wang, Q. and Xia, Y., *Facial Age Estimation by Adaptive Label distribution Learning*, IEEE 22nd International Conference on Pattern Recognition (ICPR 2014), 4465-4470, 2014.
- [4] Dehshibi, M. M. and Bastanfard, A., *A new algorithm for age recognition from facial images*, Signal Processing, 90(8):2431-2444, 2010.
- [5] Liu, L., Liu, J. and Cheng, J., *Age-Group Classification of Facial Images*, 11th International Conference on Machine Learning and Applications (ICMLA'12), 693-696, 2012.
- [6] Weixing, L., Haijun, S., Feng, P., Qi, G. and Shaoyan, G., *Facial Age Classification Based on Weighted Decision Fusion*, Proceedings of the 33rd Chinese Control Conference, 4870-4874, 2014.
- [7] Kalansuriya, T. R. and Dharmaratne, A. T., *Facial Image Classification Based on Age and Gender*, 2013 International Conference on Advances in ICT for Emerging Regions, 44-50, 2013.
- [8] Sai, P. K., Wang, J. G. ve Teoh, E. K., *Facial age range estimation with extreme learning machines*, Neurocomputing, 149:364-372, 2015.
- [9] Lanitis, A., Taylor, C. and Cootes, T., *Toward Automatic Simulation of Aging Effects on Face Images*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 24(4):442-455, 2002.
- [10] Kohli, S., Prakash, S. and Gupta, P., *Hierarchical age estimation with dissimilarity-based classification*, Neurocomputing, 120:164-176, 2013.
- [11] Chao, W. L., Liu, J. Z. and Ding, J. J., *Facial age estimation based on label-sensitive learning and age oriented regression*, Pattern Recognition, 43:628-641, 2013.
- [12] Choi, S. E., Le, Y. J., Lee, S. J., Park, K. R. and Kim, J., *Age estimation using a hierarchical classifier based on global and local facial features*, Pattern Recognition, 44:1262-1281, 2011.
- [13] Geng, X., Zhou, Z. H. and Miles, K. S., *Automatic Age Estimation Based on Facial Aging Patterns*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 29(12):2234-2240, 2007.
- [14] Fu, Y. and Huang, T. S., *Human Age Estimation with Regression on Discriminative Aging Manifold*, IEEE Transactions on Multimedia, 10(4):578-584, 2008.
- [15] Guo, G., Fu, Y., Dyer, C. R. and Huang, T. S., *Image-Based Human Age Estimation by Manifold Learning and Locally Adjusted Robust Regression*, IEEE Transactions on Image Processing, 17(7):1178-1188, 2008.
- [16] Chen, C., Yang, W., Wang, Y., Ricanek, K. and Luu, K., *Facial Feature Fusion and Model Selection for Age Estimation*, IEEE International Conference on Automatic Face & Gesture Recognition and Workshops (FG'11), 200-205, 2011.
- [17] Guo, G., Mu, G., Fu, Y. and Huang, T. S., *Human Age Estimation Using Bio-Inspired Features*, Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 112-119, 2009.
- [18] Liu, J., Ma, Y., Duan, L., Wang, F. and Liu, Y., *Hybrid constraint SVR for facial age estimation*, Signal Processing, 94:576-582, 2014.
- [19] Lanitis, A., *On the Significance of Different Facial Parts for Automatic Age Estimation*, 14th International Conference on Digital Signal Processing, 2:1027-1030, 2002.
- [20] El Dib, M. Y. and Onsi, H. M., *Human age estimation framework using different facial parts*, Egyptian Informatics Journal, 12(1):53-59, 2011.
- [21] Erikson, E., 1968. *Identity, Youth and Crisis*, New York: Norton.
- [22] Ojala, T., Pietikainen, M. and Maenpää, T., *Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 24(7):971-987, 2002.
- [23] Ojansivu, V. and Heikkilä, J., *Blur Insensitive Texture Classification Using Local Phase*

Quantization, Image and Signal Processing, 5099:236-243, 2008.

- [24] Chen, J., Shan, S., Zhao, G., Pietikainen, M., Chen, X., and Gao, W., *WLD: A Robust Local Image Descriptor*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 32(9):1705-1720, 2009.
- [25] Günay, A. and NabiyeV, V. V., *Facial Age Estimation Using Spatial Weber Local Descriptor*, 39th International Conference on Telecommunications and Signal Processing (TSP 2016), 2016.
- [26] FG-NET Aging Database, <http://sting.cycollege.ac.cy/~alanitis/fgnetaging/2008>.
- Minear, M. and Park, D. C., *A lifespan database of adult stimuli*, Behavior Research Methods, Instruments and Computers, 36(4):630-633, 2004