

T.C.
SIİRT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜZ İFADELERİNDEN CİNSİYET, DUYGU VE YAŞ TAHMİNİ
İÇİN YENİ YAKLAŞIMLAR

YÜKSEK LİSANS TEZİ

ALİ YILMAZ

(163111012)

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

TEZ DANIŞMANI: DR. ÖĞRETİM ÜYESİ YILMAZ KAYA

Haziran-2019

SIİRT

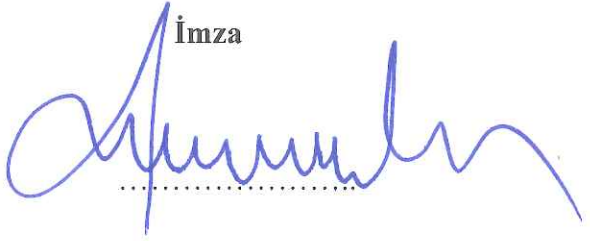
TEZ KABUL VE ONAYI

Ali YILMAZ tarafından hazırlanan “Yüz İfadelerinden Cinsiyet, Duygu ve Yaş Tahmini İçin Yeni Yaklaşımlar” adlı tez çalışması 20/06/2019 tarihinde aşağıdaki jüri tarafından oybirliği ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

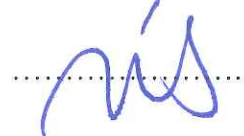
Başkan

Dr. Öğr. Üyesi Ramazan TEKİN

İmza


Danışman

Dr. Öğr. Üyesi Yılmaz KAYA

İmza


Üye

Dr. Öğr. Üyesi Mehmet Recep MİNAZ

İmza


Yukarıdaki sonucu onaylarım.

İmza


Doç. Dr. Fevzi HANSU
Fen Bilimleri Enstitüsü Müdürü

ÖN SÖZ

Bu tez çalışması esnasında sürekli yol gösteren ve her konuda yardımlarını esirgemeyen danışman hocam Dr. Yılmaz Kaya'ya ve aileme teşekkürlerimi sunarım.

Ali YILMAZ
SİİRT-2019



İÇİNDEKİLER

Sayfa

| | |
|--|-----------|
| ÖN SÖZ | iii |
| İÇİNDEKİLER | iv |
| TABLolar LİSTESİ | vii |
| ŞEKİLLER LİSTESİ | vii |
| KISALTMALAR VE SİMGELERLİSTESİ..... | viii |
| ÖZET | ix |
| ABSTRACT..... | x |
| 1. GİRİŞ..... | 1 |
| 1.1. Yaş Tahmin Yöntemleri..... | 5 |
| 1.2. Duygu Analiz Yöntemleri..... | 8 |
| 1.3. Cinsiyet Tahmin Yöntemleri..... | 10 |
| 2. LİTERATÜR ARAŞTIRMASI..... | 12 |
| 2.1. Cinsiyet Tahmini ile İlgili Çalışmalar | 12 |
| 2.2. Yaş Tahmini ile İlgili Çalışmalar | 17 |
| 2.3. Duygu Tahmini ile İlgili Çalışmalar | 21 |
| 3. MATERYAL VE METOT..... | 24 |
| 3.1. Materyal | 24 |
| 3.2. Metot | 25 |
| 3.2.1. Yerel İkili Örüntüler..... | 25 |
| 3.2.2. L2R (LBP _{L2R}) | 27 |
| 3.2.3. T2D (LBP _{T2D}) | 29 |
| 3.2.4. LBP _{Surfaces} (LBP _{Yüzey}) | 31 |
| 3.2.5. LBP _{Diagonal} | 33 |
| 3.3. Sınıflandırma | 34 |
| 3.4. Model Başarım Ölçütleri..... | 34 |
| 3.4.1. Doğruluk..... | 35 |
| 3.4.2. Hata Oranı | 35 |
| 3.4.3. Kesinlik | 35 |
| 3.4.4. Duyarlılık..... | 35 |
| 3.4.5. F-Ölçüsü | 36 |
| 3.5. Çalışma Diyagramı | 36 |
| 3.6. Renk Uzayları..... | 37 |
| 3.6.1. RGB | 37 |
| 3.6.2. HSV..... | 38 |
| 3.6.3. YIQ..... | 39 |

| | |
|--|-----------|
| 3.6.4. YCbCr | 40 |
| 3.7. Gürültü Metotları..... | 40 |
| 3.7.1. Poisson Gürültü Metodu..... | 40 |
| 3.7.2. Gaussian Gürültü Metodu | 41 |
| 3.7.3. Salt&Pepper Gürültü Metodu..... | 41 |
| 4. SONUÇ | 43 |
| 4.1. Cinsiyet Tahmin Sonuçları..... | 46 |
| 4.1.1. Farklı Renk Uzaylarında Elde Edilen Özniteliklerin Sınıflandırma Başarısı..... | 47 |
| 4.1.2. Farklı Gürültü Metotları Uygulanarak Elde Edilen Özniteliklerin..... Sınıflandırma Başarısı..... | 49 |
| 4.2. Yaş Tahmin Sonuçları..... | 52 |
| 4.2.1. Farklı Renk Uzaylarında Elde Edilen Özniteliklerin Sınıflandırma Başarısı..... | 53 |
| 4.2.2. Farklı Gürültü Metotları Uygulanarak Elde Edilen Özniteliklerin..... Sınıflandırma Başarısı..... | 55 |
| 4.3. Duygu Tahmin Sonuçları..... | 57 |
| 4.3.1. Farklı Renk Uzaylarında Elde Edilen Özniteliklerin Sınıflandırma Başarısı..... | 58 |
| 4.3.2. Farklı Gürültü Metotları Uygulanarak Elde Edilen Özniteliklerin..... Sınıflandırma Başarısı..... | 60 |
| 5. TARTIŞMA | 64 |
| 6. KAYNAKLAR..... | 67 |
| ÖZGEÇMİŞ..... | 71 |

TABLolar LİSTESİ

Sayfa

| | |
|--|----|
| Tablo 4. 1. Farklı renk uzaylarında LMT ile başarı oranları..... | 47 |
| Tablo 4. 2. Farklı renk uzaylarında LMT ile performans sonuçları | 47 |
| Tablo 4. 3. Farklı renk uzaylarında J48 ile başarı oranları | 48 |
| Tablo 4. 4. Farklı renk uzaylarında J48 ile performans sonuçları..... | 48 |
| Tablo 4. 5. Farklı renk uzaylarında Simple Logistic ile başarı oranları | 48 |
| Tablo 4. 6. Farklı renk uzaylarında Simple Logistic ile performans sonuçları..... | 49 |
| Tablo 4. 7. Farklı Gürültü Metotlarının LMT ile başarı oranları | 50 |
| Tablo 4. 8. Farklı Gürültü Metotlarının LMT ile performans sonuçları..... | 50 |
| Tablo 4. 9. Farklı Gürültü Metotlarının J48 ile başarı oranları..... | 51 |
| Tablo 4. 10. Farklı Gürültü Metotlarının J48 ile performans sonuçları..... | 51 |
| Tablo 4. 11. Farklı Gürültü Metotlarının Simple Logistic ile başarı oranları..... | 52 |
| Tablo 4. 12. Farklı Gürültü Metotlarının Simple Logistic ile performans sonuçları | 52 |
| Tablo 4. 13. Farklı renk uzaylarında LMT ile başarı oranları..... | 53 |
| Tablo 4. 14. Farklı renk uzaylarında LMT ile performans sonuçları | 53 |
| Tablo 4. 15. Farklı renk uzaylarında J48 ile başarı oranları | 54 |
| Tablo 4. 16. Farklı renk uzaylarında J48 ile performans sonuçları..... | 54 |
| Tablo 4. 17. Farklı renk uzaylarında Simple Logistic ile başarı oranları | 54 |
| Tablo 4. 18. Farklı renk uzaylarında Simple Logistic ile performans sonuçları..... | 55 |
| Tablo 4. 19. Farklı Gürültü Metotlarının LMT ile başarı oranları | 55 |
| Tablo 4. 20. Farklı Gürültü Metotlarının LMT ile performans sonuçları..... | 56 |
| Tablo 4. 21. Farklı Gürültü Metotlarının J48 ile başarı oranları | 56 |
| Tablo 4. 22. Farklı Gürültü Metotlarının J48 ile performans sonuçları..... | 56 |
| Tablo 4. 23. Farklı Gürültü Metotlarının Simple Logistic ile başarı oranları..... | 57 |
| Tablo 4. 24. Farklı Gürültü Metotlarının Simple Logistic ile performans sonuçları | 57 |
| Tablo 4. 25. Farklı renk uzaylarında LMT ile başarı oranları..... | 58 |
| Tablo 4. 26. Farklı renk uzaylarında LMT ile performans sonuçları | 58 |
| Tablo 4. 27. Farklı renk uzaylarında J48 ile başarı oranları | 59 |
| Tablo 4. 28. Farklı renk uzaylarında J48 ile performans sonuçları..... | 59 |
| Tablo 4. 29. Farklı renk uzaylarında Simple Logistic ile başarı oranları | 60 |
| Tablo 4. 30. Farklı renk uzaylarında Simple Logistic ile performans sonuçları..... | 60 |
| Tablo 4. 31. Farklı Gürültü Metotlarının LMT ile başarı oranları | 61 |
| Tablo 4. 32. Farklı Gürültü Metotlarının LMT ile performans sonuçları..... | 61 |
| Tablo 4. 33. Farklı Gürültü Metotlarının J48 ile başarı oranları | 61 |
| Tablo 4. 34. Farklı Gürültü Metotlarının J48 ile performans sonuçları..... | 62 |
| Tablo 4. 35. Farklı Gürültü Metotlarının Simple Logistic ile başarı oranları..... | 62 |
| Tablo 4. 36. Farklı Gürültü Metotlarının Simple Logistic ile performans sonuçları | 62 |

ŞEKİLLER LİSTESİ

Sayfa

| | |
|---|----|
| Şekil 3.1. FEI veri tabanındaki örnek yüz görüntüleri | 24 |
| Şekil 3.2. Kırpılmış örnek yüz görüntüleri | 25 |
| Şekil 3.3. LBP dairesel komşu şeması | 26 |
| Şekil 3.4. Bir piksel için LBP değerin elde edilmesi | 26 |
| Şekil 3.5. Farklı P ve R parametrelerine göre LBP tanımlayıcıları | 27 |
| Şekil 3.6. LBP_{L2R} yöntemi ile örüntü elde etme aşamaları | 28 |
| Şekil 3.7. LBP_{L2R} yöntemi ile farklı renk katmanlarında örüntü elde etme aşamaları | 29 |
| Şekil 3.8. LBP_{T2D} yöntemi ile örüntü elde etme aşamaları | 30 |
| Şekil 3.9. LBP_{T2D} yönteminin herhangi bir piksele uygulanışı | 31 |
| Şekil 3.10. $LBP_{Surface}$ yöntemi ile örüntü elde etme aşamaları | 32 |
| Şekil 3.11. $LBP_{Diagonal}$ yöntemi ile örüntü elde etme aşamaları | 33 |
| Şekil 3.12. Karışıklık Matrisi | 35 |
| Şekil 3.13. Çalışma Diyagramı | 36 |
| Şekil 3.14. RGB'den elde edilen bit sayıları | 38 |
| Şekil 3.15. HSV Renk Uzayı | 39 |
| Şekil 3.16. Tuz ve biber metodunun uygulanışı sonucu elde edilen yeni görüntü ... | 42 |
| Şekil 4.1. LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ örnek LBP yüzleri. (A) Orijinal görüntüler, (B) LBP_{L2R} yüzü, (C) LBP_{T2D} yüzü, (D) $LBP_{Diagonal}$ yüzü, (E) $LBP_{surface}$ yüzü. | 43 |
| Şekil 4.2. LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ yöntemlerine ait Histogramlar. (A) LBP_{L2R} histogramı, (B) LBP_{T2D} histogramı, (C), $LBP_{Diagonal}$ histogramı, (D) $LBP_{surface}$ histogramı. | 44 |
| Şekil 4.3. LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ yöntemlerine ait Histogramlar. (A) LBP_{L2R} histogramı, (B) LBP_{T2D} histogramı, (C), $LBP_{Diagonal}$ histogramı, (D) $LBP_{surface}$ histogramı. | 44 |
| Şekil 4.4. Farklı renk uzaylarına taşınmış resimler | 45 |
| Şekil 4.5. Orijinal veriler ve gürültü metotları uygulanarak elde edilen yeni veriler | 46 |

KISALTMALAR VE SİMGELERLİSTESİ

Kısaltma Açıklama

| | |
|-------------|-----------------------------------|
| GLCM | : Grey Level Co-occurrence Matrix |
| LBP | : Local Binary Pattern |
| LDA | : Linear Discriminant Analysis |
| LMT | : Logistic Model Tree |
| LR | : Logistic Regression |
| YİÖ | : Yerel İkili Örüntü |
| HMM | : Hidden Markov Model |
| ANN | : Artificial Neural Network |
| KNN | : K En Yakın Komşu |
| CS | : Cinsiyet Sınıflandırma |
| CNN | : Convolutional Neural Network |

Simge Açıklama

| | |
|----------|-------------------|
| μ | : Ortalama sonucu |
| σ | : Sigma |
| π | : Pi |

ÖZET

YÜKSEK LİSANS TEZİ

YÜZ İFADELERİNDEN CİNSİYET, DUYGU VE YAŞ TAHMİNİ İÇİN YENİ YAKLAŞIMLAR

Ali YILMAZ

Siirt Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman : Dr. Öğretim Üyesi Yılmaz Kaya

2019, 71 Sayfa

İmge işleme ile yüz görüntüleri üzerinde yapılmış ve yapılmakta olan birçok çalışma mevcuttur. Günümüzde doku analizi ile ilgili çalışmalar her geçen gün artmakta ve popüler bir çözüm sunma yolunda hızla ilerlemektedir. Bu çalışmada, kişilere ait yüz görüntülerinden yaş, cinsiyet ve duygu tahmini için klasik teşhis yöntemlerine alternatif olarak bilgisayar görü tabanlı dört farklı yeni yöntem önerilmiştir. Duygu, yaş ve cinsiyet sınıflandırma işleminde FEI veritabanına ait yüz resimleri kullanılmıştır. Çalışmada renkli yüz görüntülerinden etkili özellikler çıkarmak için yerel ikili örüntüler (Local Binary Pattern=LBP) tabanlı dört farklı yeni yaklaşım önerilmiştir. Önerilen yöntemler renkli görüntüler için kullanılmaktadır. Yapılan çalışmada verilerden en iyi sınıflandırmayı elde etmek için veriler farklı renk uzaylarına taşınmış ve verilere farklı gürültü metotları uygulanmıştır. Sınıflandırma işlemindeki başarı oranlarının tespiti iki aşamada gerçekleştirilmiştir. Birinci aşamada öznelilikler elde edilmiş, ikinci aşamada ise bu öznelilikler farklı makine öğrenmesi yöntemleri kullanılarak 10-katlı çapraz geçerlilik testi ile sınıflandırma işlemi gerçekleştirilmiştir. Çalışma sonunda cinsiyet sınıflandırmada %99, yaş sınıflandırmada %99,5 ve duygu sınıflandırma da %97,5 gibi yüksek sınıflandırma başarı oranları elde edilmiştir.

Anahtar Kelimeler: Yerel İkili Örüntüler, Görüntü İşleme, Yaş Tahmini, Duygu Tahmini, Cinsiyet Tahmini

ABSTRACT

MS Thesis

NEW APPROACHES FOR GENDER, EMOTION AND AGE PREDICTION FROM FACIAL IMAGES

Ali YILMAZ

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SIIRT UNIVERSITY**

**THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL-ELECTRONICS ENGINEERING**

Supervisor : Assist. Prof. YILMAZ KAYA

2019, 71 Pages

There are many studies that are done and made on face images by image processing. Nowadays, studies on tissue analysis are increasing day by day and are progressing rapidly to provide a popular solution. In this study, four different new methods based on computer vision have been proposed as an alternative to the classical diagnostic methods for age, gender and emotion estimation. Emotion, age and gender classification process used face images of the FEI database. Four different new approaches based on Local Binary Pattern (LBP) have been proposed to extract effective features from color facial images. Recommended methods are used for color images. In order to obtain the best classification from the data, data were moved to different color spaces and different noise methods were applied to the data. The determination of the success rates in the classification process was carried out in two stages. In the first stage, the attributes were obtained and in the second stage, these attributes were graded by 10-fold cross validation test using different machine learning methods. At the end of the study, 99% of the gender classification, 99.5% in the age classification and 97.5% in the emotion classification were achieved.

Keywords: Local Binary Pattern, Image Processing, Age Estimation, Emotion Estimation, Gender Estimation

1. GİRİŞ

İnsan varlığından bu yana duygu aktarımı ve iletişim için yüz ifadeleri en güçlü etkiye sahiptir. Bunu otomatik olarak algılamaya, tanımlamaya ve sınıflamaya evrimleşmiş olan beynimiz gibi sistemlerin tasarlanması için çeşitli yöntemler ve algoritmalar geliştirilmektedir. İnsanlar arası iletişimde duygulara mana bütünlüğü kazandıran evrensel işaretleri yüz ifadeleri olarak adlandırılmaktadır. Yüz ifadeleri duygu psikolojisinde de en önemli ipuçları olarak kabul görmüş araçlardır. İnsana ait davranış analizlerinde, insanın kendisi ile olan etkileşimi ve insanın bilgisayar ile olan etkileşimi gibi çok geniş bir uygulama yelpazesine sahip olan da yine yüz ifadeleridir. Yüz ifadeleri şeklinde ortaya çıkarak insanlar ve hayvanlarda doğuştan gelen bazı duygular olduğunu ve bu ifadelerin evrensel olarak aynı anlamda algılandığını belirterek, yüz görüntülerinden elde edilen ifadelerin evrensel olduğu vurgulanmıştır (Darwin ve Philip, 1998). Yüz ifade analizi birçok davranış bilimci için çalışmalarının dayanağını oluşturmuş ve geniş yelpazeli bir araştırma konusu haline gelmiştir. Karşılıklı iletişimin temel yapı taşlarını içinde barındıran yüz ifadeleri kişiler arasındaki iletişimin tamamında %55 oranı gibi bir yüksek değerde etkili olurken; insan ses tonundan elde edilen başarı oranı %38 ve en düşük etkiye sahip olan ise kelimeler olup sadece %7'lik bir etkiye sahiptir (Mehriban, 1968).

Üç temel adımdan oluşan yüz ifade analizinde ilk adım olarak yüz bulunur. İkinci adımda yüze ait görüntüden farklı yüz ifadelerine ait öznitelikler çıkartılır ve en son adım olarak da yüze ait ifadenin algılanması olmak üzere üç adımdan oluşmaktadır. İlk olarak kişiye ait yüz bulunur. Bu adımda giriş görüntülerinden yüz görüntüsünün belirlenmesi veya görüntü dizgilerinden, ilk karede insan simasının algılanması sağlanarak geriye kalan karelerden yüze ait görüntülerin izlenmesi şeklinde olmaktadır. Görüntülerden elde edilen insan simalarındaki ifadeleri tanımlayabilmek için insan simasına ait ifadelerin taşıdığı öznitelikler elde edilir doğal olarak bu işlem yüz bulunduktan sonraki süreçtir. Yüz üzerinde özellikle yüzün belirli bölgelerinde oluşan biçimsel farklılıklar ile ortaya çıkar yüz ifadeleri.

Otomatik yüz ifade analizini karmaşıklaştıran başlıca sebepler şunlardır: kozmetik olarak kullanılan ürünler, sakal yapısı ve yoğunluğu-bıyık şekli, saç uzunluk-kısalığı ve burun-göz ile yüzün bir kısmını kapatan gözlük gibi nesnelerin varlığı ya da cinsiyet, yaş, etnik köken gibi farklılıkların varlığı. Ayrıca çeşitli çalışmalarda

kullanılan yüz görüntüleri çoğu zaman kamera merceğinin yakaladığı o anlık poz durumu veya aydınlatmadan doğan farklılıklar nedeniyle de olduğundan daha başka görünebildiğini bizlere sunmuştur çeşitli araştırmacılar. Yüz ifadelerinin tanınmasını zorlaştıran bazı etmenler de şunlardır; ilk olarak görüntüyü elde etmek, görüntüyü elde ederken meydana gelen boyut değişimi ve görüntü üzerinde meydana gelen çözünürlük değişimi gibi problemler de yüz görüntülerine ait ifadelerin tanınırlıklarını zorlaştırmaktadır. Bütün bu varyasyonlarda otomatik yüz ifadesi analizi sistemine ait değişik varyasyonlarda ele alınması gerekmektedir (Fasel ve ark., 2003).

Yüz ifadelerini tanıma çalışmalarının temelini oluşturan başlıca etmenler şunlardır; yüz kaslarında meydana gelen kasılmayla; kaşlardaki uzunluk ve en değişimi, göz çevrelerindeki daralma ve genişlemeye bağlı olarak gözün büyümesi ve küçülmesi, burun, iki dudak arasındaki mesafe ile dudaklardaki genişliğinin değişimi ve çene bölgelerinde meydana gelen değişimler ile ciltte meydana çıkan bu kalıcı olmayan değişimlerin belirlenmesi ve ölçülmesidir. Yüz görüntülerine ait öznitelikleri belirlemek için birçok araştırmacının kullandığı iki popüler yöntem vardır. Bu yöntemlerden ilki Geometrik-tabanlı yöntem ve ikincisi ise Görünüm-tabanlı yöntemlerdir (Kumaria ve ark., 2015). Bu iki yönteme ek olarak her iki yaklaşımın birlikte kullanıldığı hibrit yöntemler de kullanılmakta olan mevcut metotlardır (Zhang ve ark., 2012).

Kullanılan yüz görüntüsü üzerinden elde edilen ifadeye göre türetilen değerlerine göre yüz ifadesinin tanınması ya da ifadenin sınıflandırma işlemi yüz ifadesi analiz çalışmalarının son aşamasında gerçekleştirilir. Yüze ait ifadelerin incelenmesi ile sözlü ve sözlü olmayan iletişimin yanı sıra psikolojik araştırma gerektiren konularda, insanın çevresi ve bilgisayar ile olan etkileşiminde, bilgisayarlı görüde ve akıllı sistemler gibi geniş bir alanda önemli bir yer edinmiştir. Şizofren hastaların duygu değişimleri ve psikolojik durumlarının belirlenip ilgili durumlarına göre gerekli tedbirlerin alınmasında yüz ifade analizi ile ilgili çalışmalar kullanılmaktadır (Alvino ve ark., 2007; Mandal ve ark., 1998; Abdenour ve Matti, 2009). Hırsızlık vakalarına karşı ve art niyetli insanlara karşı kişilerin kendilerini güvende hissetmelerini sağlamada ayrıca yüz ifade analizinden faydalanılmaktadır

(Butalia ve ark., 2012). İletişim kurma becerisinden yoksun olarak doğan bebeklerde meydana gelen ağrı tespitinde yüz ifadeleri kullanılmıştır (Lu ve ark., 2008). Ayrıca sürücülerin uykulu olma durumları yorgunluklarının algılamasında (Hachisuka, 2013), güvenli sürüş davranışlarının tahmin edilmesinde (Jabon ve ark., 2011) ve otomatik

müzik çalma listesi oluşturmada (Dureha, 2014) yüz ifadelerini kullanan çalışmalar vardır.

Günümüzde bilişim sistemlerinde de popüler bir araştırma konusu olmaya başlamış konulardan biri de insan psikolojisinin anlaşılmasına dayalı çalışmalardır. Yüz yüze iletişimde bile insanlar tarafından çok kolay analiz edilemeyen psikolojik ifadelerin bilgisayar ortamında test edilip belirlenmesinin ne kadar zor olabileceği tahmin edilebilmektedir. Bunun dışında görüntülerde ekli olan arka plan manzaraları da görüntüdeki yüzlerin tespitini zorlaştırmaktadır (Tenekeci ve ark., 2017).

