

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İSTATİSTİK VE BİLGİSAYAR BİLİMLERİ ANABİLİM DALI

**MAKİNE ÖĞRENMESİ İLE GERÇEK ZAMANLI VİDEODAN
YÜZ İFADESİ ANALİZİ**

YÜKSEK LİSANS TEZİ

Muhammet Bekir DABANOĞLU

HAZİRAN 2018

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İSTATİSTİK VE BİLGİSAYAR BİLİMLERİ ANABİLİM DALI

MAKİNE ÖĞRENMESİ İLE GERÇEK ZAMANLI VİDEODAN
YÜZ İFADESİ ANALİZİ

Muhammet Bekir DABANOĞLU

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"YÜKSEK LİSANS (İSTATİSTİK)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 25/05/2018
Tezin Savunma Tarihi : 26/06/2018

Tez Danışmanı: Dr.Öğr.Üyesi TOLGA BERBER

Trabzon 2018

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İstatistik ve Bilgisayar Bilimleri Anabilim Dalında
Muhammet Bekir DABANOĞLU Tarafından Hazırlanan

MAKİNE ÖĞRENMESİ İLE GERÇEK ZAMANLI VİDEODAN
YÜZ İFADESİ ANALİZİ

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 29/05/2018 gün ve 1755 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Doç. Dr. Kamil ALAKUŞ

Üye : Dr. Öğr. Üyesi Tolga BERBER

Üye : Dr. Öğr. Üyesi Uğur ŞEVİK

Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

Bu çalışmayı yapmamın asıl amacı, içinde bulunduğumuz çağda, neredeyse her gün yeni bir gelişme kateden, anlayan, öğrenebilen ve insanlarla iletişim kuran yazılımların gelişmesiydi. Bu yıl, Mountain View'deki I/O Konferansında, Google, telefonla randevu alan çok doğal bir Google Asistan'ı yayınladı. Bu yapay zeka, karşıdaki çalışanı, insan olduğuna ikna edebildi ve pratikte Turing Testi aşılmış oldu. İnsan ile yapay zekayı birbirinden ayırmanın zorlaştığı bu günlerde, hayret ve hayranlıkla izlediğim bu çalışmaların biraz olsun içinde olmak için yüz ifadeleri tanıma çalışmasını seçtim. Çünkü iyi bir insan bilgisayar etkileşiminin, insanları anlayabilen yazılımlar yardımı ile olacağına inanıyorum.

Öncelikle beni anlayış ve sevgiyle destekleyen aileme, bu çalışmayı gerçekleştirmem için bana yol gösteren, yardımlarını esirgemeyen Dr. Tolga BERBER' e ve eğitim hayatım boyunca bana rehberlik eden ve bilgilerini esirgemeyen tüm hocalarıma teşekkür ederim.

Muhammet Bekir DABANOĞLU
Trabzon 2018

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Makine Öğrenmesi İle Gerçek Zamanlı Videodan Yüz İfadesi Analizi” başlıklı bu çalışmayı baştan sona kadar danışmanım Dr.Öğr. Üyesi Tolga BERBER’in sorumluluğunda tamamladığımı, verileri kendim topladığımı, analizleri ilgili laboratuvarlarda yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 26/06/2018

Muhammet Bekir DABANOĞLU

İÇİNDEKİLER

| | <u>Sayfa No</u> |
|---|-----------------|
| ÖNSÖZ | III |
| TEZ ETİK BEYANNAMESİ..... | IV |
| İÇİNDEKİLER..... | V |
| ÖZET | IX |
| SUMMARY | X |
| ŞEKİLLER DİZİNİ | XI |
| TABLolar DİZİNİ..... | XII |
| SEMBOLLER DİZİNİ | XIV |
| 1. GENEL BİLGİLER..... | 1 |
| 1.1. Giriş | 1 |
| 1.2. FACS Yüz Kodlama Sistemi..... | 2 |
| 1.2.1. Mutluluk İfadesi | 3 |
| 1.2.2. Üzüntü İfadesi | 3 |
| 1.2.3. Şaşırma İfadesi | 4 |
| 1.2.4. Korku İfadesi..... | 4 |
| 1.2.5. Tikslenme İfadesi | 4 |
| 1.2.6. Öfke İfadesi | 4 |
| 1.3. Sayısal Görüntü İşleme | 5 |
| 1.4. Yüz Görüntüsü Elde Etme..... | 6 |
| 1.4.1. Haar Öznitelik Tabanlı Basamaklı Sınıflandırıcılar | 6 |
| 1.5. Öznitelik Elde Etme | 10 |

| | | |
|------------|--|----|
| 1.5.1. | Yerel İkili Örüntüler | 11 |
| 1.6. | Ön İşleme Adımları | 13 |
| 1.6.1. | Gauss Yumuşatma Filtresi Uygulaması | 13 |
| 1.7. | Makine Öğrenmesi | 14 |
| 1.7.1. | Makine Öğrenmesi Kategorileri | 15 |
| 1.7.2. | Bazı Makine Öğrenmesi Yöntemleri | 17 |
| 1.7.2.1. | K En Yakın Komşu Sınıflama Yöntemi | 17 |
| 1.7.2.2. | Yalın Bayes Sınıflama Yöntemi | 18 |
| 1.7.2.3. | Destek Vektör Makineleri Sınıflama Yöntemi | 19 |
| 1.7.2.3.1. | DVM Sınıflandırıcılarda Verilerin Doğrusal Ayrılabilirlik Durumu | 19 |
| 1.7.2.3.2. | DVM Sınıflandırıcılarda Verilerin Doğrusal Ayrılamama Durumu | 23 |
| 1.8. | Önceki Çalışmalar | 25 |
| 1.8.1. | Yüz Görüntüsü Elde Etme | 25 |
| 1.8.1.1. | Bilgi Tabanlı Yöntemler | 25 |
| 1.8.1.2. | Öznitelik Tabanlı Yöntemler | 26 |
| 1.8.1.3. | Şablon Eşleme Yöntemleri | 27 |
| 1.8.1.4. | Görünüşe Dayalı Yöntemler | 27 |
| 1.8.2. | Öznitelik Elde Etme | 28 |
| 1.8.3. | Sınıflandırıcı Tasarımı | 29 |
| 2. | YAPILAN ÇALIŞMALAR | 31 |
| 2.1. | Kullanılan Veritabanı | 31 |
| 2.2. | Yüz Görüntüsü Elde Etme ve Ön İşlemler | 31 |
| 2.3. | Öznitelik Elde Etme | 32 |

| | | |
|--------|---|----|
| 2.4. | Yüz İfadeleri Tanıma İçin Makine Öğrenmesi..... | 32 |
| 2.5. | Öğrenme Doğruluğunu Arttırmak İçin Yapılan İşlemler | 33 |
| 2.5.1. | Normalizasyon İşlemleri | 33 |
| 2.5.2. | Öznitelik Altküme Seçimi | 33 |
| 2.5.3. | Adaboost Hızlandırma Algoritması..... | 34 |
| 3. | BULGULAR, TARTIŞMA..... | 35 |
| 3.1. | Yüz İfadelerinin Bireysel Sınıflandırma Performansları..... | 35 |
| 3.2. | Veri seti-1 | 37 |
| 3.3. | Veri seti-2..... | 37 |
| 3.4. | Veri seti-3..... | 38 |
| 3.5. | Veri seti-4..... | 38 |
| 3.6. | Veri seti-5..... | 39 |
| 3.7. | Veri seti-6..