Her geçen gün daha hızlı gelişip büyüyen teknolojik gelişmelere paralel olarak eğitimde yeni atılımlar yapılmakta ve uzaktan eğitim sistemleri yaygın hale gelmektedir. Gelişen uzaktan eğitim sistemlerinin daha verimli hale gelebilmesi için teknoloji ile birlikte bu sistemin ikinci ve üçüncü ayaklarını oluşturan öğretici ve öğrenci etkileşimi çok önemlidir. Özellikle öğretici, öğrencinin ruhsal yapısını ve anlatılanlara öğrencinin bakışını duygu analizi yardımı ile ulaşabilir. Öğrencinin anlatılanlardan önce ve sonraki yüz görüntülerinin bir duygu analizi sistemi sayesinde belirlenip öğreticinin anlatım yöntem ve tekniklerinde değişime gitmesine yardımcı olur bu da uzaktan eğitim sistemlerinin daha verimli hale gelmesine yardımcı olur.

Yüz görüntülerini işleme, son yıllarda birçok araştırmacı tarafından incelenen bir araştırma konusudur. Yüz tanıma, yüz ifadesinin tespit edilmesi, cinsiyet sınıflandırma ve yüz özelliklerinin çıkartılması bu alandaki araştırmaların sonuçlarıdır. Adli tıpta ve kriminolojide cinsiyetin ve yaşın belirlenmesi büyük önem taşımaktadır. Yüz tanıma, geniş potansiyel uygulamaları nedeniyle son yıllarda büyük ilgi görmüştür. Geçtiğimiz yıllarda, desen tanıma bilgisayar vizyonunda en aktif alanlardan biri olmuştur. Yüz tanıma için birçok yöntem önerilmiş ve bunların çoğu yüz tanıma görevine başarıyla uygulanmıştır, ancak tüm yöntemlerin bazı dezavantajları vardır. En büyük zorluklardan biri yaşlanma problemi, yani test yüzü ile sorgulanan yüz arasındaki yaş farkının çoğu algoritmanın performansını önemli ölçüde azaltmasıdır (Phillips ve ark., 2003).

Herhangi bir bireye ait adli tıpta veya kriminolojide kimlik tespiti için başvuru alan ilk özellikler cinsiyetinin ne olduğu ve yaşı ile ilgili veriye ulaşılmasıdır. Kaybolmuş kişilerde zamana bağlı olarak meydana gelen değişimlerin bir tahmini modellenmesinin yapılarak ileri veya geriye dönük görüntülerinin tespiti için önem taşımaktadır. Özellikle suçluların ya da kaybolan çocukların güncel zamandaki görüntülerinin oluşturulması açısından dikkat çekicidir. Bu çalışmalar mevcut bir veritabanında bulunan görüntülerin güncelleştirilmesi amacıyla da kullanılabilir. Bu

şekilde veritabanındaki görüntüler her zaman kişilerin güncel görüntüleri olacaktır (Lanitis ve ark., 2004).

Yaş tahmini kişinin yüz görüntüsünden elde edilen bilgilerle yaşının 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 başarıyı 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. (Sai ve ark., 2015). Yaş belirlenirken karşılaşılan en önemli zorluk kişilerin gerçek yaş ile tıbbi yaşları arasında meydana gelmiş farklılıklardır ki bunun da temel sebebi çeşitli dış faktörler ve patolojik süreçlerdir. Yaş belirlenirken kişinin fiziksel ve biyolojik gelişimi dikkate alınmalıdır. Kişi yaşı belirlenirken yaşamını geçirdiği coğrafya koşulları, doğuştan gelen özellikleri, hastalık durumu, maruz kaldığı stres faktörünün etkileri oldukça büyüktür. Yaşam koşulları ve yaşanan süre miktarı ilerledikçe kişilerin gerçek yaşı ile tıbbi yaşı arasındaki fark artmaktadır. Takvim yaşı ile tıbbi yaş arasında meydana gelen yaş farkından dolayı bu işin ehli uzmanların bile yaş tahmininde 10 yıla kadar hata yaptıkları olmuştur (Valinskiy, 1999).

Kişilerde yaş faktörüne paralel olarak vücudu oluşturan çeşitli organlarında büyümeler meydana gelmektedir. Boyda uzunlama, göğüs kafesinin genişlemesi, baldır dairelerinde meydana gelen değişimler, baş çevresinin genişlemesi ve insan iskeletini oluşturan çeşitli kemiklerin boyutlarının ölçülmesi yaşın belirlenmesinde yardımcı olmaktadır. İnsandaki deri örtüsünün yapısından ve deride meydana gelen başkalaşımdan da yaşın belirlenmesi konusunda faydalanılmaktadır. Yaşın ilerlemesine paralel olarak deride meydana gelen elastiklik kaybı, deride meydana gelen su kayıpları

sonrası derinin kuruması, meydana gelen kuruma etkisi ile deri renginin değişmesi gibi değişiklikler görülmektedir. 20'li yaşlarda alında oluşmaya başlayan kırışıklıklar, burunda meydana gelen büyüme ile dudak kısmındaki değişimler, 25 yaşında gözlerin dış açılarında oluşmaya başlayan değişimler, gözlerin alt kısımlarında 30 yaşından sonra oluşmaya başlayan değişimler, 35 yaşında boyunda öne çıkan değişimler, 55 yaşında kulaklarda, yanaklarda ve dudaklarda kırışıklıklar oluşmaya başlar. Takvim yaşı ilerledikçe ortaya çıkan kırışıklıklar büyür ve derinleşmeye başlar.

Anlatılanlardan yola çıkarak yaşın belirlenmesinde biyometrik özelliklerin öne çıktığı görülmektedir. Bu çalışmadaki amaçlardan biri ise yaşın insanlara ait yüz görüntülerinden elde edilmesidir. Yaşa bağlı oluşan görünüş farklılıkları yüzde meydana gelen diğer değişikliklerle karşılaştırıldığında benzersiz bir karakteristik gösterir ve buda oluşturulan modelleri kötü yönde etkiler. Model oluşturma sırasında karşılaşılan güçlükler yaşlanmanın her insanda farklı olması, yaşlanma ile birlikte ortaya çıkan değişimin sağlık durumuna, yaşanan coğrafyaya ve o coğrafyadaki iklim şartlarına bağlı olması ve yaşlanmanın meydana gelirken ilerleme hızının yavaş olan bir olay olması nedeniyle model oluşturma sırasında kullanılacak uygun verilerin toplanmasının zor oluşudur (Günay ve Nabiyev, 2011).

1.1. Yaş Tahmin 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 özniteliklerin çıkarılmasıdır. Daha sonra bu öznitelikler 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 öznitelikler yalnızca küçük yaşlardaki kişiler için belirleyici olduğundan, daha yaşlı kişilerin sınıflandırma başarımını arttırmak için geometrik özelliklere ek olarak kırışıklık özellikleri kullanılmıştır (Dehshibi ve ark., 2010).

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. Fakat AAM'ler, yaşlı insanlar için yüzdeki kırıxıklık bilgisini iyi bir şekilde kodlayamaz. Çünkü AAM yöntemi, görüntüdeki parlaklık değerlerini, doku örüntüsünü hesaplayacak uzaysal bir komşuluk dikkate almadan kodlar. Daha yaşlı yetişkinlerin yüzlerindeki kırıxıklıkları ifade etmek için yerel bölgelerin incelenmesi gerekir. Bu nedenle bazı çalışmalarda, yüz görüntülerinden global öznitelikler AAM ile çıkarılmış ve yerel özniteliklerle birleştirilerek daha etkin yaş tahmini sistemlerinin tasarlanması hedeflenmiştir (Chao ve ark., 2013).

Yaşlanma örüntüsü alt uzayı (Aging Pattern Subspace-AGES), yaşlanma sürecinin modellenmesinde bir kişinin farklı yaşlardaki görüntülerinin dizisini kullanan bir yöntemdir (Geng, 2007). 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 sayıdaki resimden yaşlanma eğilimini öğrenmek için, verilerin daha küçük boyutlu bir topolojik uzaya gömülmesinden (manifold embedding) yararlanılır (Fu ve ark., 2008). 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 öznitelik çıkarma yöntemleri (Appearance Models), yüz görüntülerinin bütününden genel olarak ya da çeşitli sayıdaki bloklardan yerel olarak, yaşlanma ile ilişkili özniteliklerin 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 öznitelikleri 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 (Choi ve ark., 2011; Liu ve ark., 2014).

Yukarıda bahsedilen çalışmalar incelendiğinde genellikle öznitelik çıkarma aşamalarında tüm yüzün kullanıldığı görülmektedir. Bu tez çalışmasında aşağıda metot kısmında belirttiğimiz şekilde yerel ikili örüntüler (Local Binary Patterns- LBP) odaklı LBP_{L2D} , LBP_{L2R} , $LBP_{surface}$, $LBP_{diagonal}$ yöntemleri kullanılmıştır.

İnsan yüzleri cinsiyet algılaması için önemli görsel bilgiler sağlar. Yüz imgelerinden cinsiyet sınıflandırması, son yıllarda çok yaygın bir alan olmuştur. Cinsiyet sınıflandırma (CS) yüz analizinin en önemli görevlerinden biridir. CS, çeşitli bilgisayar görü uygulamalarında önemli bir yer tutmaktadır. Bu çalışmada CS için yerel ikili örüntüler tabanlı dört farklı öznelik çıkarım yaklaşımı önerilmiştir. Önerilen öznelik çıkarım yaklaşımları renkli görüntüler için kullanılmaktadır.

Bilgisayar kullanarak kişilerin yüz görüntülerinden cinsiyetini, yaşını ve etnik kökenini tanımlamak son yıllarda popüler bir çalışma alanı olmuş ve insanların son derece ilgisini çekmektedir (Siyao ve ark., 2014). Cinsiyet, yaş ve etnik köken gibi bu özellikler, insan-bilgisayar etkileşimi, gözetleme, içerik tabanlı endeksleme ve arama, biyometri, demografik çalışmalar ve hedefli reklamcılık gibi birçok uygulamada önemli bir rol oynayabilir. Çalışmalar, bir insanın erkek mi kadın mı olduğunun kolayca ayırt edilebildiğini göstermiştir, ancak bu bir makine için zordur. Cinsiyet sınıflandırmak için makine tarafından kullanılan erkek ve kadın arasında bazı ayırt edici özellikler vardır. Cinsiyet tanıma, bir desen tanıma problemidir. Desen tanıma iki parçaya bölünebilir, bunlara bir ve iki aşamalı desen tanıma sistemleri denilir. Tek aşamalı model tanıma sistemi, giriş verilerini doğrudan sınıflandırır. İki aşamalı desen tanıma sistemleri, sınıflandırıcı ile özellik çıkarıcıdan oluşur. Yüz özelliklerine ek olarak, göz, burun, ağız vb. Gibi irksal özellikler de cinsiyet sınıflandırması için kullanılmaktadır. Yapay zekada görüntü işleme ve makine öğrenimi çok önemli bir rol oynar ve yüz tanıma, jest tanıma, yüz ifadesi tanıma ve cinsiyet sınıflandırması gibi zor işleri gerçekleştirir (Lu ve ark., 2009).

Genel olarak sınıflandırma işlemi şu adımlardan oluşmaktadır:

Ön İşleme: ön işlemede aydınlatma, pozlar ve yanlışlıklar gibi varyasyonları azaltır. Birçok Sınıflandırıcı varyasyonlara duyarlıdır. Bu hassasiyeti azaltmak için bazı ön işlem adımları gerçekleştirilir.

Özellik Çıkarma: Ön işleme sonucu elde edilen veriden özellik çıkarılan kısımdır.

Boyut Ayarlama: Özellik çıkarımı sonucu elde edilen yeni özelliklere göre yeniden resimlerde boyutlandırma işleminin yapıldığı kısımdır.

Sınıflandırma: Verilerin çeşitli yöntemlerle kategorize edildiği ulaşılmak istenenin elde edildiği kısımdır.

Sosyal aktiviteler ve iletişimde, cinsiyet sınıflandırmanın önemli bir rolü vardır. Günümüzde, cinsiyetin otomatik olarak sınıflandırılabilmesi çok faydalı ve büyük uygulama alanı potansiyeline sahiptir. Sinema, bina girişleri ve restoran gibi

mekanlarda müşteri istatistikleri ve güvenlik taraması gibi alanlar otomatik cinsiyet tanıma işlevinin kullanım alanlarına örnek olarak verilebilir (Khorsandi ve Abdel-Mottaleb, 2013).

1.2. Duygu Analiz Yöntemleri

Yüz ifadelerinin tanınması konusunda Literatürde çeşitli çalışmalar yapılmış olmakla birlikte geniş bir araştırma yelpazesini halen içinde barındırmaktadır. Genel olarak yüz ifadesi analizine ait çalışmalar 19. Yüzyıla dayanmaktadır. İnsan doğuşu ile birlikte bazı duygularında kendisi ile doğuştan geldiğini öne sürerek, yüz ifadelerinin evrensel olduğuna ve bu ifadelerin kesintisiz olduklarını iddia etmiştir (Darwin, 1872). Her birisinin kendine has içeriğe sahip altı temel duygu olduğunun yanı sıra birbirinden farklı yüz ifadelerinin de olduğundan bahsetmişlerdir (Paul, 1971). Yüz görüntülerinden yüze ait ifadeleri belirlemek için yüz anatomisine dayalı eylem birimlerini (AUS-Action Units) kullanarak yüz ifadelerini kodlama sistemi Facial Actions Coding Systems (FACS) sistemini geliştirmişler ve yüze ait birbirinden ayrı 46 farklı eylem birimi tanımlamışlardır ve bu işlem her bir kas aktivitesine karşılık gelecek şekilde ayarlanmıştır. Yüzdeki kaslarda meydana gelen hareketleri temel alarak çalışan tarafsız bir yöntem olan FACS sayesinde 7.000'den farklı eylem birimlerinin kombinasyonu gözlemlenmiştir (Scherer ve ark., 1971). Yüz ifade analizinde kullanılan çeşitli metotlara aşağıda kısaca değinilmiştir.

Optik Akış Hesaplama bu yaklaşımın dayanak noktası şudur; hesaplama kısmına dahil edilenler yüze ait başlıca bölgelerin görünüm olarak izlenmesi ve yüksek yoğunluklu eğim noktalarına ait akışlardır. Optik akış hesaplaması görüntüdeki yüz ifadelerinin neden olduğu hareketlerin yönünü belirlemekte kullanılır. Belirlenen bölgelerdeki yüze ait hareket şekillerinin istatistiksel karakterizasyonuna dayalı olduğundan, yüz özniteliklerini içine alan dikdörtgenler için bir bölge izleyici geliştirilerek tek tek nokta hareketlerinin izlemenin önüne geçilmiştir. Farklı yüz özniteliklerine ait hareketlerin bölge içindeki akış hesaplamalarına karışmaması için her dikdörtgen, ilgili bir özelliği çevrelemiştir.

Saklı Markov Modeli (HMM-Hidden Markov Model) Tsapatsoulis ve arkadaşları zaman ölçeği değişmezliğini sağlamak ve zaman sıralı veriler ile başa çıkmak için Saklı Markov Modeli temelli bir ifade tanıma metodu önermişlerdir. Önerdikleri teknikte bir özellik vektör dizisi kullanılmıştır. Bunun temel sebebi hareket

alanının yönlü filtrelenmesi ve optik akış çıkarımıdır. HMM'nin öğrenme yeteneğinden bilinmeyen özniteliklere ait vektörel dizilerinin sınıflandırılmasında uygun bir seçim yapmak için faydalanmışlardır.

Zhang, özellik tabanlı 2 katmanlı bir algılayıcı mimari içinde yüz ifadelerini algılama sistemini yaptığı çalışmalar sonucunda ortaya çıkarmıştır. Çok yönelimli ve çok ölçekli Gabor dalgacık katsayıları dizisini kullanarak yüz görüntülerinden elde edilen bir kısım öznitelik kullanarak referans noktalarının geometrik konumları sayesinde bu noktalardaki yüz ifadelerini tanımayı amaçlamıştır. Elde edilen öznitelikler ile farklı bu iki kullanım birbirinden bağımsız olabileceği gibi ikisi bir olarak da gerçekleştirilebilir. Gabor dalgacık katsayılarının geometrik pozisyonlara göre farklı türdeki özellikleri tanıma performansı karşılaştırıldığında ise; çok daha güçlü olduğu görülmüştür.

Weixing ve ark. (2014) kişiler ait görüntülerden yola çıkarak yeni bir yaklaşım önererek ifade tanımayı amaçlamışlardır. İlk adımda Yerel İkili Örüntü (Local Binary Pattern-LBP) operatörünü kişilerin görüntülerini etkin bir şekilde ifade etmek için kullanmışlar, daha sonra yüz ifadelerini sınıflandırmak için Lineer Programlama (LP-Linear Programing) tekniğini uyarlamışlardır.

Martins ve ark. (2008) yaptıkları çalışmalarında Aktif Görünüm Modeli (AAM) ve Lineer Diskriminant Analizini (LDA) birleştiren yeni bir model sunmuşlardır. AAM modeli kullanılarak sisteme ilk olarak insan yüzü tanımlanmakta sonrasında ise LDA ile tanımlanan her bir görünüm vektörü Fisher uzayına yansıtılarak farklı ifade kategorileri belirtilmiştir. En sonunda ise Mahalanobis mesafesi esas alınarak yüz ifadelerini sınıflandırma işlemi yapılmıştır.

Chen ve ark. (2011) görüntüden yüzdeki ifade analizi için kullandıkları yaklaşım kenar algılama algoritmasına dayalı bir yaklaşımdır. Bu çalışmada, görüntülerden gözler ve dudaklar tespit edilip işaretlenerek kenar şekil özellikleri çıkarılmıştır. Çalışmada ten rengi modeli kullanılmıştır. Yapılan çalışmada Canny, Laplace, Sobel ve Robert operatörleri birbirleri ile karşılaştırılarak bu operatörler hakkında şu sonuçlara ulaşılmıştır. Laplace ve Sobel operatörleri belirsiz iken Robert operatörü basit, Canny operatörü ise kenar belirlemede karmaşıktır.

Neoh ve ark. (2015) yaptıkları çalışmalarında katmanlı kodlama kaskad optimizasyon modeli ile görüntüden ifade analizi konusunda çalışmışlardır. Duygu tanıma başarısı için etkili bir yüz gösterimi çok önemli bir aşama olduğundan, birincil olarak Yerel Gabor İkili Desen (Local Gabor Binary Pattern) operatörü kullanılarak yüz

görünümünü elde etmeye çalışmışlardır. Doğrudan Benzerlik ve Pareto-Tabanlı Özellik Seçimi algoritmalarını önererek özellik optimizasyonunda kullanmışlardır. Ayrıca bu algoritmalar sistemlerindeki katmanlı kaskat modeli altında bulunur. Farklı ifade kategorilerini en iyi şekilde temsil eden ve bununla birlikte diğer ifadeler ile en belirgin farkları ortaya koyan özellikler Pareto-tabanlı özellik optimizasyonunun üzerinde durur.

1.3. Cinsiyet Analiz Yöntemleri

İmge işlemede temel olarak özellik çıkarımı ön plana çıktığından dolayı yaş, duygu, cinsiyet ve benzeri tahminleme işlemlerinde aynı metotlardan faydalanılabilmekte ve genel itibari ile birbirine yakın başarı oranları elde edilmektedir. Cinsiyet tanımada da duygu ve yaş tanımada kullanılan yöntemlerin yanı sıra aşağıda yaş ve duygu analizinde de kullanılan çeşitli yöntemlere kısaca değinilmiştir.

Derin Sinir Ağları 2000'lerin başında konuşma tanıma işleminde, ileri beslemeli yapay sinir ağları gibi geleneksel yaklaşımlar hakimdi. Ancak konuşma tanımada derin öğrenme yöntemi, 1997 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından yayınlanan bir tekrarlayan sinir ağı tarafından bugün yaygın kullanıma sahiptir. Derin bir ileri beslemeli sinir ağı (Deep Neural Network), girdi ve çıktı katları arasında çok sayıda gizli katman içeren yapay bir sinir ağıdır. Sığ sinir ağlarına benzer şekilde, DNN'ler karmaşık doğrusal olmayan ilişkileri modelleyebilir. DNN mimarileri, alt katmanların özelliklerinden kompozisyona olanak tanıyan kompozisyonel modeller üretir, böylece büyük bir öğrenme kapasitesi ve böylece cinsiyet tahmini için kullanılan verinin karmaşık modellerini modelleme potansiyeli sağlar.

Viola-Jones algoritması; örüntülerden yüz, göz, burun ve ağız bölgelerini tespit etmek amacıyla 2001 yılında Viola ve ark., tarafından ortaya çıkarılmış bir yöntemdir. Kullandığı Haar öznelikleri ile yüz bölgesi içeren ve içermeyen veriler kullanılarak, önceden eğitilen bir sınıflandırıcı yardımıyla bu bölgelerin tespitini yapar. 1 saniyenin altındaki cevap süresiyle oldukça kullanışlı bir algoritmadır. Bununla birlikte, örüntü üzerinde tespit edilen hatalı alanlar algoritmanın bir dezavantajı olarak görülebilir.

Hali hazırda kullanılmakta olan makine öğrenmesi algoritmaları içinde en basit olanı KNN algoritmalarıdır. Bu algoritma, olasılık yoğunluklarının güvenilir parametrik tahminlerinin bilinmediği ya da belirlenmesinin zor olduğu zaman, ayrıştırma analizine duyulan ihtiyaçtan dolayı geliştirilmiştir. Örüntü sınıflandırma için ilk olarak 1951 yılında Fix ve Hodges tarafından KNN metodu tanımlanmıştır. Bu algoritmada ait olduğu sınıfın belirlenmesi istenen örnek için en yakın k tane komşuluklarına bakılır.

Burada k tektir ve tamsayıdır, k sayısı için mümkün oldukça küçük deęerler seęilir. k 'nın deęerinin 1'e eřit olduęu durumda, test edilecek örneęin en yakın komsusuna bakılır ve en yakın komşu hangi sınıftan ise test örneęi de aynı sınıftandır denir. Eęer k sayısı 3 ise, bu sefer test örneęinin en yakın 3 komşusuna bakılır ve çoęunluk hangi sınıftan ise test örneęi de o sınıftandır denir.



2. LİTERATÜR ARAŞTIRMASI

İmge işleme üzerine yapılan çalışmalar günümüzde çok geniş bir çalışma alanı elde etmiş ve her geçen gün popülaritesi artmaktadır. Bilimsel birçok alanda üstün başarılar elde edilmiş ve araştırmacıların sürekli yeni yaklaşımlar sunması ile başarısını arttıran imge işleme sayesinde hayatımızda birçok alanda kolaylık sağlanmıştır. İmge işleme ile kişilere ait yüz görüntüleri üzerinde yapılmış ve yapılmakta olan birçok çalışma mevcuttur. İmge işleme ile tıp, endüstri, savunma sanayi, sanayi çalışmalarının yanında kişilere ait yaş, cinsiyet, duygu analizi vb. niteliklere ulaşılmaya çalışılmaktadır. Bu tez çalışmasında daha önce yapılan çalışmaların aksine görüntü işleme ile kişilerin duygu analizi, yaş ve cinsiyet tahminleri ve sınıflandırmaları bir bütün olarak ele alınmıştır. Birey bir bütün olarak düşünüldüğünde bireye ait özellikleri birbirinden ayırıp incelemek yerine bir bütün halinde ele alıp incelemek bize kişi hakkında en gerçekçi bilgileri sunmaktadır. Birçok araştırmacı yüz görüntüleri kullanarak imge işleme ile kişilere ait yaş, cinsiyet, duygu analizi gibi tahmin ve sınıflandırma işlemlerini farklı metot ve yöntemlerle yapmıştır. Bu tez çalışmasında yüz görüntülerinden öznitelik vektörleri oluşturmak için yerel ikili örüntüler tabanlı 4 farklı yaklaşım önerilmiştir. Önerilen yaklaşımlar renkli görüntüler kullanan metotlardır. Bu bölümde sırasıyla cinsiyet tahminleme işlemi ile ilgili yapılan çalışmalar, duygu analizi konusunda yapılan çalışmalar ve yaş tahmini ile ilgili yapılan çalışmalar aşağıda verilmiştir.

2.1. Cinsiyet Tahmini ile İlgili Çalışmalar

Gutta ve ark. (1998) imge işleme ile cinsiyet tahmini yapan çalışmaların ilklerinden birini büyük bir veri kümesini kullanarak yapmışlardır. Veri tabanı olarak 1009 deneğe ait 3006 görüntü içeren FERET veri tabanı ile çalıştılar. RBF (Radial Basis Function) ağları ve C4.5 (J48) karar ağaçları topluluğu kullanılmıştır. Çapraz doğrulama kullanan 1009 deneğin 3006 görüntüsünün veri kümesinde %96 doğruluk elde etmiştir. Aynı kişi hem eğitim hem de test setlerinde görünebilirdi, bu da sistemin cinsiyet yerine yüzleri tanımayı öğrenebileceği anlamına geliyordu. Görüntüler elle parçalara ayrılmış ve 64x72 piksel olarak normalize edilmiştir.

Moghaddam ve Yang (2002) yaptıkları çalışmalarında FERET veri tabanını kullanmışlardır. Çeviri, ölçek ve hafif rotasyonları telafi eden otomatik bir yüz işleme

sistemi kullanmışlar. Görüntüleri 21x12 piksele kadar örneklendirdiler. Değerlendirmede 5 kat çapraz doğrulama kullanılmıştır. Sunulan doğruluk oldukça yüksek (% 96.62) çıkmasına rağmen deneyler aynı kişilerden birden fazla görüntü kullanılarak yapıldığı için Gutta ve ark., (1998)'nin karşılaştığı aynı problemin ortaya çıkmasına sebep olmuştur.

Jabid ve ark. (2010) tarafından Uluslararası Örüntü Tanıma Konferansında yayınlanan çalışmalarında FERET veri tabanı kullanılarak örüntü tanıma metodu ile 2000 adet yüz görüntüsünden (1100 bay-900 bayan) cinsiyet sınıflandırma işlemini karar destek vektörleri kullanılarak LDP (Local Directional Pattern) ve klasik LBP (Local Binary Pattern) metotları kullanılarak yapılmıştır. LDP ile yapılan sınıflandırma işleminde LBP metoduna oranla daha yüksek başarı yüzdesi elde edilmiştir. Yapılan çalışmada LDP yöntemi ile en az %92'lik bir doğru sınıflandırma başarısı elde edilirken bu oran LBP metodunun ulaştığı en yüksek değer olmaktadır.

Hadid ve Matti (2009) tarafından yapılan bir çalışma da psikolojik ve nöral çalışmaların kişilerin konuşurken veya kafalarını hareket ettirirken değişen yüz ifadelerinin cinsiyet ve yüz analizleri için birer dinamik işaret oluşturduğunu göstermektedir. Bu çalışmada hareketli videolardan yüz görüntüleri elde edilerek cinsiyet tahmini yapılmaya çalışılmıştır. Bu çalışmada kullanılan üç farklı veri tabanı mevcuttur. Birinci veri tabanı olarak MoBo(Motion of Body) video veri tabanından koşu bandı üzerinde hareketli 24 farklı kişinin 96 yüz dizisi kaydedilmiş. Her bir dizi 300 kareden oluşur. Görüntüler yeniden boyutlandırılarak 40x40 piksellik yeni görüntüler elde edilmiştir. İkinci veri tabanı olarak Honda / UCSD veritabanından kabul edilen alt grup, 20 farklı bireyden oluşan 40 video dizisi içerir (iki video konuşan kişi). Veri toplama sırasında bireylerden yüzlerini farklı bir şekilde hareket ettirmeleri istenmiştir. Kombinasyonlar (hız, rotasyon baskısı) .Video sekanslarında, yüz görüntülerini MoBo veri tabanı ile aynı şekilde kırılmış. Ortaya çıkan yüz görüntülerinin boyutu 20 × 20 pikseldir. Üçüncü veri tabanı ise CRIM adlı üçüncü bir video veri tabanıdır. Bu veri tabanı yaklaşık 5 saat boyunca yayın haberlerini okuyan 20 kişiyi gösteren 591 adet geniş bir yüz dizisidir. Veritabanları aslında görsel olarak tanınır. Her birey için 23 ve 47 video dizisi vardır. Çıkarılan yüz görüntülerinin boyutu 150 × 150 pikseldir. Bu çalışmada başarımlar ölçütleri için LDA (Linear Discriminant Analysis), PCA (Principal Component Analysis), LBP (Local Binary Pattern) metotları kullanılarak elde edilmeye çalışılmıştır. Kullanılan metotlarla her bir veri tabanından

elde edilen en büyük başarı yüzdesi %93 LBP metodu ile CRIM veritabanından elde edilmiştir.

Alexandre (2010) yaptığı çalışmada LBP (Yerel İkili Örüntüler) metodunu kullanarak cinsiyet tahmini yapmaya çalışmıştır. Bu çalışmada iki ayrı veri tabanı kullanılmıştır. Birinci veri tabanımız birçok araştırmacı tarafından kullanılmış ve halen kullanılmakta olan FERET (Face Recognition Technology) veri tabanıdır. İkincisi ise UND (University of Notre Dame) veri tabanıdır. Yapılan çalışmada iki veri tabanındaki toplam test ve eğitim verileri şu şekildedir. FERET için toplam veri seti 411, toplam veri setinin 304 tanesi eğitim, 107 tanesi test amaçlı kullanılmıştır. Eğitim veri setinin yarısı erkek diğer yarısı kadın resimlerinden oluşmakta. Test veri setinde ise 47 erkek, 60 kadın resmi bulunmaktadır. UND veri tabanı için toplam 487 adet resim kullanılmış olup bunun 260 tanesi eğitim ve kalan 227 adet resim ise test amaçlı kullanılmıştır. Bu veritabanında eğitim için 130 bay ve 130 bayan resmi, test için 56 bay 130 bayan resmi kullanılmıştır.

Her iki veri tabanındaki verilerimiz yeniden üç farklı boyutlandırma işlemine tabi tutularak 20x20, 36x36, 128x128'lik üç ayrı boyutlanmış yeni verilere LBP metodu uygulayarak cinsiyet tahmini yapılmaya çalışılmıştır. Sınıflandırma işleminde Karar Destek Vektörleri kullanılmıştır. Her iki veritabanından elde edilen yeni boyutlandırma işleminden sonra en büyük başarı yüzdesi %87,85 ile 36x36 boyutlu FERET veritabanından elde edilmiştir. Ayrıca yapılan çalışmada her üç farklı resim boyutlandırma işleminde de FERET veritabanında UND veritabanına oranla daha yüksek başarı oranları elde edilmiştir.

Caifeng (2012), yaptığı çalışmasında Cinsiyet tanımanın, temel yüz analiz görevlerinden biri olduğunu belirterek, cinsiyet tanıma ile ilgili yapılan mevcut çalışmaların çoğunun kontrollü koşullar altında elde edilen yüz görüntülerine odaklandığını açıklamıştır. Bununla birlikte, gerçek dünyadaki uygulamaların, kısıtlanmamış senaryolardaki önemli görünüm varyasyonları nedeniyle çok daha zor olduğunu ve gerçek yaşam yüzlerinde cinsiyet sınıflandırılmasının gerekliliğini dile getirmektedir. Bu çalışmasında, yakın zamanda oluşturulmuş veri tabanı olan etiketli yüzler içeren WILD(LFW) veri tabanı kullanılarak gerçek yaşamdan alınan yüz görüntüleri üzerinden cinsiyet algılamayı amaçlamıştır. LFW kısıtlanmamış pozlar içeren internetten toplanan bir veri tabanıdır. Elde edilen görüntülere 250x250'lik yeni boyutlandırma işlemi uygulanmıştır. Her yüz için cinsiyet belirtme işlemi her yüze elle etiketleme yapılarak yapılmıştır. Toplam 7.443 yüz görüntüsünden oluşan(2.943 kadın,

4.500 erkek) LFW veri tabanı kullanılmıştır. Bütün deney sonuçları 5 kat çapraz doğrulama işlemine tabi tutularak elde edilmiştir. Veri seti benzer büyüklükteki beş alt kümeye ayrılmıştır.

Bu çalışmada Caifeng Shan yöntem olarak klasik LBP (Yerel İkili Örüntüler), LBPH (Yerel İkili Örüntü Histogramları) metodunu kullanmıştır. Sınıflandırma işlemini SVM (Karar Destek Vektörleri) kullanarak yapmıştır. Kullandığı veri tabanının hiçbir sınırlamaya gidilmeden elde edilmesi gerçek yaşamdan alınmış olmasına rağmen LBPH metodu ile %94.81'lik yüksek bir başarı oranı elde etmiştir.

Bing ve ark. (2012) yaptıkları bir çalışmalarında sadece yüz bileşenin aksine kıyafet, saç ve yüz kombinasyonları birleştirilerek cinsiyet tahmini yapmaya çalışmışlardır. Saç objesinin yüz nötr olduğunda insanlara ayırt edici ipuçları sağladığını dile getirmektedirler. Yaptıkları bu çalışmalarında saç gibi kıyafetinde cinsiyet ayırımında önemli bir etken olduğunu dile getirmişlerdir. Çalışmalarında üç farklı veri tabanı kullanılmıştır. Bunlar FERET, AR ve kendi oluşturdukları ve BCMI adını verdikleri üçüncü bir veri tabanı kullanmışlardır. Elde edilen verileri üç ayrı kombinasyona ayırıp bu kombinasyonlarla çeşitli deneyler yapılmıştır. Bu kombinasyonları şu şekilde sıralayabiliriz (a) beş yüz bileşeninden oluşan kombinasyonu, (b) kıyafet, saç ve tüm yüzden oluşan kombinasyon, (c) kıyafet, saç ve beş yüz bileşeninden oluşan kombinasyon. Her üç kombinasyonun özellik çıkarımında LBP (Yerel İkili Örüntüler) metodu kullanılmıştır. Sınıflandırma işleminde SVM (Karar Destek Vektörleri) kullanılmıştır. Yapılan çalışmada ilk önce resimlerdeki arka zemin kaldırılmış ve kaşlarda bazı önemli noktalar, gözler, burun ve ağız bulunur. İlk adımda, Kenar konturunu elde etmek için giriş görüntüsüne Sobel kenar algılama algoritması uygulanmıştır. Kenar konturuna göre arka plan kaldırılmış. Önemli noktaları bulmak için, yüz bölgesi ilk olarak Adaboost yüz denetçisi tarafından tespit edilmiş ve daha sonra, daha önce eğitilmiş olan Aktif Şekil Modelinden (ASM) kaş, göz, burun, ağız ve çene yerleri elde edilmiş. Bundan sonra, gözlerin aynı yatay çizgide olduğu görüntüleri döndürmüşler ve yüz bölgesini 150x130 piksel boyutuna getirmek için yeniden boyutlandırmışlar. Son olarak yüz bölgeleri ve giyim bölgeleri kırılarak alınmıştır. Yapılan çalışmada tüm yüz özelliklerinin kullanıldığı sınıflandırıcının en yüksek doğruluğu aldığı ortaya çıkmıştır. Bu başarı yüzdeleri iki veri kümesinde (FERET, AR) ortalama olarak %88,5 ve %91,9'dur. Her iki veri kümesinde, yüz bileşenlerinin sınıflandırıcıları arasında, baş ve çene en iyi performans gösterirken, burun bu konuda daha kötüdür. Baş ve çene bölgelerinin cinsiyet açısından en ayırıcı bilgiyi sağladığını

gösterirken, burun nispeten daha az yararlıdır. Buna ek olarak, saç kullanan cinsiyet sınıflandırıcısı saçın özellik gösteriminde azda olsa etkili olduğunu gösterir % 79,7 ve % 77,7'lik bir doğruluk elde edilmiştir.

Levi ve Hassner (2015) yaptıkları çalışmada imge işleme ile cinsiyet ve yaş tahmini yapabilen bir çalışma yapmışlardır. Yapılan çalışmada veri tabanı olarak birçok çalışmada kullanılan ve bu alanda popüler olan FERET veri tabanı kullanılmıştır. Yöntem olarak CNN (Convolutional Neural Network) kullanılmıştır. CNN görüntülerin analiz edilmesine başarılı bir şekilde uygulanmış derin ileri beslemeli yapay sinir ağıdır. CNN'ler minimal ön işleme gerektiren birçok katmanlı algılayıcı varyasyonu kullanırlar. Bu çalışmada kullanılan CNN yapısında ağ, her biri düzeltilmiş doğrusal işlem ve bir araya getirme katmanı ile takip eden üç adet konvolüsyon tabaka içerir. İlk iki tabaka lokal yanıt normalizasyonunu kullanarak, normalizasyonu takip eder. İlk Konvolüsyon Katmanı, 7x7 pikselden oluşan 96 filtre içerir, ikinci Konvolüsyon Katmanı, 5x5 pikselden oluşan 256 filtre içerir, Üçüncü ve son Konvolüsyon Katmanı, 3x3 pikselden oluşan 384 filtre içerir. Son olarak, her biri 512 nöron içeren iki adet tam bağlı tabaka eklenir. Yapılan çalışmaya ait detaylı algoritmanın her bir adımında yapılan işlemler şu şekilde sıralanabilir.

İlk önce her üç renk kanalı da doğrudan ağ tarafından işlenir. Görüntüler önce 256x256'lik piksele ayarlanır ve ağa 227x227'lik pikselle sistem beslenir. Diğer üç katman şu şekilde tanımlanır.

1-ilk konvolüsyon tabakasında girişe 3x7x7 piksel boyutunda 96 filtre uygulanmıştır. bunu takiben, revize edilmiş bir doğrusal operatör olan, ikili-üçlü adımlarla ve bir yerel yanıt normalleştirme tabakasıyla en fazla 3x3'lük bölgeyi alan bir maksimum havuzlama katmanı takip eder.

2-Bir önceki tabakanın 96x28x28 çıktısı daha sonra 96x5x5'lik Piksel boyutunda 256 filtre içeren büyüklükte ikinci kıvrım tabakası tarafından işlenir. Yine, bunu, daha önce olduğu gibi aynı yüksek parametrelere sahip bir maksimum havuzlama katmanı ve bir lokal cevap normalleştirme tabakası olan revize edilmiş bir doğrusal operatör takip eder.

3-Son olarak, üçüncü ve son konvolüsyon katman operatörleri ile 256x14x14'lik pikseli damlalar üzerinde 256x3x3 boyutunda bir 384 filtre seti uygulayarak çalışır. Sonrasında revize edilmiş bir doğrusal operatör ve maksimum bir havuz tabakası izler. Aşağıda kalan diğer tam bağlı katmanlar, daha sonra şu şekilde tanımlanır:

4-ilk olarak tamamen bağı katman üçüncü kıvrım tabakasının çıkışı alır ve 512 nöron içerir ve bunu revize edilmiş bir doğrusal operatör ile çıkış katmanı takip eder.

5-İlk tam bağı katmanın 512 boyutlu çıktısını alan ve yine 512 nöron içeren bir ikinci tam bağı katman, ardından bir revize edilmiş bir doğrusal operatör ve bir çıkış tabakası içerir.

6-Final kısmının olduğu yaş veya cinsiyet için en son sınıflara ayırma işleminin yapıldığı üçüncü tam bağı katmandır.

Son olarak, son tam bağı tabakanın çıkışı, her bir sınıf için bir olasılık tayin eden bir softmax tabakasını besler. Tahmin, verilen test görüntüsü için en yüksek olasılıklı sınıfı olarak yapılır. Tüm katmanlardaki ağırlıklar, 0.01'in standart sapmasıyla sıfır ortalama Gaussian'dan rastgele değerler ile başlatılır. Bunu vurgulamak için, ağı başlatılması için önceden eğitilmiş modeller kullanılmamış; Ağ, görüntülerin dışında herhangi bir veri kullanmadan ve ölçüt tarafından mevcut olan etiketleri kullanmadan sıfırdan eğitilir. Eğitim için hedef değerler, yer gerçeği sınıflarına karşılık gelen seyrek, ikili vektörler olarak temsil edilmiştir. Her bir eğitim görüntüsü için, hedef, etiket vektörü, zemin hanesinin indeksinde 1 ve başka yerlerde 0 içeren, sınıfların uzunluğuna (cinsiyet için iki, yaş sınıflandırma görevinin sekiz yaş sınıfı için sekiz) sahiptir. Ağı eğitilmesinde yalın bir ağ mimarisini kullanmanın yanı sıra, aşırı takılma riskini daha da azaltmak için iki ek yöntem daha uygulamıştır. Öncelikle, çıkış öğrenimini uygulamış (yani ağ nöronlarının çıkış değerini rastgele ayarlayarak). Ağ, 0.5'lik bir çıkış oranına sahip iki çıkış katmanı içerir (nöronun çıkış değerinin sıfıra ayarlanması olasılığının %50'si). İkincisi, 256x256 piksellik giriş görüntüsünden ve her ileriye dönük eğitim geçişinde rastgele yansıtılan 227x227 piksel rastgele bir ürün olarak veri artışı kullanılmıştır. Eğitim, elli imge görüntü boyutu ile stokastik düğüm kullanarak gerçekleştirilmiştir. İlk öğrenme oranı e^{-3} , 10 bin tekrardan sonra e^{-4} değerine düşürülmüştür.

Yapılan bu çalışmada Gil Levi ve Tal Hassner cinsiyet sınıflandırmada %86,8'lik, yaş sınıflandırma da ise %84,7'lik bir başarı oranı elde etmişlerdir.

2.2. Yaş Tahmini ile İlgili Çalışmalar

Yang ve Haizhou (2007) yaptıkları çalışmalarında yüz dokusu ile yaş ve etnik köken sınıflandırma işlemini yapmayı amaçlamışlardır. Metot olarak bizim de bu tez

çalışmasında temel aldığımız klasik LBP (Yerel İkili Örüntüler) yöntemine ek olarak LBPH(Yerel İkili Örüntü Histogramları) metodunu kullanmışlardır. Yaş üç döneme ayrılır: çocuk, genç ve yaşlılık; etnik köken ise Asyalı ve Asyalı olmayan olarak sınıflandırılmıştır. Veri tabanı olarak FERET, PIE ve Snapshot (anlık) görüntülerinden oluşan üç farklı veri tabanı kullanılmıştır. 1196 kişiye ait FERET'teki tüm önden çekilmiş 3540 görüntü, 68 bireye ait 696 adet iyi aydınlatma ile önden çekilmiş PIE görüntüsü kullanılmıştır. Anlık görüntü veritabanı ise 9000 Çinli'ye ait anlık görüntüler içermektedir. Üç veri tabanında da gözlüklü veya gözlüksüz bireylerin olduğu resimler mevcuttur. Anlık görüntü veritabanını, yaş ve cinsiyet sınıflandırmasında beş kat çapraz doğrulama için kullanılmış, bağımsız veritabanı testi için FERET ve PIE kullanılmıştır. Etnik sınıflandırma konusunda yapılan deneylerde, FERET ve anlık görüntüler çapraz doğrulama için birleştirilmiş ve PIE veri tabanı testi için kullanılmıştır.

Yaklaşımlarının etkinliğini göstermek için, referans şablon histogramı olarak pozitif örneklerin ortalama histogramını alan yöntemin (LBPH olarak gösterilir) deney sonucu, karşılaştırma için üç alt bölümde verilmiştir. Karşılaştırma için Mean while, Real AdaBoost ve Haar kullanılmıştır. Yöntem belirtildiği gibi LBPH (Yerel İkili Örüntülerin Histogramları) kullanılmıştır. Kullandıkları yöntem temel olarak referans şablon histogramı olarak pozitif örneklerin ortalama histogramını alır. Yapılan çalışmada yaş sınıflandırma işleminde en düşük hata oranı %7,88 LBPH metodu ile FERET veritabanından elde edilmiştir. Etnik sınıflandırma işleminde de en düşük hata oranı %6,8 ile LBPH metodu ile elde edilmiştir.

Ylioinas ve ark., (2013) yaptıkları bir çalışmada yüz resimlerinden örüntü elde ederek yaş tahmini yapmışlardır. Veri seti olarak Flickr'dan 5,080 deneğe ait 28,231 yüz görüntüsü kullanılmıştır. Kontrolsüz koşullarda alınan yüz görüntülerinin her biri 0-2, 3-7, 8-12, 13-19, 20-36, 37-65, 66 yaş ve üzeri olmak üzere 7 farklı yaş kategorisinden birine atılmış. Düşük çözünürlüğe sahip görüntüler göz koordinatları kullanılarak kırılıp 60x48'lik piksellere normalize edilmiş. Daha sonra, verilen LBP operatörü uygulanarak, model oluşumlarının mekansal olarak geliştirilmiş bir histograma dönüştürüldüğü 6x6'lık piksellerin meydana geldiği bölgeler uzamsal olarak geliştirilmiş bir histogram olarak hesaplanır. Büyüklük bileşeni için, dokuz ayrı yüz bölgesinde çalışmanın genel olarak tüm yüzdeki işlemlerden daha iyi sonuçlar verdiğini fark etmişler. Dolayısıyla, verilen yüz, ilk olarak, yerel fark büyüklüğü dönüşümü (LDMT) ve büyüklük kodlaması ile ayrı olarak işlenen dokuz bölge bölünmüştür. Son olarak, hem işaret hem de büyüklük bileşen histogramları tek bir histogram halinde

birleştirilmiştir. Belirli bir test görüntüsünde bir kişinin yaşını tahmin etmek için, çıkarılmış yüz ifadelerini doğrusal olmayan bir RBF çekirdeği olan çok sınıflı bir SVM sınıflandırıcısına girdi olarak kullanmışlardır. SVM sınıflandırıcısının parametreleri bir network araştırması kullanılarak belirlenmiş. SVM uygulaması için kamuya açık LIBSVM Kütüphanesi kullanılmıştır. Yapılan çalışmada örüntü elde etmede birkaç LBP çeşidini ve bunların kombinasyonları karşılaştırılmıştır. BeFIT'de önerildiği gibi, sınıflandırıcıları, her bir yaş kategorisine (sınıf başına 500) eşit sayıda örnek içeren, rastgele bir 3.500 yüz imgesi kullanılarak eğitilmiş. Test, bağımsız bir şekilde dağıtılmış 1.050 yüz numunesi (sınıf başına 150) üzerinde gerçekleştirilmiştir. Gerçekleştirilen çalışmada %88,7'lik bir başarı oranı elde edilmiştir.

Ramesha ve ark., (2010) yılında yaptıkları çalışmada imgeden öz nitelik çıkararak yaş ve cinsiyet tahmini yapmışlardır. Çalışmada kullandıkları model ve izledikleri yolda öncelikle yüz görüntüsünün, kalitesini artırmak için dönüştürülmüş bir yüz resmi elde etmek üzere işlenmesi ve önemli özelliklerin korunması için bir ön işleme yapılmıştır. Daha sonra sırasıyla iki göz bebeği arası uzunluk, burun ucu ile dudak arası mesafe, burun ucu göz bebekleri arası mesafe, göz bebeği dudak orta noktası arası mesafe hesaplanmıştır. Daha sonra yüz görüntüsünde piksel içeren yüzün şekli elde edilmiştir. Kullandıkları metotta sırasıyla yüz görüntüsünün genişliğinin yüksekliğine oranını elde etmişlerdir. Yüz görüntüsünün sınırlayıcı kutu koordinatları belirlenip bu koordinatlar kullanılarak genişlik ve yükseklik hesaplanmıştır. Dudağın sağ uç noktası ile yüz görüntüsünde dudak içeren piksellerin sol uç noktası arasındaki mesafe, yüz görüntüsünden elde edilen toplam piksel sayısı, yüz görüntüsünde bıyık içeren bölgelerin belirlenmesi, dudak bölgelerinin belirlenmesi, göz kuyruklarının belirlenmesi, alın bölgesinin belirlenmesi, yanakların belirlenmesi, göz kapakları, burun kanadının belirlenmesi ile çalışmada temel alınacak noktalar belirlenip gerekli hesaplamalar yapılmıştır. Bir piksel topluluğunun ortalaması, aritmetik yoğunluk ortalamalarıdır, bunların toplanmasıyla hesaplanmış ve toplam sayılarına bölünmüştür. Her bir veri noktası seti ile ortalama değerleri arasındaki ortalama mesafenin bir ölçüsü ortalama değerinden sapmanın karelerinin toplamı ile hesaplanmıştır.

Yapılan çalışmada ön işleme kısmında Renk Dönüştürme: RGB renk görüntüsü, bir $M \times N \times 3$ renk piksel dizisidir, belirli bir mekansal konumda bir RGB görüntünün kırmızı, yeşil ve mavi bileşenlerine karşılık gelen bir üçüzdür. Bileşen görüntülerinin veri sınıfı, kendi değer aralıklarını belirler. Bir RGB görüntüsü sınıf çiftindeyse, değer aralığı $[0, 1]$ şeklindedir. Benzer şekilde, sırasıyla sınıf birimi8 veya birim16'nın RGB

görüntüleri için değerler aralığı $[0,255]$ veya $[0, 65535]$ 'dir. Bileşen görüntülerin piksel değerlerini temsil etmek için kullanılan bit sayısı, bir bitin bit derinliğini belirler. Gürültü azaltma: Beyaz arka planda tek siyah pikseli ortadan kaldırmak için ikili görüntüye bir gürültü azaltma filtresi uygulanır. Siyah piksellerin sayısı beyaz pikselden daha büyükse, seçilen piksellerin 8-komşuları incelenir, aksi takdirde siyah beyaz olarak kabul edilir. Fotoğraf makinesi veya tarayıcı camındaki kir, tarayıcı aydınlatmasında vb. Kusurlar, taranan yüz görüntüsündeki gürültüyü tanıtır. Görüntüdeki gürültüyü gidermek için bir filtreleme işlevi kullanılmıştır. Kenar algılama yöntemi: Nokta ve çizgi algılamaları, görüntü segmentasyonunda önemlidir. Kenar tespiti, yoğunluk değerlerinde birçok süreksizliğin saptanması için en yaygın yaklaşımdır. Canny kenar algılama, $f(x, y)$ gradyanının yerel maksimum değerini arayarak kenarı bulur. Gradyan, Gaussian filtrenin türevleri kullanılarak hesaplanır. Yöntem, güçlü ve zayıf kenarları tespit etmek için iki eşik kullanır ve çıktısındaki zayıf kenarları sadece güçlü kenarlara bağlıysa, diğer bir deyişle gerçek zayıf kenarları tespit etmek için kullanılmıştır. Özellik çıkarımı kısmında Özellikleri ayıklamak için global ve sistem özellikleri bir arada kullanılmıştır. Global özellikler arası göze ait mesafe, burun ucu ile dudak ucu arasındaki mesafeyi, burun ucunu iki göze birleştiren çizgi arasındaki mesafe, iki dudak arasındaki çizgiyi iki göze birleştiren çizgi, yüzün eksantrikliğini, boyut oranını, genişliğini içerir. Kullanılan ızgara özellikleri, yüz görüntüsünün ten rengi, bıyık bölgesi, dudak bölgesi, göz kuyruğu, alın, göz bebeklerini birleştiren yerdeki açı, göz kapağı ve burun kanadıdır.

Yüz üzerinden elde edilen temel özellikleri yaş sınıflandırması için oranların hesaplanmasında kullanılmıştır. Genç, orta ve yaşlı olmak üzere yetişkinlerden oluşan yüz yüze veritabanı için dört oran hesaplanmıştır. Bunlardan ilki olan $oran_1$, sol göz ve sağ göz mesafesi arasındaki farkın göz ile burun mesafesi arasındaki farka oranıdır. İkincisi yine iki göz arasındaki farkın göz dudak arası farka oranıdır. Üçüncüsü göz burun mesafe farkının göz çene mesafesi arasındaki farka oranıdır. Dördüncü ve sonuncusu ise göz burun mesafe farkının göz dudak mesafe farkına oranıdır.

Yapılan çalışma bir eğitim ve test modeli de içermektedir. ANN (Artificial Neural Networks) kullanılmıştır. ANN, yapay nöronlar olarak adlandırılan temel birimler arasındaki bağlantıdır. Yapay bir nöron iki girdi alır, onları bir ağırlık ile çarpar ve birleştirir. Her bir giriş bağlantısının, onunla ilişkili bağımsız bir ağırlığı vardır. Eğer ağırlıklı girişin değerinin toplamı eşik değerine eşit veya daha büyükse, çıktı 1'e eşittir. Toplam, eşik değerinden küçükse, çıktı 0'dır. Bu önemlidir, çünkü yapay nöronların

AND, OR ve NOT mantıksal işlevlerinin hesaplamasına izin verir. Yapay sinir ağları oluşturmak için üç mantık fonksiyonunu hesaplamak için yapay nöronlar birleştirilir.

Sınıflandırma bölümünde FEBFRGAC adı verdikleri yeni bir algoritma ile yapılmıştır. FEBFRGAC ve ACFI (Age Classification using Facial İmage)'nin ortalama, varyans, standart sapmaları karşılaştırılmıştır. FEBFRGAC kullanarak ortalama, varyans ve standart sapma değerleri, daha az sayıda yüz görüntüsü içeren veri tabanı için daha iyi sonuçlar veren ACFI'dan çok daha yüksektir. Oranlar, ortalama, varyans ve standart sapma değerlerini geliştirecek şekilde seçilmiştir. Yapılan çalışmada FEBFRGAC algoritması ile cinsiyet sınıflandırmasında %95, yaş sınıflandırmasında ise %90 gibi yüksek başarı oranları elde edilmiştir.

2.3. Duygu Tahmini ile İlgili Yapılan Çalışmalar

Caifeng ve ark., (2012) yaptıkları bu çalışmalarında, kişiden bağımsız yüz ifadesi tanıma için Yerel İkili Örüntü (LBP) özelliklerine dayanarak yüz temsili deneysel olarak incelemişlerdir. LBP özellikleri orijinal olarak doku analizi için önerilmiş ve son zamanlarda yüz görüntüleri analizindeki yüzleri temsil etmek için tanıtılmıştır. LBP'nin en önemli özellikleri, aydınlatma değişikliklerine karşı toleransları ve hesaplama basitlikleridir. LBP özelliklerini kullanarak yüz ifadesi tanımayı gerçekleştirmek için şablon eşleştirme, Destek Vektör Makinesi (SVM), Doğrusal Ayrımsal Analiz (LDA) ve Doğrusal Programlama tekniği dahil olmak üzere farklı makine öğrenme yöntemlerini incelenmiştir. Çalışmalarında, Gabor dalgacıklarına kıyasla, LBP özelliklerinin tek bir taramada çok hızlı bir şekilde elde edilebildiğini ve düşük boyutlu özellik alanında ya da küçük bir taslakta ayırt edici yüz bilgisini sakladığını elde etmişlerdir. AdaBoost ile en ayırt edici LBP özelliklerini öğrenerek Boosted-LBP'yi daha da formüle etmişler ve Boosted-LBP özelliklerini kullanarak farklı sınıflandırıcıların tanıma performansı iyileştirilmiştir. Ayrıca LBP özelliklerinin farklı veritabanlarında genelleştirme yeteneğini değerlendirmişler. Bu çalışmada, düşük çözünürlüklü yüz ifadesi tanıma için LBP özelliklerini araştırılmıştır. Farklı görüntü çözünürlükleriyle ilgili deneyler, LBP özelliklerinin kullanışlı bir düşük yüzölçümlü görüntü çözünürlüğü aralığında sabit ve sağlam bir performans sergilediğini göstermektedir. Bu çalışmada daha geniş veritabanlarında farklı sınıflandırıcılarla yüz ifadesi tanıma için LBP özelliklerini kapsamlı bir şekilde incelenmiştir. Düşük çözünürlüklü yüz ifadesi tanıma için LBP özelliklerini araştırılmıştır. Yalnızca farklı görüntü çözünürlükleri üzerinde değerlendirme yapmakla kalmıyor, aynı zamanda gerçek dünyada sıkıştırılmış

video dizilerinde deneyler yapılmıştır. Her ifade için AdaBoost ile en ayırt edici LBP histogramlarını öğrenerek Boosted-LBP'yi formüle ediyoruz ve farklı sınıflandırıcıların tanıma performansı Boosted-LBP özellikleri kullanılarak geliştirilmiştir. Ayrıca, LBP özelliklerinin farklı veri tabanları üzerindeki genelleme yeteneğini de değerlendirilmiştir. Yapılan çalışmada yedi farklı yüz ifadesinin tahmini yapılmaya çalışılmıştır. Bu yüz ifadelerinin tahmin işleminde %91,5'lik yüksek bir doğru sınıflandırma başarısı elde edilmiştir.

Kumaria ve ark. (2015) yaptıkları çalışmaları ile duygu analizi yapmaya çalışmışlardır. Yaptıkları çalışma beş adımdan oluşur. Bu adımlar sırası ile görüntüde ön işleme gürültü giderme / iyileştirme, ön işleme aşamasında görüntü veya görüntü dizisi (nötrden bir ifadeye geçen bir dizi görüntü dizisi) bir girdi olarak alınarak yapılır ve daha sonraki işlemler için yüzü verir. Yüz bileşeni tespiti, gözler, burun, yanaklar, ağız, göz kaşları, kulak, ön kafa vb. özellik çıkarımı, sınıflandırma adımlarıdır. Yapılan çalışmada LBP (Local Binary Pattern), LGC (Local Gradient Code), LDA (Linear Discriminant Analysis), LGC-HD (Local Gradient Code-Horizontal Diagonal), LGC-VD (Local Gradient Code-Vertical Diagonal), HOG (Histogram of Oriented Gradients) metotları uygulanarak özellik çıkarımı yapılarak KNN (K-En Yakın Komşu) ile sınıflandırma işlemi yapılmıştır. Yapılan sınıflandırma işleminde LGC (Local Gradient Code) %88,77 ile en iyi performansı göstermiştir. En düşük oran %64,79 ile LDP'den elde edilirken diğer metotlarda LGC'ye yakın başarılı sınıflandırma elde edilmiştir.

Happy ve ark., (2012) yaptıkları çalışmalarında Yerel İkili Örüntüler (LBP) kullanarak kişilere ait farklı duyguların sınıflandırılması amaçlanmıştır. Bu çalışmada, yüz algılama amacıyla Haar sınıflandırıcı, yüz görüntüsünün farklı blok boyutlarındaki Yerel İkili Desenler (LBP) histogramı özellik vektörleri olarak kullanan ve Temel Bileşen Analizi (PCA) kullanılarak çeşitli yüz ifadelerini sınıflandıran bir yüz ifadesi sınıflandırma algoritması sunulmuştur. Çalışmadaki eğitim kısmında eğitim örneklerinin haritalanacağı altı temel ifadeye ait altı sınıf kabul edilmiştir. Yüz algılama, Haar sınıflandırıcıları kullanılarak eğitim veri setinde gerçekleştirilmiştir. Daha sonra LBP blok histogramı özellikleri yüz görüntülerinden elde edilir. PCA, aynı sınıf özelliklerinin daha fazla dağıldığı özün yönlerini bularak verilerin boyutlandırılmasını azaltmak için kullanılmıştır. Eğitim, altı yüz sınıfının tümü için gerçekleştirilmiştir. Özellik çıkarımında LBP tabanlı özellik çıkarma yöntemi, mükemmel ışık değişmezliği ve düşük hesaplama karmaşıklığı nedeniyle kullanılmıştır. Özellik çıkarma yönteminden elde edilen verilerin boyutları çok yüksek olduğu için hesaplamaların

gerçek zamanlı olarak hızını artırmak için PCA ile boyutluluk azaltma yapılmıştır. PCA, verileri yüksek boyutlu bir alandan daha düşük boyutlu bir alt boşluğa haritalayan doğrusal bir dönüşümü hesaplamayı sağlamıştır. Yapılan çalışmada test sonuçları, LBP özelliklerini kullanarak yüz ifadeleri tanıma doğruluğunun %97'den fazla olduğunu gösterir.



3. MATERYAL VE METOT

Bu tez çalışmasında yüz görüntülerinden kişilerin duygu, yaş ve cinsiyet tahminleri gerçekleştirilmiştir. Tahmin işlemleri iki aşamada gerçekleştirilmiştir. Birinci aşamada yüz görüntülerinden öznitelikler elde edilmiştir. İkinci aşamada ise sınıflandırma işlemi gerçekleştirilmiştir. Bu tez çalışmasında yüz görüntülerinden öznitelik vektörleri oluşturmak için yerel ikili örüntüler tabanlı 4 farklı yaklaşım önerilmiştir. Önerilen yaklaşımlar renkli görüntüler kullanan metotlardır. Bu metotlar aşağıda detaylıca açıklanmıştır. Metotları test etmek için FEI yüz veri tabanı kullanılmıştır.

3.1. Materyal

Bu çalışmada FEI veri tabanındaki görüntüler kullanılmıştır. FEI kişi tanıma, cinsiyet tanıma gibi farklı amaçlar için kullanılan bu alanda popüler bir veri tabanıdır. FEI yüz veri tabanı, yaşları 19-70 arasında değişen FEI'de öğrenim gören veya çalışan 200 kişiye ait görüntülerden oluşmaktadır (Thomaz ve ark., 2010). Her kişi için farklı açılardan oluşan birden fazla görüntü bulunmaktadır. Görüntüler Haziran 2005 ile Mart 2006 arasında São Bernardo do Campo, São Paulo, Brezilya'da FEI'nin Yapay Zeka Laboratuvarı'nda çekilmiştir. Farklı yüz ifadelerine sahip 14 farklı görüntü, her bir bireyin dik frontal pozisyonundan alınırken, profilleri yaklaşık 180 dereceye kadar döndürülmüştür. Bu veri seti, 640x640 piksel boyutunda renkli, homojen beyaz arka plana sahip, toplam 2800 resim içeriyor. Kullanılan bazı görüntüler şekil 3.1.'de gösterilmiştir.



Şekil 3.1. FEI veri tabanındaki örnek yüz görüntüleri

Tüm görüntülerdeki yüzler tespit edilerek yüz kısımları kırılıp kayıt edilmiştir. Kişinin tespitinde problem olacak saç, giysi gibi gereksiz alanlardan kurtulmak için bu işlem gerekli olmaktadır. Yüzler Matlab programında geliştirilen bir script ile kırılmıştır. Sadece yüz kısmını içeren görüntüler şekil 3.2.'de gösterilmektedir.



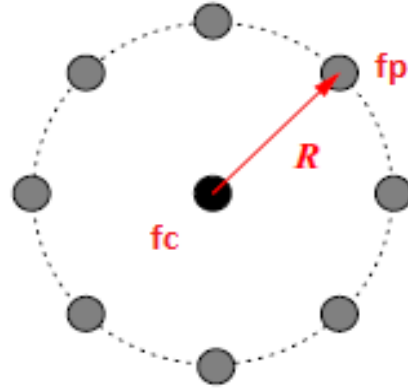
Şekil 3.2. Kırılmış örnek yüz görüntüleri

3.2. Metot

3.2.1. Yerel İkili Örüntüler

Yerel İkili Örüntüler (Local Binary Pattern=LBP, YİÖ) görüntülerden etkili özellikler elde etmemizi sağlayan bir istatistiksel yaklaşımdır. Yerel İkili Örüntülerde özellik çıkarımı yerel komşuluk değerlerine dayanır. Bilgisayar görü uygulamalarında yaygın bir şekilde kullanılmaktadır. Çeşitli çalışmalarda etkinliği kanıtlanmıştır. İki aşamadan oluşmaktadır. Birinci aşamada görüntülerden yerel ikili örüntüler, mikro yapılar çıkarır. İkinci aşamada ise bu örüntülerin histogramı oluşturulur (Ojala ve ark., 2002; Liao ve ark., 2009).

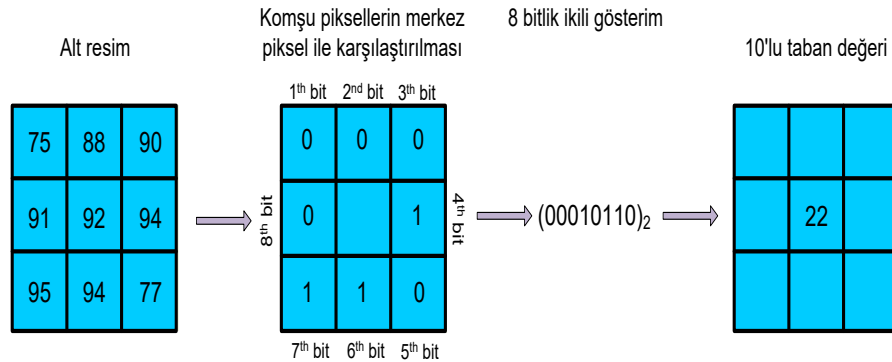
LBP tanımlayıcısı, 3x3 komşuluğunda merkez pikseli (f_c) etrafındaki pikseller $f_p = (p = 0,1, \dots, 7)$ ile karşılaştırarak her piksel için ikili bir değer $S(f_p - f_c)$ oluşturmaktadır. LBP tanımlayıcısı ile bir pikselin etiketlenmesine ilişkin bir örnek Şekil 3.3'te verilmiştir. LBP değerleri görüntüdeki her pikselin komşuları arasındaki farkın basamak fonksiyonu ile ikilileştirilmesi ile elde edilir (Eşitlik 1).



Şekil 3. 3. LBP dairesel komşu şeması

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

LBP_{P,R} biçimindeki operatörde, R yarıçapı belirtmekte merkez piksel ile komşu piksellerin birbirlerine olan uzaklığını belirtir, işleme dahil edilen komşu piksel sayısını da P ifade eder (Zhao ve ark., 2007). Aşağıdaki örnekte (Şekil 3.3) R yarıçap değeri bir (1) alınırken, komşu sayısı P ise sekiz (8) olarak alınmıştır.




Şekil 3. 4. LBP değeri elde edilen bir piksel

Yapılan çalışmalarda görüntülerdeki yüzeylerinin büyük bir kısmının uniform örüntülerden oluştuğu görülmektedir. Uniform örüntüler, ikili LBP kodunda 0-1 ya da 1-0 geçiş sayısı 2 ya da daha az olanlardır. Örneğin 00000000 ve 11111111 örüntüleri 0 geçişe, 01100000 ve 11000011 örüntüleri 2 geçişe sahip olduklarından uniform örüntülerdir. Uniform örüntüler, spot, kenar, köşe gibi basit dokuları da

açıklayabilmekteler. Toplamda (P-1) P+2 uniform örüntü bulunmaktadır (Nanni ve ark., 2010; Ahonen ve ark., 2006; Kaya ve ark., 2015).

Komşu sayısını P ile ifade edilmekte ve P aynı zamanda LBP'nin ilk parametresidir. LBP yüz ifadelerinin oluşturulmasında P'nin sahip olabileceği her büyük değer öznitelik histogramını büyütmenin yanı sıra aynı zamanda işlem maliyetini artırmaktadır. P'nin küçük değerleri ise önemli bilgi kaybına neden olabilmektedir. Ölçek (R) parametresi ise LBP'nin ikinci parametresidir. Merkez piksel ile komşu pikseller arasındaki uzaklık R ile belirtilir. Farklı R değerlerin kullanılması ile farklı ölçekteki dokuların analizini gerçekleştirmek mümkün olmaktadır. Bu notasyon çeşitli dairesel komşulukların kullanılabilceğini de göstermektedir. Farklı P ve R değerlerinin kullanılması ile farklı ölçekteki dokuların analizini gerçekleştirmek mümkün olmaktadır. Şekilde 3.4'te farklı LBP operatörlerine örnek verilmiştir.

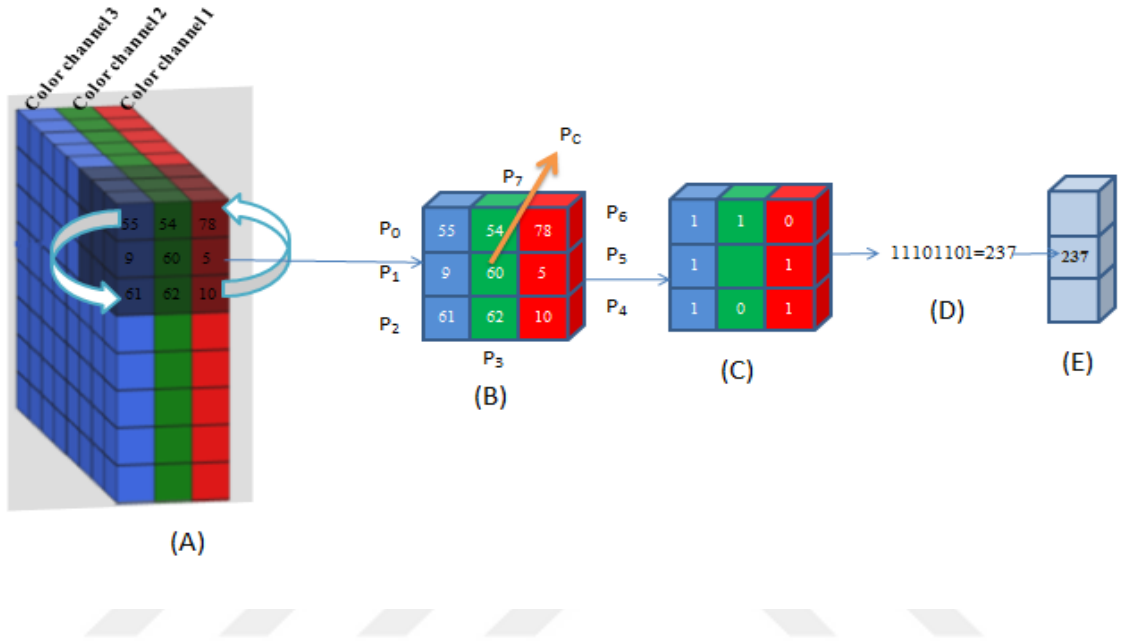


Şekil 3. 5. Farklı P ve R parametrelerine göre LBP tanımlayıcıları

3.2.2. L2R (LBP_{L2R})

LBP soldan sağa (Left2Right, L2R) LBP_{L2R} yöntemi renkli görüntüler için geliştirilmiştir. LBP operatörü RGB, HSV, YCbCr veya YIQ renk uzayı kanallarındaki bilgileri kullanılarak oluşturulmaktadır. Aşağıdaki şekil RGB renk kanalları olarak düşünüldüğünde şekilde görüldüğü gibi görüntünün solundan sağa doğru ele alınan renk kanallarından değerler karşılaştırılarak ikili değerler elde edilmektedir. İkili dizgeler çok az piksel kullanılarak elde edilmektedir. Mikro örüntülerin yakalanması açısından

önerilen bu yöntem önemli olmaktadır. Şekil 3.6. (E)'de görüldüğü gibi örüntüler 3x1 adet piksel üzerinden oluşturulmuştur. Klasik LBP'de örüntüler 3x3 piksel üzerinden oluşturulmaktadır. Her pikselin üst ve alt komşu bilgileri kullanılarak mikro örüntüler çıkarılmaktadır. Önerilen bu modelin en önemli avantajı mikro örüntülerin elde edilmesi olmaktadır.



Şekil 3.6. LBP_{L2R} yöntemi ile örüntü elde etme aşamaları.

(A):Orijinal renkli resim

(B):Renkli resimden LBP_{L2R} ile elde edilen bir kesit

(C):LBP_{L2R} ile hesaplama sonucu elde edilen sonuç.

(D):LBP_{L2R} yöntemi ile elde edilen örüntünün ikilik taban karşılığı.

(E):LBP_{L2R} yöntemi ile elde edilen örüntünün onluk değer karşılığı.


Şekil 3.6'da görüldüğü gibi G kanalındaki merkez nokta etrafındaki R,G,B kanallarındaki pikseller ile karşılaştırılmaktadır. Şekildeki örneğe göre;

$$LBP_{L2R}(x)=\{S(P_0>P_c),S(P_1>P_c),S(P_2>P_c),S(P_3>P_c),S(P_4>P_c),S(P_5>P_c),S(P_6>P_c),S(P_7>P_c)\}$$

Burada S karşılaştırmayı ifade eder ve aşağıdaki eşitlik ile hesaplanır.

$$S(P_i > P_c) = \begin{cases} 1, & P_i \geq P_c \\ 0, & P_i < P_c \end{cases} \quad (2)$$

Elde edilen ikili değerler şekilde görüldüğü gibi onlu değerlere dönüştürülür. Benzer işlemler diğer HSV, YIQ, YCbCr renk kanalları içinde geçerlidir. Aşağıda şekil 3.7'deki resimde farklı renk katmanlarındaki örüntüler ve LBP_{L2R} metodunun uygulanması ile elde edilen yeni örüntünün piksel değeri görsel bir şekilde ifade edilmeye çalışılmıştır. Şekil 3.7'de de görüldüğü gibi öncelikle (A) renkli orijinal resmimizden bir piksel seçip, (B) de bu piksele ait RGB(Red, Green, Blue) olmak üzere üç farklı renk kanalı elde ediyoruz. (D) de ise her bir kanaldan elde edilen örüntüler gösterilmiştir. (E) de elde edilen her bir kanaldaki matris değerleri yukarıdan aşağıya ve soldan sağa gelecek şekilde yeni bir örüntü ve komşu örüntüleri elde edilmektedir. (F) de ise merkez pikselle tek tek karşılaştırıp binary form elde edilir ve soldan sağa başlayarak kodlanır.




Şekil 3.7. LBP_{L2R} yöntemi ile farklı renk katmanlarında örüntü elde etme aşamaları.

3.2.3. T2D (LBP_{T2D})

LBP yukarıdan aşağıya (Top2Down, T2D) LBP_{T2D} yöntemi LBP_{L2R} yöntemi gibi renkli görüntüler için geliştirilmiştir. LBP_{T2D} operatörü RGB kanallarındaki bilgiler kullanılarak oluşturulmaktadır. Bu yöntemde şekil3.8.'den görüldüğü gibi görüntünün üst bölümünden aşağı doğru ele alınan renk kanallarından değerler karşılaştırılarak ikili değerler elde edilmektedir. İkili dizgeler çok az piksel kullanılarak elde edilmektedir. LBP_{T2D} operatörü iki 1x3 piksel üzerinden oluşturulmaktadır. Klasik LBP yöntemine göre daha az piksel kullanılmaktadır. Mikro örüntülerin yakalanması açısından

önemlidir. Her pikselin üst bölümünden ve aşağı doğru alınarak renk kanallarından değerlerin karşılaştırılarak ikili değerler elde edilmektedir. Bulunan iki komşu piksel üzerinden mikro örüntüler elde edilmektedir. LBP_{T2D} yöntemi aşağıdaki şekil.3.9 ile gösterilmiştir.



Şekil 3.8. LBP_{T2D} yöntemi ile örüntü elde etme aşamaları.

(A):Orijinal renkli resim

(B):Renkli resimden LBP_{T2D} ile piksel elde edilmesi

(C): LBP_{T2D} ile hesaplama sonucu elde edilen örüntünün ikilik sonucu.

(D): LBP_{T2D} yöntemi ile elde edilen örüntünün onluk taban karşılığı.

(E): LBP_{T2D} yöntemi ile elde edilen 3x1'lik örüntünün değer karşılığı.

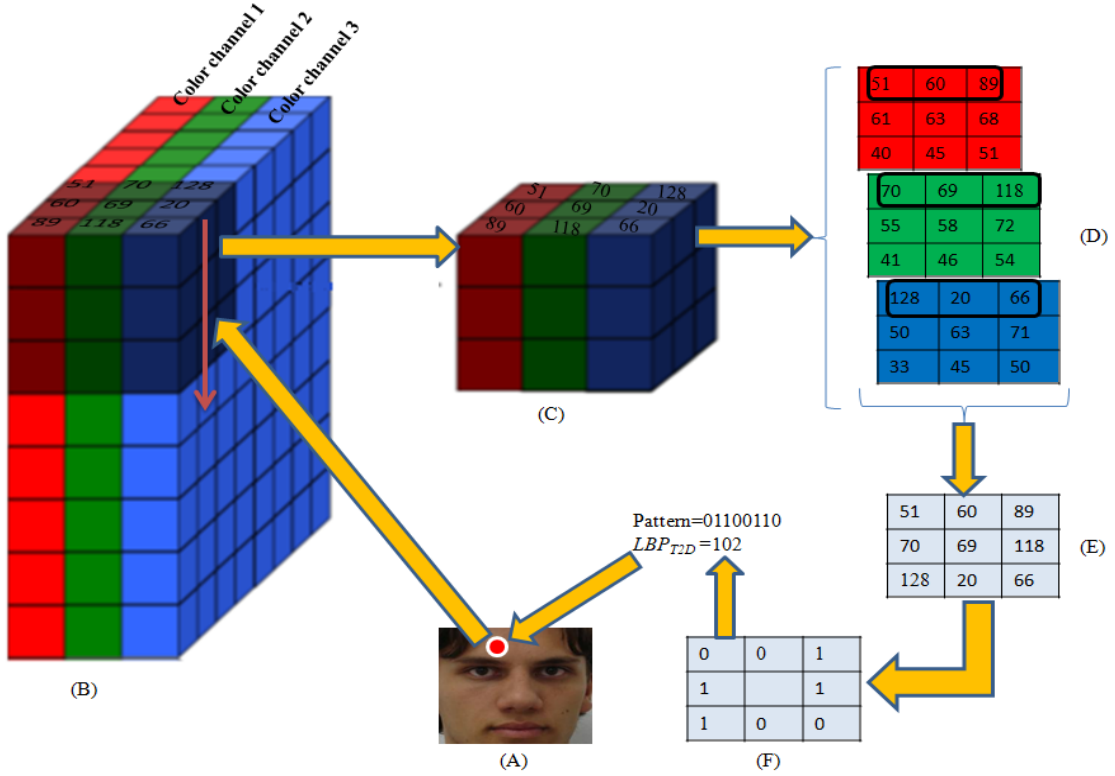
Şekildeki örneğe göre;

$$LBP_{T2D}(x)=\{S(P0>Pc),S(P1>Pc),S(P2>Pc),S(P3>Pc),S(P4>Pc),S(P5>Pc),S(P6>Pc),S(P7>Pc)\}$$

Burada S karşılaştırmayı ifade eder ve aşağıdaki eşitlik ile hesaplanır.

$$S(P_i > P_c) = \begin{cases} 1, & P_i \geq P_c \\ 0, & P_i < P_c \end{cases} \quad (3)$$

Elde edilen ikili değerler onluk tabandaki karşılık değerlerine dönüştürülür. Bu işlemler diğer renk kanalları için de aynı şekilde kullanılabilir.



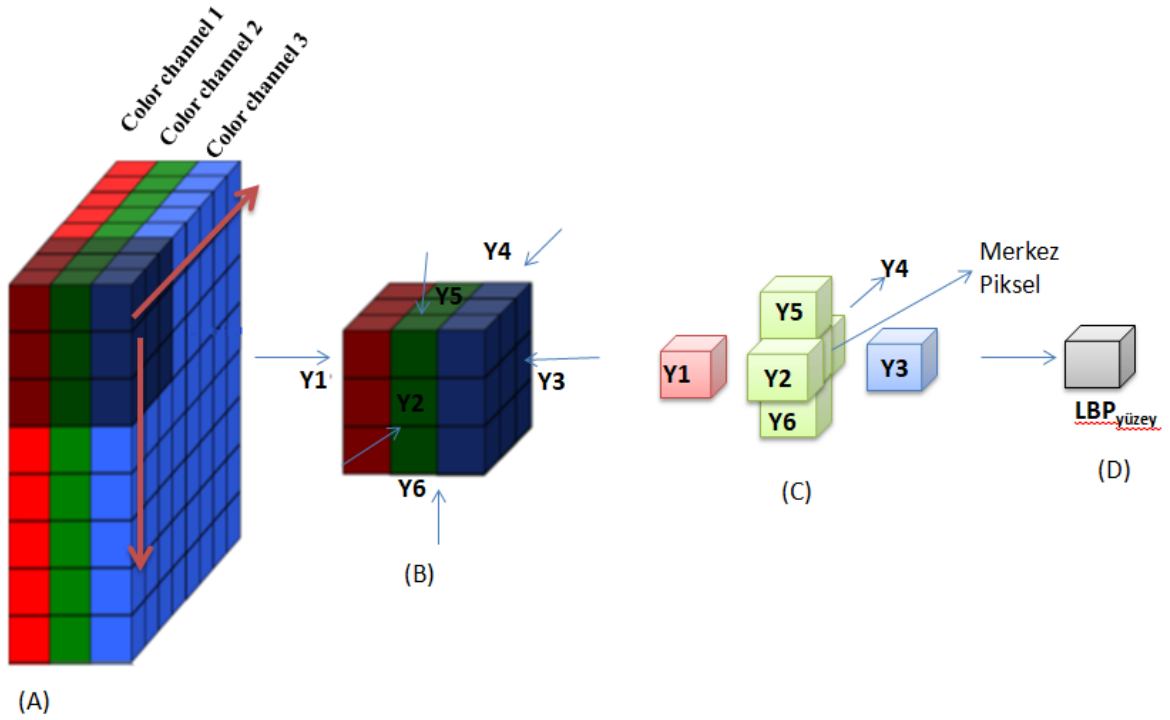
Şekil 3.9. LBP_{T2D} yönteminin herhangi bir piksele uygulanışı.

- (A):Orijinal renkli resim ve işleme alınan piksel kırmızı kutucukla belirtilmiştir.
 (B):Renkli resmin RGB(Red, Green, Blue) görünümü.
 (C): LBP_{T2D} ile örüntü elde edilmesi.
 (D): LBP_{T2D} yöntemi ile elde edilen örüntünün RGB katmanları.
 (E): LBP_{T2D} yöntemi ile elde edilen örüntünün 3x3'lük matris değer karşılığı.
 (F): LBP_{T2D} ile hesaplama sonucu elde edilen örüntünün ikilik tabandaki sonucu.

3.2.4. $LBP_{Surfaces}$ ($LBP_{Yüzey}$)

Bu yaklaşımda her pikselin etrafındaki yüzeyler için LBP operatörü işlenmektedir. Her pikselin etrafında 6 adet yüzey vardır. Bir küpte toplam altı yüzey bulunmaktadır. Daha sonra her yüzey için elde edilen merkez değerler merkez piksel ile karşılaştırılarak $LBP_{Surfaces}$ değeri hesaplanmaktadır. Bu yaklaşımda $2^6=64$ adet örüntü

elde edilmektedir. Klasik LBP yöntemlerine göre daha az örüntü elde edilir. $LBP_{Surfaces}$ yönteminin uygulanış adımları aşağıdaki şekilde gösterilmiştir.



Şekil 3.10. $LBP_{Surface}$ yöntemi ile örüntü elde etme aşamaları.

(A):Orijinal renkli resim

(B):Renkli resimden elde edilen örüntüye ait altı adet yüzey.

(C):Merkez piksel ve komşu altı yüzey.

(D): $LBP_{Yüzey}$ yöntemi ile hesaplama sonucu elde edilen kübik yüzey değeri.

$$LBP_{Yüzey}(x) = \{Yüzey(Y1 > Pc), Y(Y2 > Pc), Y(Y3 > Pc), Y(Y4 > Pc), Y(Y5 > Pc), Y(Y6 > Pc)\}$$

Burada Yüzey karşılaştırmayı ifade eder ve aşağıdaki eşitlik ile hesaplanır.

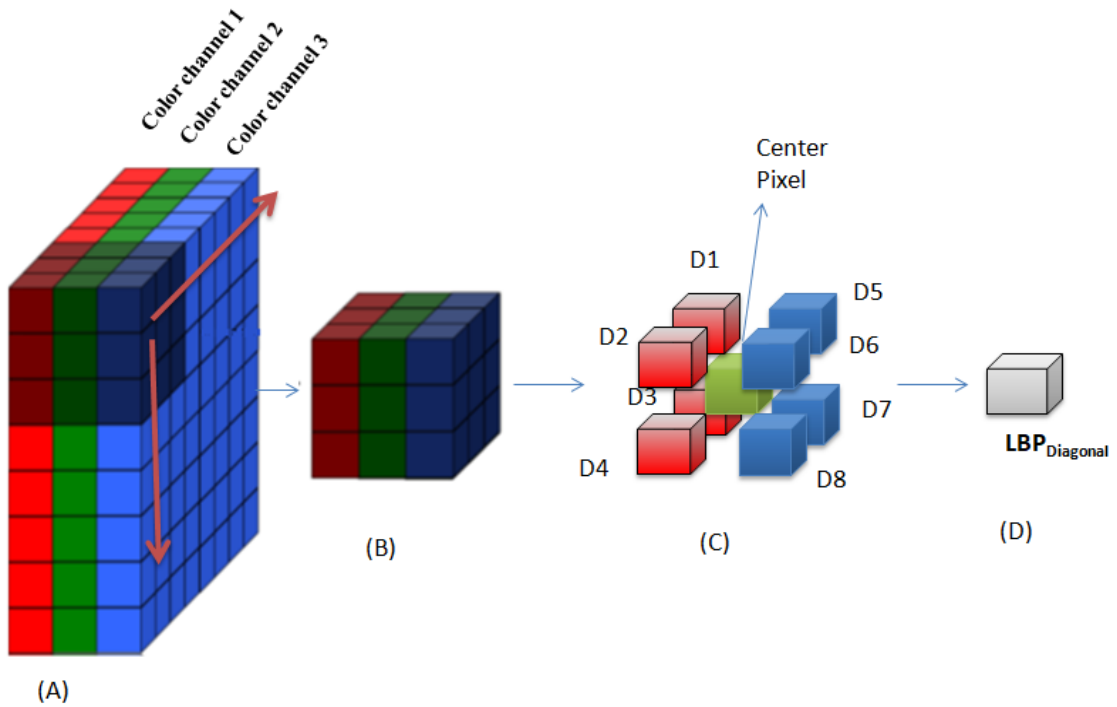
$$Yüzey(Y_i > Pc) = \begin{cases} 1, & Y_i \geq Pc \\ 0, & Y_i < Pc \end{cases} \quad (4)$$

Elde edilen ikili değerler onluk tabandaki yeni değerlere dönüştürülür. Yukarıdaki şekilden anlaşılacağı üzere her bir küpte altı yüzey bulunmaktadır. Orijinal renkli resmimizden (A)'dan elde edilen kesit (B)'yi incelediğimizde her bir küpte toplam altı yüzey bulunmaktadır. Kesit (C)'den anlaşıldığı üzere bir merkez pikselimiz

var ve bu merkez pikselimize komşu altı adet yüzeyimizin merkez değerleri hesaplanıp merkez piksel ile karşılaştırılıp ikili değer karşılığı yüzey numaralandırması dikkate alınır ve ondan sonra onluk tabandaki değer karşılığı merkez pikselimizin yeni değeri olarak yazılır.

3.2.5. $LBP_{Diagonal}$

$LBP_{Diagonal}$ yaklaşım ele alınan pikselin etrafındaki köşegen piksellerin merkez piksel ile karşılaştırılarak elde edilen yeni örüntülere dayanmaktadır. $LBP_{Diagonal}$ yönteminin çalışma basamakları ve elde edilen bulgular aşağıda şekil10.3'te görsel olarak ifade edilmiştir. Şekle göre G kanalındaki bir pikselin R ve B kanallarındaki köşegenlerden elde edilen bilgileri kullanılmaktadır. RGB pikselleri küp şeklinde gösterildiğinden sekiz(8) adet köşegen (D1,D2,D3,D4,D5,D6,D7,D8) piksel değeri ile merkez (Pc) piksel değeri karşılaştırılıp yeni merkez pikselin (Pc) değeri hesaplanır. Karşılaştırma sırasında merkez pikselin mevcut değeri ile elde edilen köşegenlerin değerleri sırasıyla karşılaştırılıp ikili tabanda bir değer elde edilir ve daha sonra bu ikilik tabandaki değerimizi onluk tabana çevirip merkez pikselimizin yeni değeri olarak yazarız.



Şekil 3.11. $LBP_{Diagonal}$ yöntemi ile örüntü elde etme aşamaları.

- (A):Orijinal renkli resim
- (B):Renkli resimden bir kesit
- (C):Köşegen piksel ve merkez piksel
- (D):LBP_{Diagonal} yöntemi ile elde edilen yeni örüntü

Şekil 3.11'deki örneğe göre LBP_{Diagonal} ile örüntü elde etmek için aşağıdaki şekilde bir yol izlenir.

$$LBP_{Diagonal}(x) = \{S(D1 > Pc), S(D2 > Pc), S(D3 > Pc), S(D4 > Pc), S(D5 > Pc), S(D6 > Pc), S(D7 > Pc), S(D8 > Pc)\}$$

Burada S karşılaştırmayı ifade eder ve aşağıdaki eşitlik ile hesaplanır.

$$S(Di > Pc) = \begin{cases} 1, & Di \geq Pc \\ 0, & Di < Pc \end{cases} \quad (5)$$

3.3. Sınıflandırma

Verileri benzerliklerine göre gruplamak için kullanılan ilgili kategorilerden oluşan bir gruplama aracı veya bir veri kümesi üzerinde tanımlanmış olan çeşitli sınıflar arasında veriyi dağıtma işine sınıflandırma kavramı denilmektedir. Sınıflandırmanın temelinde incelenen örneklerin veya durumların her biri için ayırt edebileceğimiz karakteristik veya benzer özelliğin seçilmesi gerektiğidir. Bu tez çalışmasındaki sınıflandırma FEI veri setinden oluşan 200 adet renkli yüz görüntüsünden kişilerin duygu, yaş ve cinsiyet tahminlerinin yapılmasıdır.

3.4. Model Başarım Ölçütleri

Herhangi bir çalışmaya ait model başarımını değerlendirirken baz alınan temel kavramlar doğruluk, F-ölçütü, kesinlik, hata oranı ve duyarlılıktır. Modelin başarısı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atanan örnek sayısı nicelikleriyle ilgilidir. Test sonucunda ulaşılan sonuçların başarım bilgileri karışıklık matrisi ile ifade edilebilir. Karışıklık matrisinde satırlar test kümesindeki örneklere ait gerçek sayıları, kolonlar ise modelin tahminlemesini ifade eder.

| KARIŞIKLIK MATRİSİ | | Öngörülen sınıf | |
|-----------------------|---------|-----------------|---------|
| | | Sınıf=1 | Sınıf=0 |
| Doğru sınıf | Sınıf=1 | a | b |
| | Sınıf=0 | c | d |

Şekil 3.12.Karışıklık Matrisi

3.4.1. Doğruluk

Model başarımının ölçülmesinde kullanılan en popüler ve basit yöntem, modele ait doğruluk oranıdır. Doğru sınıflandırılmış örnek sayısının (TP +TN), toplam örnek sayısına (TP+TN+FP+FN) oranıdır.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

3.4.2. Hata Oranı

Hata oranı doğruluk oranının 1'e tamlayanıdır. Diğer bir ifadeyle yanlış sınıflandırılmış örnek sayısının (FP+FN), toplam örnek sayısına (TP+TN+FP+FN) oranıdır.

$$Hata\ oranı = \frac{FP + FN}{TP + TN + FP + FN} \quad (7)$$

3.4.3. Kesinlik

Kesinlik, sınıfı 1 olarak tahmin edilmiş True Pozitif örnek sayısının, sınıfı 1 olarak tahmin edilmiş tüm örnek sayısına oranıdır.

$$Kesinlik = \frac{TP}{TP + FP} \quad (8)$$

3.4.4. Duyarlılık

Doğru sınıflandırılmış pozitif örnek sayısının toplam pozitif örnek sayısına oranıdır.

$$Duyarlilik = \frac{TP}{TP+FN} \quad (9)$$


3.4.5. F-Ölçütü

Kesinlik ve duyarlılık ölçütleri tek başına anlamlı bir karşılaştırma sonucu çıkarmamıza yeterli değildir. Her iki ölçütü beraber değerlendirmek daha doğru sonuçlar verir. Bunun için f-ölçütü tanımlanmıştır. F-ölçütü, kesinlik ve duyarlılığın harmonik ortalamasıdır.

$$F - \text{Ölçütü} = \frac{2 \times \text{Duyarlilik} \times \text{Kesinlik}}{\text{Duyarlilik} + \text{Kesinlik}} \quad (10)$$

3.5. Çalışma Diyagramı:

Bu tez çalışmasında FEI'den alınmış belli kişilere ait yüz görüntülerine uygulanan bir takım ön işlemler sonucunda kişilerin duygu, yaş ve cinsiyet tahminlerinin yapıp belli sınıflandırmalara ayırma işlemi yapılmıştır. Yapılan bu çalışmaya ait aşağıda şekil 3.13'te çalışma diyagramı verilmiştir. Bu tez çalışmasına ait çalışma diyagramındaki her bir adımda yapılan işlemleri kısaca şu şekilde açıklayabiliriz.



Şekil 3.13.Çalışma Diyagramı

Bu tez çalışmasında kullanılan 200 adet bay-bayan karışık resim kullanılmıştır. Öncelikle görüntüler duygu, cinsiyet ve yaş niteliklerine göre çeşitli gruplara ayrıştırılmıştır.

Blok-1: Bu kısımda yüz görüntülerine LBP, LBP_{L2D}, LBP_{L2R}, LBP_{surface}, LBP_{diagonal} yöntemleri uygulanarak yüzlerin LBP görüntüleri oluşturulmaktadır.

Blok-2: Bu bölümde LBP yöntemlerinin uygulandığı görüntülerin histogramları elde edilmektedir.

Blok-3: Sınıflandırma işlemi ilk bloğudur. Sınıflandırma işlemi k=10 çapraz geçerlilik metoduna göre gerçekleştirilmiştir. Görüntülerden oluşturulan veri seti k=10 parçaya bölünmüştür. Sırası ile her parça test diğer parçalar eğitim seti olarak kullanılmaktadır.

Blok -4: Test veri setindeki her örneğin ait olduğu grup tahmin edilmeye çalışılmıştır. Çeşitli sınıflandırma algoritmaları ile sınıflandırma işlemi yapılmıştır. Sınıflandırma algoritmaları olarak Logistic Model Tree (LMT), Simple Logistic ve J48 algoritmaları kullanılmıştır. Sınıflandırma işlemlerinde Weka yazılımı kullanılmıştır.


Blok-5: Bu aşamada sonuçlarımızı elde ettiğimiz, kullandığımız yöntemlerle verilerimizi sınıflandırdığımız ve kullandığımız yöntemlerden elde edilen başarı oranlarını gözlemleyebildiğimiz kısımdır.

3.6. Renk Uzayları

Renkleri tanımlamak için kullanılan matematiksel modellere renk uzayları denilmektedir. Oluşturulan renk uzayları bütün renkleri temsil edecek şekilde üç boyutlu olarak tasarlanır. Renkmetri bilimine göre bir rengi belirlemek için birbirinden bağımsız üç değişkene ihtiyaç vardır. Renk uzayındaki renk yerleri bu değişkenlere göre belirlenir. Her bir renk uzayının kendine has biçimde renk oluşturması için bazı standartları vardır.

3.6.1. RGB

RGB renk uzayı (Red, Green, Blue) yani 'Kırmızı' 'Yeşil' 'Mavi' ana renklerinden oluşan ve en sık kullanılan renk uzayıdır. Doğadaki tüm renklerin kodları ışığı temel alarak bu üç temel renge dayalı olarak belirtilir. Bütün renklerden %100 oranında karıştırıldığında beyaz renk elde edilirken, bütün renklerden %0 oranında karıştırıldığında siyah renk elde edilir. Ana renklerin kırmızı, mavi ve yeşil uzayda belirtilmediği için, bu ana renklere ait tanımda meydana gelen değişikliklerden dolayı, tüm renklerin de değişir. Üç boyutlu Kartezyen bir koordinat sistemi olarak RGB renk uzayını tanımlayabiliriz. Meydana gelen her bir eksen kırmızı, yeşil ve mavi renklerden oluşur. Siyah renk koordinat sistemine ait orijinde mevcuttur. Mavi, yeşil ve kırmızı beyaz renklerin değerlerini maksimum olacak şekilde oluşturur. Siyah ve beyaz noktaları birleştiren doğru üzerinde yer alan farklı gri tonları mavi, yeşil ve kırmızı renklerin eşit oranda karışımıyla meydana gelir. Mavi, yeşil ve kırmızı renklerin dışında kalan diğer bütün renklerin oluştuğu küpün içerisinde veya küpün üzerinde mavi, yeşil ve kırmızı eksenler üzerinde aldıkları değerlere göre yer alır.



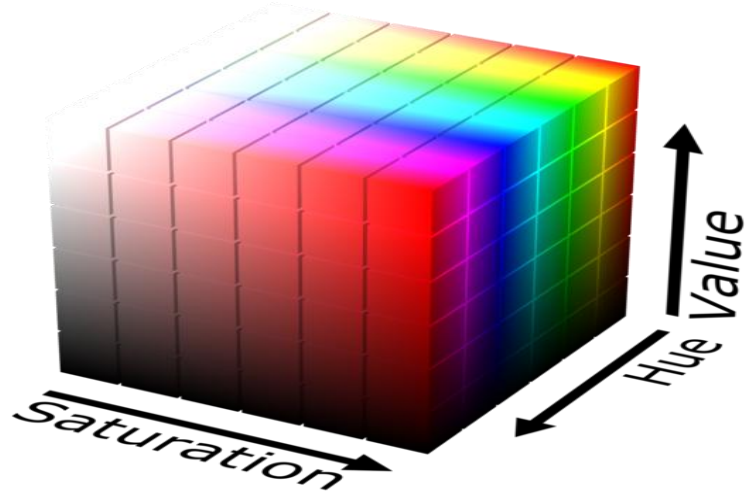
| | Bit | Byte | Renk Sayısı |
|----------|-----|------|---------------------|
| 1 Piksel | 1 | 1/8 | $256^{\frac{1}{8}}$ |
| 1 Piksel | 4 | 4/8 | $256^{\frac{4}{8}}$ |
| 1 Piksel | 8 | 1 | 256 |
| 1 Piksel | 24 | 3 | 256^3 |

Şekil 3.14.RGB'den elde edilen sayıları

3.6.2. HSV

HSV (Hue, Saturation, Value) veya HSB (Hue, Saturation, Brightness) renk uzayında yer edinen renkleri renk özü, doygunluk ve parlaklık olarak tanımlayabiliriz. Renge ait baskın dalga uzunluğunu renk özü belirler. Rengin canlılığını renge ait doygunluk miktarı belirler. Canlı renklerin oluşumuna yüksek doygunluk değerleri neden olurken, renge ait düşük doygunluk olasılığı ise rengin gri tonlarına yaklaşmasına neden olur. Renk içindeki beyaz oranını yani renkteki aydınlık oranını ise parlaklık miktarı belirler.

0 ile 255 arasında herhangi bir değer HSV uzayında siyah renk için renk ve doygunluk değeri olabilir. Siyah renge ait aydınlık oranı yani parlaklık değeri sıfırdır. Beyaz renkte aydınlık değeri en yüksektir bunun nedeni parlaklık değerinin 255 olmasıdır. HSV renk uzayını kullanmak herhangi bir bilgisayarlı görme uygulamasında belirli renkteki bir nesneyi ayırt etmek istediğimizde daha elverişlidir. Bunun nedeni HSV'nin RGB'nin aksine sadece HUE değerini kullanarak eşik değer uygulama suretiyle renkleri daha net ayırt edebiliyor olmasıdır (Coşar. K., 2018).



Şekil 3.15. HSV Renk Uzayı

HSV renk uzayında sadece Hue değerine bakarak yapılacak bir filtreleme ile kırmızı rengi ayırt etmek yeterlidir. Saturation ve Value değerlerinin ne olduğuna bakmaksızın kırmızı rengi ayırt edebiliriz. Böylece hem daha kolay hem de daha hassas sonuç elde etmek için kırmızı rengin ayırt edilmesi için renk değeri 160-180 arası bölgenin filtrelenmesi, sarı rengin ayırt edilebilmesi için ise 20-30 arasındaki renk değerlerini filtreleyerek istediğimiz sonuca ulaşabiliriz.

3.6.3. YIQ

YIQ modeli, ABD'nin ticari renkli televizyon yayıncılığında kullanılmaktadır. RGB'nin iletim verimliliği ve siyah-beyaz televizyon ile aşağı doğru uyumluluk için bir yeniden kodlamasıdır. Bu uyumluluk, siyah-beyaz televizyonların, göreceli aydınlatma bilgilerini içeren, iletimin Y bileşenine dikkat etmeleridir. Bu bileşen, televizyon yayıncılığındaki bant genişliğinin çoğunluğunu alır ve böylelikle daha nettir, böylelikle siyah-beyaz televizyon resimleri genellikle ABD'deki renkli televizyon resimlerinden daha keskin görünecektir. (Y parametresi) bant genişliğinden daha fazlasını alır. Çünkü insan görsel sistemi, tonlama veya doygunluktaki değişikliklerden ziyade parlaklıktaki değişikliklere karşı daha hassastır. RGB ve HSV gibi YIQ renk alanı, aygıtı bağlı bir renk alanıdır; bu, monitörünüzde gördüğünüz gerçek renk, kullandığınız monitörün türüne ve ayarlarının ne olduğuna bağlı olarak değişir.

3.6.4. YCbCr

YCbCr Y ile parlaklık (luminance) sinyalinin, Cb ve Cr ile ise renk (chrominance) bilgilerini saklayan bir renk uzayıdır. YCbCr renk uzayı, dünya çapında sayısal video standardı oluşturma çabaları sırasında ortaya çıkmıştır. Y, 8 bitlik 16-235 Aralığında tanımlanmaktadır. Cb ve Cr de ise 16-240 arasında tanımlanmaktadır.

3.7. Gürültü Metotları

Gürültü yüksek frekanslı bileşenlerde bulunan istenmeyen işaretler olup, bir işaretin ya da değişkenin bilgi içeriğinin bozulması olarak tanımlanmaktadır. Görüntülerde ise söz konusu durum, resmin elde edilmesinde veya taşınmasında vuku bulur. Genelde de çevresel faktörler (atmosferik durumlar) ya da görüntüyü elde eden cihazlardaki sensörlerin durumları (ışık değeri ya da ısısız nedenler) mevcut durumu oluşturmaktadır. Bu aşamada görüntü işleme tekniklerinden, filtreleme yöntemleri kullanılarak gürültü indirgenmeye çalışılmaktadır. Yapılan işlemin başarısının ölçülmesi için de indirgeme aşamasından sonra elde edilen sonucun, orijinal görüntüye ne kadar yakın sonuç ürettiğini göstermek gerekmektedir. Böylece tekniğin hızı ve performansı hakkında bilgi edinilir. Bahsi geçen metotlar, medikal, radar, fotoğraf veya kameralardan elde edilen çeşitli türde girdi görüntüye yapay gürültü eklenerek denetlenmektedir. Çünkü gürültü karışmış görüntü üzerinde yürütülen filtrenin performansı ve hızı, orijinal görüntü bilinmediği için gösterilememektedir. Görüntülerde karşılaşılan pek çok gürültü çeşidi vardır.

Görüntü işleme tekniklerinde başarı oranını arttıran en önemli etmenlerinden biri gürültüdür. Görüntü işleme tekniklerinde başarıyı arttırmanın en önemli yollarından biri görüntüdeki gürültü oranını azaltmaktır. Birçok araştırmacı karşılaştığı bu sorunu çözmek ve yaptığı araştırma konusunda maksimum verim alabilmek için çeşitli gürültü metotlarını kullanmaktadır.

3.7.1. Poisson Gürültü Metodu

Foton gürültüsü olarak ta bilinen poisson gürültüsü, ışığın ölçülmüş niteliğine ve foton tespitlerinin bağımsızlığına kadar, ışığın ölçülmesiyle ilgili temel belirsizlik biçimidir. Poisson gürültüsünün beklenen büyüklüğü sinyale bağlıdır ve düşük ışık koşullarında baskın olarak görüntü gürültüsünün baskın kaynağını oluşturur. Görüntü sensörleri, belirli bir zaman aralığı boyunca sensöre gelen fotonların sayısını ölçerek

sahne ışınmasını ölçer. Dijital sensörlerde, fotoelektrik etki fotonları elektronlara dönüştürmek için kullanılırken, film tabanlı sensörler, ışığa duyarlı kimyasal reaksiyonlara dayanır. Her iki durumda da, rastgele bireysel foton gelişlerinin bağımsızlığı, altta yatan sinyalin kendisinin bir özelliği olan belirsizliğin bir sinyal bağımlılık biçimi olan foton gürültüsüne yol açar. Bilgisayar görüşünde, yaygın bir yaklaşım, görüntü gürültüsünü genellikle sıfır-katsayılı bir Gaussian kullanarak, sinyalden bağımsız olarak modellemektir. Gerçek görüntüleme sistemlerinde, foton gürültüsü ve diğer sensör tabanlı gürültü kaynakları, farklı sinyal seviyelerinde değişen oranlarda katkıda bulunur ve bu da sahne parlaklığına bağlı gürültüye yol açar. Foton gürültüsünü anlamak ve onu modellemek, gürültülü görüntüleri tedavi eden düşük seviyeli bilgisayar görme görevleri için ve farklı pozlamayı dikkate alan görüntüleme sistemlerinin analizi için özellikle önemlidir.

3.7.2. Gaussian Gürültü Metodu

Gauss gürültüsü, Gauss dağılımı denilen normal dağılıma benzer bir olasılık yoğunluk fonksiyonu ile istatistikeldir. Gauss genlik dağılımı da gürültü olarak bilinir. Bir Gauss dağılımı normal dağılım denkleminde verilir. Gaussian, yoğunluğu aşağıdaki formülde de ifade edildiği gibi bir x değişkeni, ortalama (μ) ve (σ) ile aşağıdaki gibi verilen sürekli, simetrik bir dağılımdır.

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (11)$$

3.7.3. (Salt and Pepper) Tuz ve Biber Gürültü Metodu

Tuz ve biber gürültüsü içeren bir görüntü, parlak piksellere ve parlak piksellerden oluşan koyu bölgeler içeren parlak bölgelere sahip olacaktır. Bu tür ters gürültülere ölü pikseller, dijital dönüşümde analog hatalar, iletimdeki bit hataları vb. etmenler neden olabilmektedir. Bu tarz bir gürültüyü ise karanlık bölgeyi çerçeve içine çıkarmak ve koyu/ parlak piksellerin etrafında değişime gidilerek büyük ölçüde ortadan kaldırılabılır.

Tuz ve biber gürültüsü impuls gürültü, sivri gürültü, rastgele gürültü veya bağımsız gürültü olarak da adlandırılır. Tuz ve biber gürültüsünde (seyrek ışık ve koyu bozukluklar), görüntüdeki pikseller, çevrelerindeki piksellerden renk veya yoğunluk bakımından çok farklıdır. Görüntü sinyalindeki keskin ve ani değişimler nedeniyle tuz

ve biber bozunması meydana gelebilir. Genellikle bu tip bir gürültü sadece küçük bir sayısal görüntü pikselini etkiler. Görüntülediğinde, görüntü koyu ve beyaz noktalar içerir, bu nedenle tuz ve biber gürültüsü terimi alır. Tuz ve biber gürültüsü içeren bir görüntü parlak bölgelerde koyu piksellere sahip olacağı gibi bunun tersi yani koyu bölgelerde parlak piksellere de sahip olacaktır.




Şekil 3.16. Tuz ve biber metodunun uygulanışı sonucu elde edilen yeni görüntü

Yukarıda şekil 3.16.'da görüldüğü gibi solda orijinal madeni paraların olduğu resmimiz ve sağında ise tuz ve biber gürültü metodu uygulanmış orijinal resmimizden elde edilen iki ayrı görüntü görünmektedir. Orijinal resmimiz ile tuz ve biber gürültü metodu uygulanarak elde edilmiş sağdaki resmimize baktığımızda orijinal resmimizde tekdüze bir görüntü hâkimken tuz ve biber gürültü metodu uygulanmış resmimizde ise koyu ve parlak bölgeler göze çarpmaktadır. Tuz ve Biber metodu uygulanarak elde edilen yeni resmimizde parlak bölgelerde koyu pikseller olduğu gibi koyu bölgelerde de parlak pikseller olabilmektedir.


4. SONUÇ

Bu tez çalışmasında kişilere ait yüz görüntülerden kişilere ait duygu, yaş ve cinsiyet tahmini gerçekleştirilmiştir. Bu amaçla LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ şeklinde dört(4) farklı yaklaşım önerilmiştir. Yaklaşımlar ayrıca klasik LBP yöntemi ile de karşılaştırılmıştır. Önerilen yöntemler renkli görüntüler için kullanılmaktadır. Bu yöntemler ile görüntülerden daha az piksel bilgisi kullanarak mikro bilgiler edilmektedir. Yüz tanıma sistemlerin başarısı yüz ifadelerinden elde edilen özneliklerin etkinliğine bağlıdır. Geometrik veya dokusal çıkarılan öznelikler sınıflandırma metodun başarısını etkilemektedir. Yöntemlerin iki yüz görüntüsüne(bir bay bir bayan) uygulandığında elde edilen yerel ikili görüntüler Şekil 4.1’de verilmiştir.




Şekil 4.1. LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ örnek LBP yüzleri. (A) Orijinal görüntüler, (B) LBP_{L2R} yüzü, (C) LBP_{T2D} yüzü, (D) $LBP_{Diagonal}$ yüzü, (E) $LBP_{surface}$ yüzü.

Şekil 4.1’e bakıldığında önerilen dört farklı yöntem ile aynı yüz görüntüleri için farklı ikili yerel yüzlerin elde edildiği görülmektedir. Her yöntem ile farklı görüntüler elde edildiği yüz görüntülerinden anlaşılmaktadır. Bunu daha ayrıntılı görmek için yöntemlerin oluşturduğu yüz görüntülerinin histogramlarının incelenmesi gerekir. Şekil 4.2 ve 4.3’te elde edilen yüz görüntülerinin histogramları verilmiştir.



Şekil 4.2. LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ yöntemlerine ait Histogramlar. (A) LBP_{L2R} histogramı, (B) LBP_{T2D} histogramı, (C), $LBP_{Diagonal}$ histogramı, (D) $LBP_{surface}$ histogramı




Şekil 4.3. LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ yöntemlerine ait Histogramlar. (A) LBP_{L2R} histogramı, (B) LBP_{T2D} histogramı, (C), $LBP_{Diagonal}$ histogramı, (D) $LBP_{surface}$ histogramı

Histogramlara bakıldığında her yöntemin farklı örüntüler çıkardığı anlaşılmaktadır. LBP_{L2R} yönteminde örüntüler sağa çarpık bir yayılım göstermektedir. LBP_{T2D} ve $LBP_{Diagonal}$ yöntemlerinde ise örüntüler düzensiz bir dağılım göstermektedir. $LBP_{surface}$ yöntemindeki örüntüler ise daha çok değişkenlik göstermektedir.

Bu tez çalışmasında yüz görüntülerine uygulanan LBP, LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ yöntemleri ile elde edilen özneliklere LMT(Logistic Model

Tree), Simple Logistic ve J48 algoritmaları ile kişilere ait duygu, yaş ve cinsiyet tahmini yapılmıştır. Önerilen yaklaşımların etkinliğini test etmek için görüntülerin farklı renk uzaylarındaki dönüşümlerine de uygulanmıştır. Bunun yanında hangi renk uzaylarındaki görüntülerin etkin olduğu belirlenmiştir. Ayrıca kullanılan yüz görüntülerine farklı gürültü metotları uygulanarak elde edilen gürültü metodu uygulanmış verilerden öznelikler çıkarılarak uygulanan sınıflandırma algoritmaları ile sınıflandırma başarıları ölçülmüştür. Şekil 4.4'te bir bay ve bir bayana ait görüntülere sırasıyla RGB, HSV, YCbCr ve YIQ renk uzaylarındaki görüntüleri verilmiştir.




Şekil 4.4 Farklı renk uzaylarına taşınmış resimler

RGB renk uzayı kırmızı, yeşil ve mavi (Red, Green, Blue) ana renklerinden oluşan ve en sık kullanılan renk uzayıdır. HSV (Hue, Saturation, Value) veya HSB (Hue, Saturation, Brightness) renk uzayı, renkleri sırasıyla renk özü, doygunluk ve parlaklık olarak tanımlar. YCbCr Y ile luminance (parlaklık) sinyalini, Cb ve Cr ile ise chrominance (renk) bilgilerini saklayan bir renk uzayıdır. YIQ modeli, ABD'nin ticari renkli televizyon yayıncılığında kullanılmaktadır. RGB'nin iletim verimliliği ve siyah-beyaz televizyon ile aşağı doğru uyumluluk için bir yeniden kodlamasıdır. Her bir renk uzayından elde edilen özneliklerin farklı olmasından dolayı elde edilen başarı ölçütlerinin farklılık göstermesi beklenmektedir.

Çalışmada kullanılan veri setine aşağıda Şekil 4.5.'te görüldüğü gibi orijinal resimlerimiz ile birlikte gürültü metotları uygulandıktan sonra elde edilen yeni veriler

ve meydana gelen deęişimler gösterilmiştir. Uygulanmakta olan gürültü metotlarında varsa her bir metodun kendisine ait varsayılan deęerleri kullanılmıştır. Her bir gürültü metoduna ait bilgilendirmeler detaylı bir şekilde bu tezin metot kısmında yapılmıştır.



Şekil 4.5. Orijinal veriler ve gürültü metotları uygulanarak elde edilen yeni veriler.

4.1. Cinsiyet Tahmin Sonuçları

Bu tez çalışmasında kullanılan yüz resimleri cinsiyet tahmini için iki ayrı klasöre bay ve bayan şeklinde dağıtılarak her bir klasördeki verilere özellik çıkarım metotları uygulanarak elde edilen özniteliklere Lojistik Regresyon ve Karar Ağacı gibi makine öğrenmesi algoritmalarını birleştiren denetimli bir sınıflandırma modeli olan LMT(Lojistik Model Ağacı Algoritması) algoritması uygulanmıştır. IF-THEN kurallarına dayalı bir karar ağacı ve üyelik fonksiyon kümeleri çıktısı veren enformasyon kazancı en iyi olan J48 algoritması ile basit lojistik algoritması uygulanmıştır.

4.1.1. Farklı Renk Uzaylarında Elde Edilen Özniteliklerin Sınıflandırma Başarısı

Önerilen metotların farklı renk uzaylarındaki görüntülerinden elde edilen öznitelikler LMT (Lojistik Model Ağacı Algoritması) ile sınıflandırma işlemine tabi tutulmuştur. Tüm yöntemlere ait başarı oranları ve diğer performans ölçütlerine ait başarılar Tablo 4.1. ve Tablo 4.2’de verilmiştir.

Tablo 4.1. Farklı renk uzaylarında LMT ile başarı oranları

| Öznitelik | RGB | HSV | YCbCr | YIQ |
|-------------------------|------|------|-------|------|
| LBP | 94,5 | 84,5 | 82 | 81,5 |
| LBP _{L2R} | 96 | 98,5 | 83,5 | 99 |
| LBP _{T2D} | 94 | 97 | 89 | 99 |
| LBP _{surface} | 95 | 90 | 86 | 87 |
| LBP _{Diagonal} | 94,5 | 87,5 | 85,5 | 76 |

Tablo 4.2. Farklı renk uzaylarında LMT ile Performans Sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|-------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,068 |
| LBP _{L2R} (YIQ) | 0,99 | 0,99 | 0,99 | 0,99 | 0,01 |
| LBP _{T2D} (YIQ) | 0,99 | 0,99 | 0,99 | 0,99 | 0,011 |
| LBP _{surface} (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,049 |
| LBP _{Diagonal} (RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,055 |

Tablo 4.1 ve Tablo 4.2’ye bakıldığında sınıflandırma işleminde en yüksek başarı yüzdesi LBP_{T2D} ve LBP_{L2R} metotları ile YIQ renk uzayındaki verilerden %99’luk yüksek bir sınıflandırma başarısı elde edilmiştir. Kullanılan metotların hepsine birlikte baktığımızda ise RGB renk uzayındaki verilerden elde edilen ortalama başarı oranları daha yüksektir. En düşük başarı oranı ise %76’lık oran ile yine YIQ renk uzayında LBP_{Diagonal} metodu ile elde edilmiştir.

Tüm öznitelik çıkarım yöntemleri ile J48 makine öğrenmesi yöntem ile gözlenen başarı oranları ve diğer performans ölçütleri Tablo 4.3 ve Tablo 4.4’te verilmiştir.

Tablo 4.3. Farklı renk uzaylarında J48 ile gözlenen başarı oranları

| Öznitelik | RGB | HSV | YCbCr | YIQ |
|-------------------------|------|------|-------|------|
| LBP | 87,5 | 78 | 77 | 67 |
| LBP _{L2R} | 97,5 | 98,5 | 80,5 | 99 |
| LBP _{T2D} | 96 | 98 | 86 | 99,5 |
| LBP _{surface} | 79,5 | 87,5 | 87,05 | 70 |
| LBP _{Diagonal} | 88 | 81 | 82 | 73,5 |

Tablo 4.4. Farklı renk uzaylarında J48 ile Performans Sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|-------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,875 | 0,875 | 0,875 | 0,875 | 0,126 |
| LBP _{L2R} (YIQ) | 0,99 | 0,99 | 0,99 | 0,99 | 0,01 |
| LBP _{T2D} (YIQ) | 0,99 | 0,99 | 0,99 | 0,99 | 0,011 |
| LBP _{surface} (HSV) | 0,78 | 0,78 | 0,78 | 0,78 | 0,222 |
| LBP _{Diagonal} (RGB) | 0,905 | 0,905 | 0,905 | 0,905 | 0,094 |

Tablo 4.3.'te farklı renk uzaylarına taşınmış verilerden elde edilen özniteliklere J48 algoritması uygulanarak cinsiyet sınıflandırma işlemi yapılmıştır. Yapılan sınıflandırma işleminde YIQ renk uzayındaki verilerden LBP_{T2D} metodu ile %99,5'lük yüksek bir başarı oranı elde edilmiştir. En düşük başarı oranı ise yine YIQ renk uzayında LBP metodu ile %67'lik bir başarı elde edilmiştir.

Tüm öznitelik çıkarım yöntemleri ile lojistik regresyon makine öğrenmesi yöntem ile gözlenen başarı oranları ve diğer performans ölçütleri Tablo 4.5 ve Tablo 4.6'te verilmiştir.

Tablo 4.5. Farklı renk uzaylarında Simple Logistic ile gözlenen başarı oranları

| Öznitelik | RGB | HSV | YCbCr | YIQ |
|-------------------------|------|------|-------|------|
| LBP | 95 | 87 | 81,5 | 81,5 |
| LBP _{L2R} | 94,5 | 84,5 | 81 | 74,5 |
| LBP _{T2D} | 94 | 84 | 84 | 71,5 |
| LBP _{surface} | 95 | 87,5 | 84 | 87 |
| LBP _{Diagonal} | 95 | 88 | 83,5 | 74,5 |

Tablo 4.6. Farklı renk uzaylarında Simple Logistic ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|------------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,055 |
| LBP_{L2R}(RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,055 |
| LBP_{T2D}(RGB) | 0,94 | 0,94 | 0,94 | 0,94 | 0,061 |
| LBP_{surface}(RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,049 |
| LBP_{Diagonal}(RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,049 |

Tablo 4.3.'te farklı renk uzaylarına taşınmış verilerden elde edilen özniteliklere sınıflandırma metodu olarak Simple Logistic uygulanarak elde edilen başarı oranları gözlenmiştir. En yüksek başarı oranları RGB renk uzayından elde edilmiştir. Öznitelik çıkarım metotlarının tamamı birbirine yakın ve %95'lik yüksek bir cinsiyet sınıflandırma başarı oranı elde edilmiştir.

4.1.2. Farklı Gürültü Metotları Uygulanarak Elde Edilen Özniteliklerin Sınıflandırma Başarısı

Gürültü farklı ışık, görüntü cihazlarından kaynaklanan faktörler yüzünden görüntü üzerindeki hatalardır. Gürültü görüntüdeki hem yerel hem de global özellikleri etkiler. Gürültü yüzünden doku tanıma ve sınıflama görevleri zor olmaktadır. Klasik LBP yönteminin bir dezavantajı gürültüye duyarlı olmasıdır. Bu yüzden bu çalışmada yeni dört LBP tanımlayıcısı önerilmiştir.

Önerilen yöntemlerin etkinliğini test etmek için yöntemler gürültülü görüntüler üzerinde test edilmiştir. Görüntülere Poisson, Guassian ve Salt-Pepper ile gürültü eklenmiştir. Poisson, Guassian ve Salt-Pepper ile gürültü değerleri varsayılan değerler ile eklenmiştir. Görüntülere gürültü eklendikten sonra elde edilen yeni görüntülerden önerilen yaklaşımlar ile öznitelikler elde edilerek sınıflandırma işlemleri gerçekleştirilmiştir. LMT sınıflandırma metodu ile elde edilen performans değerleri Tablo 4.7 ve Tablo 4.8'de verilmiştir.

Tablo 4.7. Farklı Gürültü Metotlarının LMT ile başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|-------------------------|------|---------|----------|-------------|
| LBP | 94,5 | 74,5 | 91,5 | 72,5 |
| LBP _{L2R} | 96 | 77 | 93 | 67 |
| LBP _{T2D} | 94 | 77 | 95,5 | 67 |
| LBP _{surface} | 95 | 74 | 89 | 74 |
| LBP _{Diagonal} | 94 | 74,5 | 94,5 | 78 |

Tablo 4.8. Farklı Gürültü Metotlarının LMT ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|------------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,068 |
| LBP _{L2R} (RGB) | 0,96 | 0,96 | 0,96 | 0,96 | 0,04 |
| LBP _{T2D} (Gaussian) | 0,966 | 0,965 | 0,965 | 0,965 | 0,037 |
| LBP _{surface} (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,049 |
| LBP _{Diagonal} (Gaussian) | 0,945 | 0,945 | 0,945 | 0,945 | 0,055 |

Tablo 4.7.'de kullandığımız verilere farklı gürültü metotları uygulanarak elde edilen verilerden çıkarılan özniteliklere LMT uygulanarak sınıflandırma başarı oranları gözlemlenmiştir. Yapılan çalışmada gürültü metodu uygulanmamış RGB verilerden LBP_{L2R} metodu ile elde edilen özniteliklerden %96'lık bir başarı oranı elde edilmiştir. En düşük başarı%72,5'lik oran ile tuz-biber gürültü metodu uygulanmış verilerden elde edilen özniteliklerden elde edilirken genel olarak RGB verilerden daha yüksek başarı oranları elde edilmiştir. Önerilen yaklaşımların gürültülere duyarlı olduğu görülmüştür.

Gürültülü görüntülerden elde edilen özniteliklerin J48 makine öğrenmesi yöntem ile gözlenen başarı oranları ve diğer performans ölçütleri Tablo 4.9 ve Tablo 4.10'da verilmiştir

Tablo 4.9. Farklı Gürültü Metotlarının J48 ile gözlenen başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|-------------------------|------|---------|----------|-------------|
| LBP | 87,5 | 59 | 75 | 65,5 |
| LBP _{L2R} | 97,5 | 62,5 | 83,5 | 66 |
| LBP _{T2D} | 96 | 66 | 91,5 | 67,5 |
| LBP _{surface} | 79,5 | 63,5 | 72 | 61 |
| LBP _{Diagonal} | 88 | 62 | 79 | 65 |

Tablo 4.10. Farklı Gürültü Metotlarının J48 ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|-------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,875 | 0,875 | 0,875 | 0,875 | 0,126 |
| LBP _{L2R} (RGB) | 0,975 | 0,975 | 0,975 | 0,975 | 0,025 |
| LBP _{T2D} (RGB) | 0,941 | 0,94 | 0,94 | 0,94 | 0,061 |
| LBP _{surface} (RGB) | 0,797 | 0,795 | 0,794 | 0,795 | 0,208 |
| LBP _{Diagonal} (RGB) | 0,905 | 0,905 | 0,905 | 0,905 | 0,094 |

Tablo 4.9.'da kullandığımız verilere farklı gürültü metotları uygulanarak elde edilen verilerden çıkarılan özniteliklere J48 algoritması uygulanarak sınıflandırma başarı oranları gözlemlenmiştir. RGB renk uzayından LBP_{L2R}metodu ile elde edilen özniteliklerden %97,5'lik en yüksek başarı oranı elde edilirken en düşük başarı oranı poisson gürültü metodu uygulanan verilerden elde edilen özniteliklerden %59'luk düşük bir cinsiyet sınıflandırma başarısı elde edilmiştir.

Gürültülü görüntülerinden elde edilen özniteliklerin lojistik regresyon makine öğrenmesi yöntem ile gözlenen başarı oranları ve diğer performans ölçütleri Tablo 4.11 ve Tablo 4.12'de verilmiştir.

Tablo 4.11. Farklı Gürültü Metotlarının Simple Logistic ile gözlenen başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|-------------------------|------|---------|----------|-------------|
| LBP | 95 | 74,5 | 91,5 | 72,5 |
| LBP _{L2R} | 94,5 | 78,5 | 93 | 68 |
| LBP _{T2D} | 94 | 77 | 94,5 | 68 |
| LBP _{surface} | 95 | 74 | 88,5 | 74,5 |
| LBP _{Diagonal} | 95 | 74,5 | 94,5 | 78 |

Tablo 4.12. Farklı Gürültü Metotlarının Simple Logistic ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|-------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,058 |
| LBP _{L2R} (RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,055 |
| LBP _{T2D} (Gaussian) | 0,966 | 0,965 | 0,965 | 0,965 | 0,037 |
| LBP _{surface} (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,049 |
| LBP _{Diagonal} (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,049 |

Tablo 4.11.'de kullandığımız verilere farklı gürültü metotları uygulanarak elde edilen verilerden çıkarılan özniteliklere Simple Logistic algoritması uygulanarak sınıflandırma başarı oranları gözlemlenmiştir. Bu çalışmada kullanılan orijinal RGB verilerden elde edilen özniteliklerden %95'e yakın bir sınıflandırma başarısı elde edilirken en düşük oran ise %72,5 ile tuz-biber gürültü metodu uygulanmış verilerden LBP metodu ile elde edilen özniteliklerin sınıflandırılmasından elde edilmiştir.

4.2. Yaş Tahmin Sonuçları

Bu çalışmada yaş tahminleme işleminde en yüksek sınıflandırma başarı oranının elde edilebilmesi için kullanılan veriler genç, orta ve yaşlı olmak üzere üç farklı sınıfa dağıtılarak her bir sınıfa uygulanan metotlarla öznitelik elde edilerek sınıflandırma algoritmaları ile sınıflandırma işlemi yapılmıştır. Cinsiyet tahmininde olduğu gibi yaş tahminleme işleminde de veriler farklı renk uzaylarına aktarılmış ve ayrıca farklı gürültü metotları uygulanarak en yüksek başarı oranları hedeflenmiştir.

4.2.1. Farklı Renk Uzaylarında Elde Edilen Özniteliklerin Sınıflandırma Başarısı

Yaş tahminleme için, önerilen metotların farklı renk uzaylarındaki görüntülerinden elde edilen öznitelikler LMT (Lojistik Model Ağacı Algoritması) ile sınıflandırma işlemine tabi tutulmuştur. Tüm yöntemlere ait başarı oranları ve diğer performans ölçütlerine ait başarılar Tablo 4.13 ve Tablo 4.14’te verilmiştir.

Tablo 4.13. Farklı renk uzaylarında LMT ile gözlenen başarı oranları

| Öznitelik | RGB | HSV | YCbCr | YIQ |
|-------------------------|------|------|-------|------|
| LBP | 82,5 | 83 | 92 | 81 |
| LBP _{L2R} | 88 | 82,5 | 88 | 94,5 |
| LBP _{T2D} | 86 | 82,5 | 89 | 94 |
| LBP _{surface} | 82,5 | 83 | 85,5 | 86 |
| LBP _{Diagonal} | 86 | 81,5 | 90,5 | 85,5 |

Tablo 4.14. Farklı renk uzaylarında LMT ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|---------------------------------|----------|------------|----------|---------|---------|
| LBP (YCbCr) | 0,914 | 0,92 | 0,915 | 0,92 | 0,262 |
| LBP _{L2R} (YIQ) | 0,941 | 0,945 | 0,94 | 0,945 | 0,19 |
| LBP _{T2D} (YIQ) | 0,937 | 0,94 | 0,938 | 0,94 | 0,167 |
| LBP _{surface} (YIQ) | 0,843 | 0,86 | 0,834 | 0,86 | 0,544 |
| LBP _{Diagonal} (YCbCr) | 0,89 | 0,905 | 0,893 | 0,905 | 0,356 |

Tablo 4.13.’te kullandığımız verileri farklı renk uzaylarına taşıyarak her bir renk uzayındaki verilere uygulanan metotlarla elde edilen özniteliklere LMT algoritması uygulanarak yaş sınıflandırma başarı oranları gözlemlenmiştir. Yapılan çalışmada YIQ renk uzayındaki verilerden LBP_{L2R} metodu ile elde edilen özniteliklerden %94,5 ile elde edilmiştir. En düşük sınıflandırma başarısı ise yine YIQ renk uzayında %81 ile LBP metodu elde edilen özniteliklerden elde edilmiştir.

Öznitelik grupları ile J48 metodun kullanılması ile elde edilen başarı oranları Tablo 4.15 ve Tablo 4.16’da verilmiştir.

Tablo 4.15. Farklı renk uzaylarında J48 ile gözlenen başarı oranları

| Öznitelik | RGB | HSV | YCbCr | YIQ |
|-------------------------|------|------|-------|------|
| LBP | 72,5 | 69,5 | 89 | 72,5 |
| LBP _{L2R} | 86 | 82,5 | 88 | 94,5 |
| LBP _{T2D} | 89,5 | 82,5 | 84,5 | 94 |
| LBP _{surface} | 80 | 84 | 83 | 79,5 |
| LBP _{Diagonal} | 77,5 | 79,5 | 87,5 | 81 |

Tablo 4.16. Farklı renk uzaylarında J48 ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|---------------------------------|----------|------------|----------|---------|---------|
| LBP (YCbCr) | 0,902 | 0,89 | 0,895 | 0,89 | 0,194 |
| LBP _{L2R} (YIQ) | 0,944 | 0,945 | 0,944 | 0,945 | 0,075 |
| LBP _{T2D} (YIQ) | 0,939 | 0,94 | 0,939 | 0,94 | 0,121 |
| LBP _{surface} (HSV) | 0,721 | 0,83 | 0,77 | 0,83 | 0,709 |
| LBP _{Diagonal} (YCbCr) | 0,869 | 0,875 | 0,871 | 0,875 | 0,358 |

Tablo 4.15.'te kullandığımız verileri farklı renk uzaylarına taşıyarak her bir renk uzayındaki verilere uygulanan metotlarla elde edilen özniteliklere J48 algoritması uygulanarak yaş sınıflandırma başarı oranları gözlemlenmiştir. Yapılan çalışmada YIQ renk uzayındaki verilerden LBP_{L2R} metodu ile elde edilen özniteliklerden %94,5 ile elde edilmiştir. En düşük sınıflandırma başarısı ise yine HSV renk uzayında %69,5 ile LBP metodu elde edilen özniteliklerden elde edilmiştir.

Öznitelik grupları ile lojistik regresyon metodun kullanılması ile elde edilen başarı oranları Tablo 4.17 ve Tablo 4.18'de verilmiştir.

Tablo 4.17. Farklı renk uzaylarında Simple Logistic ile gözlenen başarı oranları

| Öznitelik | RGB | HSV | YCbCr | YIQ |
|-------------------------|------|------|-------|------|
| LBP | 82,5 | 83 | 92 | 82 |
| LBP _{L2R} | 84,5 | 82,5 | 87,5 | 82,5 |
| LBP _{T2D} | 83,5 | 82,5 | 89,5 | 82,5 |
| LBP _{surface} | 82,5 | 83 | 86 | 83,5 |
| LBP _{Diagonal} | 86 | 82 | 90,5 | 82,5 |

Tablo 4.18. Farklı renk uzaylarında Simple Logistic ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|--------------------------------------|-----------------|-------------------|-----------------|----------------|----------------|
| LBP (YCbCr) | 0,912 | 0,92 | 0,911 | 0,92 | 0,285 |
| LBP_{L2R}(YCbCr) | 0,834 | 0,875 | 0,852 | 0,875 | 0,453 |
| LBP_{T2D}(YCbCr) | 0,862 | 0,895 | 0,877 | 0,895 | 0,38 |
| LBP_{surface}(YCbCr) | 0,853 | 0,86 | 0,845 | 0,86 | 0,478 |
| LBP_{Diagonal}(YCbCr) | 0,89 | 0,905 | 0,893 | 0,905 | 0,356 |

Tablo 4.17.'de elde edilen özniteliklerin sınıflandırma işleminde Simple Logistic kullanılmış ve YCbCr renk uzayındaki verilerden LBP_{Diagonal} metodu ile elde edilen özniteliklerden %90,5'lik bir başarı oranı elde edilmiştir.

4.2.2. Farklı Gürültü Metotları Uygulanarak Elde Edilen Özniteliklerin Sınıflandırma Başarısı

Görüntülere gürültü metotları ile varsayılan oranlarda gürültü eklenmiştir. Daha sonra yeni oluşan görüntülerden önerilen yaklaşımlar ile öznitelikler elde edilmiştir. Bu özniteliklerin LMT ile elde edilen başarı oranları Tablo 4.19 ve Tablo 4.20'de verilmiştir.

Tablo 4.19. Farklı Gürültü Metotlarının LMT ile başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|-------------------------------|------------|----------------|-----------------|------------------------|
| LBP | 82,5 | 82,5 | 84,5 | 82,5 |
| LBP_{L2R} | 88 | 82,5 | 86 | 83 |
| LBP_{T2D} | 86 | 80,5 | 88 | 82 |
| LBP_{surface} | 82,5 | 82 | 87 | 81,5 |
| LBP_{Diagonal} | 86 | 91 | 89 | 82,5 |

Tablo 4.20. Farklı Gürültü Metotlarının LMT ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|--|----------|------------|----------|---------|---------|
| LBP (Gaussian) | 0,816 | 0,845 | 0,825 | 0,845 | 0,478 |
| LBP_{L2R}(RGB) | 0,864 | 0,88 | 0,87 | 0,88 | 0,291 |
| LBP_{T2D}(Gaussian) | 0,869 | 0,88 | 0,874 | 0,88 | 0,291 |
| LBP_{surface}(Gaussian) | 0,864 | 0,87 | 0,866 | 0,87 | 0,269 |
| LBP_{Diagonal}(Poisson) | 0,9 | 0,91 | 0,9 | 0,91 | 0,354 |

Tablo 4.19’da farklı gürültü metotları uygulanan verilerden elde edilen özniteliklerden LMT ile sınıflandırma işlemi yapılmış olup en yüksek başarı yüzdesi %91 ile poisson ile elde edilirken en düşük oran %80,5 ile yine poisson gürültü metodu uygulanmış verilerden LBP_{T2D} metodu ile elde edilen özniteliklerden elde edilmiştir.

J48 makine öğrenmesi yöntemi ile elde edilen başarı oranları Tablo 4.21 ve Tablo 4.22’de verilmiştir.

Tablo 4.21. Farklı Gürültü Metotlarının J48 ile başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|-------------------------------|------|---------|----------|-------------|
| LBP | 72,5 | 74 | 84,5 | 72 |
| LBP_{L2R} | 86 | 77 | 84 | 72,5 |
| LBP_{T2D} | 89,5 | 72,5 | 85 | 72 |
| LBP_{surface} | 80 | 79,5 | 84 | 78 |
| LBP_{Diagonal} | 77,5 | 84,5 | 80,5 | 72 |

Tablo 4.22. Farklı Gürültü Metotlarının J48 ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|--|----------|------------|----------|---------|---------|
| LBP (Gaussian) | 0,852 | 0,845 | 0,848 | 0,845 | 0,293 |
| LBP_{L2R}(RGB) | 0,866 | 0,86 | 0,863 | 0,86 | 0,246 |
| LBP_{T2D}(RGB) | 0,893 | 0,895 | 0,894 | 0,895 | 0,265 |
| LBP_{surface}(Gaussian) | 0,838 | 0,84 | 0,839 | 0,84 | 0,342 |
| LBP_{Diagonal}(Poisson) | 0,879 | 0,845 | 0,861 | 0,845 | 0,289 |

Tablo 4.21’de J48 algoritması ile yapılan sınıflandırma işleminde LBP_{T2D} metodu ile elde edilen özniteliklerden %89,5 ile en yüksek sınıflandırma başarısı elde edilirken en düşük oran ise %72 ile tuz-biber gürültü metodu uygulanmış verilerden elde edilmiştir.

lojistik regresyon makine öğrenmesi yöntemi ile elde edilen başarı oranları Tablo 4.23 ve Tablo 4.24’de verilmiştir.

Tablo 4.23. Farklı Gürültü Metotlarının Simple Logistic ile gözlenen başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|------------------------------------|------|---------|----------|-------------|
| LBP | 82,5 | 82,5 | 82,5 | 82,5 |
| LBP_{L2R} | 84,5 | 82,5 | 82 | 82,5 |
| LBP_{T2D} | 83,5 | 81 | 88 | 82,5 |
| $LBP_{surface}$ | 82,5 | 82,5 | 82 | 81,5 |
| $LBP_{Diagonal}$ | 86 | 89 | 89 | 82 |

Tablo 4.24. Farklı Gürültü Metotlarının Simple Logistic ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|--|----------|------------|----------|---------|---------|
| LBP (Tüm Metotlar) | 0,857 | 0,89 | 0,87 | 0,89 | 0,427 |
| $LBP_{L2R}(RGB)$ | 0,805 | 0,845 | 0,823 | 0,845 | 0,433 |
| $LBP_{T2D}(Gaussian)$ | 0,869 | 0,88 | 0,874 | 0,88 | 0,291 |
| $LBP_{surface}(RGB-Poisson)$ | 0,792 | 0,825 | 0,789 | 0,825 | 0,663 |
| $LBP_{Diagonal}(Poisson-Gaussian)$ | 0,857 | 0,89 | 0,87 | 0,89 | 0,427 |

Tablo 4.23.’te Poisson ve Gaussian gürültü metotları uygulanmış verilerden $LBP_{Diagonal}$ metodu ile elde edilen özniteliklerin Simple Logistic ile sınıflandırma başarıları aynı olup %89 ile en yüksek başarı oranıdır. En düşük başarı oranı ise %81 ile poisson uygulanmış verilerden LBP_{T2D} metodu ile elde edilen özniteliklerin sınıflandırmasında elde edilmiştir.

4.3. Duygu Tahmin Sonuçları

Bu tez çalışmasında kullanılan verilerden duygu tahmini yapılmaya çalışarak aynı veriler üzerinde kişiye ait temel özelliklerden yaş ve cinsiyet dışında o anlık duygu durumunun tahmin edilmesi amaçlanmıştır. Bu çalışmada kullanılan verilerden duygu

tahmininin yapılabilmesi için gülüyor ve gülmüyor olmak üzere iki ayrı klasöre dağıtılarak her bir klasörden elde edilen öznitelikler sınıflandırma işleminde kullanılmıştır. Yaş ve cinsiyet tahminleme işleminde olduğu gibi duygu tahmininde de aynı sınıflandırma algoritmaları kullanılmıştır. Veriler farklı renk uzaylarına taşınmış ve farklı gürültü metotları uygulanmıştır.

4.3.1. Farklı Renk Uzaylarında Elde Edilen Özniteliklerin Sınıflandırma Başarısı

Duygu tahminleme için, önerilen metotların farklı renk uzaylarındaki görüntülerinden elde edilen öznitelikler LMT ile sınıflandırma işlemine tabi tutulmuştur. Tüm yöntemlere ait başarı oranları ve diğer performans ölçütlerine ait başarılar Tablo 4.25 ve Tablo 4.26’da verilmiştir.

Tablo 4.25. Farklı renk uzaylarında LMT ile gözlenen başarı oranları

| Öznitelik | RGB | HSV | YCbCr | YIQ |
|-------------------------------|------|------|-------|------|
| LBP | 94,5 | 71 | 84 | 75 |
| LBP_{L2R} | 90 | 58 | 89 | 96 |
| LBP_{T2D} | 86,5 | 52,5 | 89 | 97 |
| LBP_{surface} | 96 | 73 | 89,5 | 75,5 |
| LBP_{Diagonal} | 94,5 | 73 | 87,5 | 76,5 |

Tablo 4.26. Farklı renk uzaylarında LMT ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|------------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,05 |
| LBP_{L2R}(YIQ) | 0,96 | 0,96 | 0,96 | 0,96 | 0,04 |
| LBP_{T2D}(YIQ) | 0,97 | 0,97 | 0,97 | 0,97 | 0,03 |
| LBP_{surface}(RGB) | 0,96 | 0,96 | 0,96 | 0,96 | 0,04 |
| LBP_{Diagonal}(RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,054 |

Tablo 4.25.’te farklı renk uzaylarındaki verilerden uygulanan metotlarla elde edilen öznitelikler LMT algoritması ile sınıflandırma işlemine tabi tutulmuştur. Yapılan sınıflandırma işleminde YIQ renk uzayından LBP_{T2D} metodu ile elde edilen özniteliklerden %97’lik bir başarı oranı elde edilmiştir. En düşük sınıflandırma başarısı

%52,5 ile HSV renk uzayından LBP_{T2D} metodu ile elde edilen özneliklerden elde edilmiştir.

J48 makine öğrenmesi yöntemi ile elde edilen başarı oranları Tablo 4.27 ve Tablo 4.28’de verilmiştir.

Tablo 4.27. Farklı renk uzaylarında J48 ile gözlenen başarı oranları

| Öznelik | RGB | HSV | YCbCr | YIQ |
|-------------------------|------|------|-------|------|
| LBP | 80 | 58 | 83 | 57,5 |
| LBP _{L2R} | 87,5 | 55,5 | 92,5 | 97,5 |
| LBP _{T2D} | 82 | 52,5 | 88 | 98 |
| LBP _{surface} | 87 | 64 | 85 | 64,5 |
| LBP _{Diagonal} | 91 | 67,5 | 87 | 60 |

Tablo 4.28. Farklı renk uzaylarında J48 ile performans sonuçları

| Öznelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|-------------------------------|----------|------------|----------|---------|---------|
| LBP (YCbCr) | 0,831 | 0,83 | 0,83 | 0,83 | 0,169 |
| LBP _{L2R} (YIQ) | 0,975 | 0,975 | 0,975 | 0,975 | 0,025 |
| LBP _{T2D} (YIQ) | 0,98 | 0,98 | 0,98 | 0,98 | 0,019 |
| LBP _{surface} (RGB) | 0,87 | 0,87 | 0,87 | 0,87 | 0,13 |
| LBP _{Diagonal} (RGB) | 0,911 | 0,91 | 0,91 | 0,91 | 0,089 |

Tablo 4.27.’de J48 algoritması ile farklı renk uzaylarında duygu sınıflandırma tahmini yapılmış ve YIQ renk uzayından LBP_{L2R} metodu ile elde edilen özneliklerden %97,5’luk doğru bir sınıflandırma ile en yüksek başarı oranı elde edilmiştir. En düşük sınıflandırma başarısı ise %52,5 ile HSV renk uzayında elde edilmiştir.

Lojistik regresyon makine öğrenmesi yöntemi ile elde edilen başarı oranları Tablo 4.29 ve Tablo 4.30’da verilmiştir.

Tablo 4.29. Farklı renk uzaylarında Simple Logistic ile gözlenen başarı oranları

| Öznitelik | RGB | HSV | YCbCr | YIQ |
|-------------------------|------|------|-------|------|
| LBP | 95 | 71 | 79,5 | 74,5 |
| LBP _{L2R} | 88,5 | 58 | 78,5 | 73 |
| LBP _{T2D} | 88 | 51,5 | 76,5 | 74 |
| LBP _{surface} | 96 | 73 | 81 | 75,5 |
| LBP _{Diagonal} | 94,5 | 71,5 | 81,5 | 76,5 |

Tablo 4.30. Farklı renk uzaylarında Simple Logistic ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|-------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,05 |
| LBP _{L2R} (RGB) | 0,885 | 0,885 | 0,885 | 0,885 | 0,115 |
| LBP _{T2D} (RGB) | 0,88 | 0,88 | 0,88 | 0,88 | 0,12 |
| LBP _{surface} (RGB) | 0,96 | 0,96 | 0,96 | 0,96 | 0,04 |
| LBP _{Diagonal} (RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,054 |

Tablo 4.29.'da Simple Logistic ile yapılan sınıflandırma işleminde LBP ile RGB renk uzayından elde edilen özniteliklerden %95 ile en yüksek başarı yüzdesi elde edilmiştir. En düşük oran ise %51,5 ile HSV renk uzayından LBP_{T2D} metodu ile elde edilen özniteliklerden elde edilmiştir.

4.3.2. Farklı Gürültü Metotları Uygulanarak Elde Edilen Özniteliklerin Sınıflandırma Başarısı

Farklı gürültü yöntemleri ile görüntülere varsayılan oranlarda gürültüler eklenmiştir. Bu gürültülü görüntülerden önerilen LBP yöntemler ile elde edilen öznitelikler kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. LMT sınıflandırma metodu ile gözlenen başarı oranları Tablo 4.31 ve Tablo 4.32'de verilmiştir.

Tablo 4.31. Farklı Gürültü Metotlarında LMT ile başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|-------------------------|------|---------|----------|-------------|
| LBP | 94,5 | 76,5 | 84,5 | 66,5 |
| LBP _{L2R} | 90 | 79,5 | 77,5 | 45,5 |
| LBP _{T2D} | 86,5 | 78,5 | 83 | 50 |
| LBP _{surface} | 96 | 74 | 70 | 68,5 |
| LBP _{Diagonal} | 94,5 | 72,5 | 79 | 53,5 |

Tablo 4.32. Farklı Gürültü Metotlarında LMT ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|-------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,05 |
| LBP _{L2R} (RGB) | 0,901 | 0,9 | 0,9 | 0,9 | 0,101 |
| LBP _{T2D} (RGB) | 0,865 | 0,865 | 0,865 | 0,865 | 0,135 |
| LBP _{surface} (RGB) | 0,96 | 0,96 | 0,96 | 0,96 | 0,04 |
| LBP _{Diagonal} (RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,054 |

Tablo 4.31’de farklı gürültü metotları uygulanarak elde edilen verilere uygulanan öznitelik çıkarım metotlarına LMT uygulanarak sınıflandırma işlemi yapılmıştır. Yapılan sınıflandırma işleminde en iyi başarı oranı %94,5 ile RGB verilerden LBP ve LBP_{Diagonal} metotları ile elde edilen özniteliklerden elde edilmiştir. En düşük başarı yüzdeleri tuz-biber gürültü metodu uygulanmış verilerden elde edilmiştir. J48 kullanılarak gözlenen başarı oranları Tablo 4.33 ve tablo 4.34’te verilmiştir.

Tablo 4.33. Farklı Gürültü Metotlarında J48 ile başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|-------------------------|------|---------|----------|-------------|
| LBP | 80 | 75,5 | 59 | 58,5 |
| LBP _{L2R} | 87,5 | 67,5 | 67,5 | 49 |
| LBP _{T2D} | 82 | 72 | 76 | 50 |
| LBP _{surface} | 87 | 76,5 | 66 | 50,5 |
| LBP _{Diagonal} | 91 | 70,5 | 60 | 48,5 |

Tablo 4.34. Farklı Gürültü Metotlarında J48 ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|------------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,8 | 0,8 | 0,8 | 0,8 | 0,2 |
| LBP_{L2R}(RGB) | 0,875 | 0,875 | 0,875 | 0,875 | 0,126 |
| LBP_{T2D}(RGB) | 0,82 | 0,82 | 0,82 | 0,82 | 0,181 |
| LBP_{surface}(RGB) | 0,87 | 0,87 | 0,87 | 0,87 | 0,13 |
| LBP_{Diagonal}(RGB) | 0,911 | 0,91 | 0,91 | 0,91 | 0,089 |

Tablo 4.33.'te farklı gürültü metotları uygulanarak elde edilen verilere J48 algoritması ile yapılan sınıflandırma işleminde genel olarak RGB verilerden elde edilen özniteliklerden yüksek başarı yüzdeleri elde edilmiştir. En yüksek başarı oranı %91 ile LBP_{Diagonal} metodu ile elde edilen özniteliklerden elde edilmiştir. En düşük başarı oranı ise tuz-biber gürültü metodu uygulanarak elde edilen özniteliklerden elde edilmiştir. Lojistik regresyon kullanılarak gözlenen başarı oranları Tablo 4.35 ve tablo 4.36'da verilmiştir.

Tablo 4.35. Farklı Gürültü Metotlarında Simple Logistic ile gözlenen başarı oranları

| Öznitelik | RGB | Poisson | Gaussian | Salt&Pepper |
|-------------------------------|------|---------|----------|-------------|
| LBP | 95 | 70,5 | 84,5 | 66,5 |
| LBP_{L2R} | 88,5 | 79,5 | 77,5 | 48 |
| LBP_{T2D} | 88 | 79 | 82,5 | 50 |
| LBP_{surface} | 96 | 76 | 70,5 | 68,5 |
| LBP_{Diagonal} | 94,5 | 72,5 | 79,5 | 54,5 |

Tablo 4.36. Farklı Gürültü Metotlarında Logistic ile performans sonuçları

| Öznitelik | Kesinlik | Duyarlılık | F-Ölçütü | TP Oran | FP Oran |
|------------------------------------|----------|------------|----------|---------|---------|
| LBP (RGB) | 0,95 | 0,95 | 0,95 | 0,95 | 0,05 |
| LBP_{L2R}(RGB) | 0,885 | 0,885 | 0,885 | 0,885 | 0,115 |
| LBP_{T2D}(RGB) | 0,88 | 0,88 | 0,88 | 0,88 | 0,12 |
| LBP_{surface}(RGB) | 0,96 | 0,96 | 0,96 | 0,96 | 0,04 |
| LBP_{Diagonal}(RGB) | 0,945 | 0,945 | 0,945 | 0,945 | 0,054 |

Tablo 4.35.'te elde özniteliklere Simple Logistic uygulanarak duygu tahmini yapılmaya çalışılmıştır. Yapılan sınıflandırma işleminde RGB renk uzayındaki verilerden her bir metotla elde edilen özniteliklerden en yüksek başarı oranları elde edilmiştir. En düşük başarı oranı ise tuz-biber gürültü metodu uygulanarak elde edilen özniteliklerin sınıflandırılmasında elde edilmiştir.



5. TARTIŞMA

İmge işleme üzerine yapılan çalışmalar günümüzde çok geniş bir çalışma alanı elde etmiş ve her geçen gün popülaritesi artmaktadır. Bilimsel birçok alanda üstün başarılar elde edilmiş ve araştırmacıların sürekli yeni yaklaşımlar sunması ile başarısını arttıran imge işleme sayesinde hayatımızda birçok alanda kolaylık sağlanmıştır. İmge işleme ile kişilere ait yüz görüntüleri üzerinde yapılmış ve yapılmakta olan birçok çalışma mevcuttur. Günümüzde doku analizi ile ilgili çalışmalar her geçen gün artmakta ve popüler bir çözüm sunma yolunda hızla ilerlemektedir. İleri sürülen çeşitli yaklaşımlardan çoğu yapısal, model temelli, istatistiksel (histogram, mutlak gradyan, çalışma uzunluğu matrisi, ortak oluşum matrisi, oto-regresif model, dalgacıklar) ve dönüşüm bazlı yöntemlere (Castellano ve ark., 2004; Maani ve ark., 2013; Zhu ve ark., 2015) dayanmaktadır. En yaygın kullanılan yöntemler Local Binary Pattern (LBP), Grey Level Co-occurrence Matrix (GLCM) yöntemleridir. LBP, Ojala ve ark., (1996) tarafından önerilmiş doku sınıflandırma için kullanılan etkili en basit istatistiksel yaklaşımlardan biridir. Bir görüntünün veya görüntüdeki bir yerel yapının istatistiksel olarak yoğunluğunu belirtir. LBP görüntüdeki her pikseli, pikselin etrafında dairesel olarak oluşan komşu pikseller ile karşılaştırır (Pan ve ark., 2017).LBP yaklaşımında merkez piksel kendisine ait komşu piksellerin yerel farklılıklarından bağımsız olduğu varsayımına dayanmaktadır. LBP'yi başarılı kılan başlıca etmenler: diğer yöntemlere göre daha az hesaplama maliyeti, basit uygulanabilir olması ve en önemlisi güçlü bir ayırt edici olması LBP'nin başlıca avantajlarıdır. LBP güçlü bir doku analiz metodu olmasının yanında bazı dezavantajları da vardır. Bu dezavantajları şöyle açıklayabiliriz uzun dengesiz dağılmış histogramlar üretilmekte, görüntüler dönmeye bağımlıdır, gürültüye duyarlı ve büyük ölçekli dokuların algılanması zor olmaktadır bu durum etkili özelliklerin elde edilmesini zorlaştırmaktadır (Lian, 2015). Bundan dolayı LBP tabanlı farklı geliştirilmiş yeni yöntemler sunulmuştur.

Bu tez çalışmasında kişilere ait yüz resimlerinden LBP tabanlı dört farklı yeni yaklaşım ile elde edilen özniteliklerden kişiye ait temel özelliklerden yaş, cinsiyet ve duygu tahmini yapılmaya çalışılmıştır. Bu amaçla LBP_{L2R} , LBP_{T2D} , $LBP_{surface}$, $LBP_{Diagonal}$ şeklinde dört(4) farklı yaklaşım önerilmiştir. Önerilen yöntemler klasik LBP yöntemi ile de karşılaştırılmıştır. Önerilen yöntemler renkli görüntüler için kullanılmaktadır. Bu yöntemler ile görüntülerden daha az piksel bilgisi kullanarak

mikro bilgiler elde edilmektedir. Bu çalışmada FEI veri tabanındaki görüntüler kullanılmıştır. FEI kişi tanıma, cinsiyet tanıma gibi farklı amaçlar için kullanılan bu alanda popüler bir veri tabanıdır. FEI yüz veri tabanı, yaşları 19-70 arasında değişen FEI'de öğrenim gören veya çalışan 200 kişiye ait görüntülerden oluşmaktadır(Thomaz ve ark., 2010). Yapılan çalışmada yaş tahmini için kişiler genç, orta ve yaşlı olmak üzere üç ayrı yaş grubuna dağıtılmıştır. En iyi sınıflandırma sonuçlarının elde edilmesi için resimler RGB dışında farklı renk uzaylarına taşınmış ve farklı gürültü metotları uygulanarak en iyi durum ve en iyi sınıflandırma elde edilmeye çalışılmıştır. Cinsiyet sınıflandırma işlemi de bay ve bayan resimleri iki ayrı klasöre dağıtılarak öznitelikler elde edilmiştir. Cinsiyet tahmininde farklı renk uzaylarında ve farklı gürültü metotları uygulanmış verilerden öznitelikler elde edilmiştir. Duygu tahmininde de verilere yaş ve cinsiyet tahmininde uygulanan ön işlemlerin hepsi uygulanmıştır. Veriler gülüyor ve gülmüyor şeklinde sınıflandırılmaya çalışılmıştır. Bu sınıflandırma işlemleri için açık kaynak bir program olan Weka yazılımı kullanılmıştır. Farklı sınıflandırma metotları denenmiştir. Kullanılan yüz resimlerine uygulanan özellik çıkarım metotları ile elde edilen özniteliklere ilk önce denetimli bir sınıflandırma modeli olan LMT (Lojistik Model Ağacı Algoritması) algoritması uygulanmıştır. LMT Lojistik Regresyon ve Karar Ağacı Öğrenmesi algoritmalarını birleştiren bir algoritmadır. Üyelik fonksiyon kümeleri çıktısı veren ve IF-THEN kurallarına dayalı bir karar ağacı olup enformasyon kazancı en iyi olan J48 algoritması ile Simple Logistic algoritması da sınıflandırma işlemi için uygulanmıştır. Farklı sınıflandırma algoritmaları denenmiş olup en iyi sınıflandırma başarıları genel olarak uygulanan bu üç algordimada elde edilmiştir. Çalışmada sınıflandırma işlemi de kullanılan algoritmaların performanslarını değerlendirmek için doğruluk, duyarlılık, kesinlik ve F-ölçüsü kullanılmıştır. Algoritma performans ölçüleri elde edilirken hangi renk uzayında veya hangi gürültü metodunda en yüksek sınıflandırma başarıları elde edilmişse orda ki öznitelik çıkarım metodundan elde edilen veriler sınıflandırma işlemi de kullanılan sınıflandırma algoritmalarından elde edilmiştir. Sınıflandırma işlemi k=10 çapraz geçerlilik metoduna göre gerçekleştirilmiştir. Görüntülerden oluşturulan veri seti k=10 parçaya bölünmüştür. Sırası ile her parça test diğer parçalar eğitim seti olarak kullanılmıştır.

Yapılan çalışmada cinsiyet sınıflandırma işlemi de oldukça başarılı sonuçlar elde edilmiştir. Özellikle YIQ renk uzayına taşınmış yüz resimlerinden LBP_{T2D} metodu ile elde edilen özniteliklerden J48 ile yapılan sınıflandırma işlemi de %99,5 gibi yüksek bir başarılı sınıflandırma oranı elde edilmiştir (Tablo 4.3). Cinsiyet sınıflandırma da

kullanılan farklı gürültü metotları sınıflandırma başarı oranının düşmesine neden olmakta ve en iyi sınıflandırma RGB renk uzayındaki verilerden elde edilmiştir.

Yaş sınıflandırma işleminde YIQ renk uzayında LBP_{L2R} metodu ile elde edilen özneliklerin LMT ve J48 algoritmaları ile %94,5 gibi başarılı bir sınıflandırma oranı elde edilmiştir (Tablo 4.13).

Duygu tanımada da genel olarak YIQ renk uzayında LBP_{L2R} ve LBP_{T2D} metotları elde edilen özneliklerden başarılı sınıflandırmalar elde edilmiştir. En yüksek başarı oranı %97 gibi LBP_{T2D} ile elde edilmiştir (Tablo 4.25).

Gürültü farklı ışık, görüntü cihazlarından kaynaklanan faktörler yüzünden görüntü üzerindeki hatalardır. Gürültü görüntüdeki hem yerel hem de global özellikleri etkiler. Gürültü yüzünden doku tanıma ve sınıflama görevleri zor olmaktadır. Klasik LBP yönteminin bir dezavantajı gürültüye duyarlı olmasıdır. Bu yüzden bu çalışmada yeni dört LBP tanımlayıcısı önerilmiştir.

Önerilen yöntemlerin etkinliğini test etmek için yöntemler gürültülü görüntüler üzerinde test edilmiştir. Görüntülere Poisson, Guassian ve Salt-Pepper ile gürültü eklenmiştir. Poisson, Guassian ve Salt-Pepper ile gürültü değerleri varsayılan değerler ile eklenmiştir. Görüntülere gürültü eklendikten sonra elde edilen yeni görüntülerden önerilen yaklaşımlar ile öznelikler elde edilerek sınıflandırma işlemleri gerçekleştirilmiştir. Gürültü metotları genel olarak sınıflandırma başarı oranlarını düşürmektedir.

6. KAYNAKLAR

- Abdenour, H. and Matti, P., 2009. Combining appearance and motion for face and gender recognition from videos, *Pattern Recognition*, 42, 2818-2827
- Ahonen, T., Hadid, A., 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.
- Alvino, C., Kohler, C., Barrett, F., Gur, R., Verma, R., 2007. Computerized measurement of facial expression of emotions in schizophrenia”, *Journal of Neuroscience Methods*, cilt 163, no. 2, pp. 350-361
- Bing, L., Xiao, L., Bao, L., 2012. Gender classification by combining clothing, hair and facial component classifiers *Neuro computing*, 76, 18–27
- Butalia, A., Ingle, M., Kulkarni, P., 2012. Facial expression recognition for security, *International Journal of Modern Engineering Research (IJMER)*, cilt 2, no. 4, pp.1449-1453
- Caifeng, S., Shaogang, G., Peter, W., Owan, M., 2009. Facial expression recognition based on Local Binary Patterns: A comprehensive study. *Image and Vision Computing Image and Vision Computing*, 27, 803–816
- Caifeng, S., 2012. Learning Local binary patterns for gender classification on real-world face images, *Pattern Recognition Letters*, 33, 431–437
- Shan, C., Gong, S., McOwan, P.W., 2005, September. Robust facial expression recognition using local binary patterns. In *IEEE International Conference on Image Processing 2005* (Vol. 2, pp. II-370). IEEE.Castellano, G., Bonilha, L., Li, L.M., Cendes, F., 2004. Texture analysis of medical images, *Clin, Radiol*, 59, 1061–1069.
- Ce, L., Richard, S., Sing, K., Lawrence, Z., William, F., 2008. Automatic estimation and removal of noise from a single image. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30, 299–314
- Chao, L., Liu, Z., Ding, 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., Luu, K., 2011. Facial Feature Fusion and Model Selection for Age Estimation, *IEEE International Conference on Automatic Face & Gesture Recognition and Workshops (FG'11)*, 200-205
- Choi, E., Le, J., Lee, J., Park, R., Kim, J., 2011. Age estimation using a hierarchical classifier based on global and local facial features, *Pattern Recognition*, 44, 1262-1281
- Coşar, K., 2018. Görüntü İşleme Renk Uzayları [Online], <http://kubracosar.blogspot.com/2018/05/goruntu-isleme-renkuzaylari.html>, [Ziyaret Tarihi: 10 Ocak 2019]
- Darwin, C. and Phillip P., 1998. The expression of the emotions in man and animals. *Oxford University Press, USA*

- Dehshibi, M. and Bastanfard, A., 2010. A new algorithm for age recognition from facial images, *Signal Processing*, 90, 2431-2444
- Dureha, A., 2014. An accurate algorithm for generating a music playlist based on facial expressions, *International Journal of Computer Applications*, cilt 100, no. 9, pp.33-39
- Fasel, B., and Luetttin, J., 2003. Automatic Facial Expression Analysis: A Survey, *Pattern Recognition*, cilt 36, pp. 259-275
- Fu, Y. and Huang, S., 2008. Human Age Estimation with Regression on Discriminative Aging Manifold, *IEEE Transactions on Multimedia*, 10, 578-584
- Geng, X., Zhou, H., Miles, S., 2007. Automatic Age Estimation Based on Facial Aging Patterns, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(12), 2234-2240
- Gil, L. and Tal, H., 2015. Age and Gender Classification using Convolutional Neural Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 34-42.
- Günay, A., ve Nabiyev, V., 2016. Yüz Bölgelerinin Yaş Tahmini Başarımlarının Yaş Gruplarına Göre Değerlendirilmesi, *Türkiye Bilişim Vakfı Bilgisayar Bilimleri Ve Mühendisliği Dergisi*, 9.2, 1-10.
- Gutta, S., Wechsler, H., Phillips, P., 1998. Gender and ethnic classification of face images. In: *Third IEEE International Conference on Automatic Face and Gesture Recognition*, 194–199.
- Hachisuka, S., 2013. Human and Vehicle Drowsiness Detection by Facial Expression, *International Conference on Biometrics and Kansei Engineering (ICBAKE)*, Tokyo.
- Happy, L., Anjith, G., Aurobinda, R., 2012. A Real Time Facial Expression Classification System Using Local Binary Patterns. *4th International Conference on Intelligent Human Computer Interaction (IHCI)*. IEEE, p. 1-5.
- Jabid, T., Kabir, H., Chae, O., 2010. Gender Classification using Local Directional Pattern (LDP), 2010 *International Conference on Pattern Recognition, IEEE*, 2162-2165.
- Jabon, E., Bailenson, J., Pontikakis, L., Takayama, L., Nass, C., 2011. Facial expression analysis for predicting unsafe driving behavior, *IEEE Pervasive Computing*, cilt 10, 84-95
- Kaya, Y., Ertuğrul, Ö. F., Tekin, R., 2015. Two novel local binary pattern descriptors for texture analysis, *Applied Soft Computing*, 34, 728-735.
- Khorsandi, R., and Abdel-Mottaleb, M., 2013. Gender classification using 2-D ear images and sparse representation, *Applications of Computer Vision (WACV)*, 2013 *IEEE Workshop on vol*, 461,466
- Kumaria, J., Rajesh, R., Poojaa, K., 2015. Facial expression recognition: A survey, *Second International Symposium on Computer Vision and the Internet (Vision Net'15)*, Kochi.
- Lanitis, A., Taylor J., Cootes, F., 2002. Toward automatic simulation of aging effects On face images, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24, 442-455.

- Li, L. and Pengfei S., 2009. A Novel Fusion-Based method for Expression- Invariant Gender Classification, *IEEE Transaction*, 1065-1068
- Liao, S., Law, M. W., Chung, A. C., 2009. Dominant local binary patterns for texture classification, *IEEE transactions on image processing*, 18 (5), 1107-1118.
- Liu, L., Liu, J., Cheng, J., 2012. Age-Group Classification of Facial Images, *11th International Conference on Machine Learning and Applications (ICMLA'12)*, 693-696
- Lu, G., Yuan, L., Li, X., Li, H., 2008. facial expression recognition of pain in neonates, *International Conference on Computer Science and Software Engineering, Wuhan. IEEE*. Vol. 1, pp. 756-759.
- Lu, G., Li, X., Li, H., 2008. Facial expression recognition for neonatal pain assessment, *International Conference on Neural Networks and Signal Processing*, Nanjing. IEEE. pp. 456-460.
- Maani, R., Sanjay K., Yee-Hong Y., 2013. Noise robust rotation invariant features for texture classification, *Pattern Recognition* 46.8: 2103-2116.
- Mandal, K. Pandey, R., Prasad, A., 1998. Facial expressions of emotions and schizophrenia: A review, *Schizophrenia Bulletin*, cilt 24, no. 3, 399-412
- Martins, P., Sampaio, J., Batista, J., 2008 Facial expression recognition using active appearance models, *International Conference on Computer Vision Theory and Applications (VISAPP), Funchal*.
- Mehriban, A., 1968. Communication without words, *Psychology Today*, cilt 2, no. 4, 55-56
- Moghaddam, B. and Yang, M., 2002. Learning gender with support faces. *IEEETrans. PAMI* 24 ,5, 707-711
- Nanni, L., Lumini, A., Brahnam, S., 2010. Local binary patterns variants as texture descriptors for medical image analysis, *Artificial intelligence in medicine*, 49 (2), 117-125.
- Neoh, S., Zhang, L., Mistry, K., Hossain, M., Lim, C., Nauman-Aslam, M., 2015. Intelligent facial emotion recognition using a layered encoding cascade optimization model, *Elsevier Applied Soft Computing*, cilt 34, pp. 72-93
- Ojala, T., Pietikainen, M., Maenpaa, T., 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 24 (7), 971-987.
- Paul, E., 1975. A Guide To Recognizing Emotions From Facial Expressions. Libraries Australia, *Prentice Hall*. ISBN: 0-13-938183-X.
- Phillips, J., Grother, J., Micheals, R., Blackburn, M., Tabassi, E., Bone, M., 2003. *Face recognition vendor test 2002: Evaluation report* (No. NIST Interagency/Internal Report (NISTIR)-6965.
- Ramesha, K.B.R.K., Raja, K.B., Venugopal, K.R., Patnaik, L.M., 2010. Feature extraction based face recognition, gender and age classification. *International Journal on Computer Science and Engineering*, Vol. 02, No.01S, 2010, 14-23 .

- Sai, K., Wang, G., Teoh, K., 2015. Facial age range estimation with extreme learning machines, *Neurocomputing*, 149, 364-372
- Siyao, F., Haibo, H., Zeng-Guang, H., 2014. Learning Race from Face, *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2483-2509.
- Tenekeci, M. E. ve Aslan, E., 2014 Görüntüden Opencv ile Duygu Analizi, *Akademik Bilişim '14*, Mersin, 861-865.
- Valinskiy, A., Kriminoloji, *Yur nauki, Russia* 1999.
- Ylioinas, J., Hadid, A., Pietikainen, M., 2012. Age Classification in Unconstrained Conditions Using LBP Variants. *In Pattern Recognition (ICPR), 21st International Conference* on pp. 1257-1260
- Zhang, L., Chen, S., Wang, T., Liu, Z., 2012. Automatic facial expression recognition based on hybrid features. *Energy Procedia*, 17, 1817-1823.
- Zhao, G. and Pietikainen, M., 2007. Dynamic texture recognition using local binary patterns with an application to facial expressions. *IEEE transactions on pattern analysis and machine intelligence*, 29 (6), 915-928.
- Weixing, L., Haijun, S., Feng, P., Qi, G., Shaoyan, G., 2014. Facial Age Classification. *Based on Weighted Decision Fusion, Proceedings of the 33rd Chinese Control Conference*, 4870- 4874

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı :Ali YILMAZ
Doğum Yeri ve Tarihi :BULANIK/1987
Telefon :5418717128
E-posta :aliyilmaz@yyu.edu.tr

EĞİTİM

| Derece | | Bitirme Yılı |
|------------|---------------------------------|--------------|
| Lise | : Muş Anadolu Lisesi | 2007 |
| Üniversite | : Süleyman Demirel Üniversitesi | 2014 |

İŞ DENEYİMLERİ

| Yıl | Kurum | Görevi |
|-------------------|------------------------------|-----------|
| 2013-Devam Ediyor | Van Yüzüncü Yıl Üniversitesi | Programcı |

UZMANLIK ALANI: Network, Sistem, Güvenlik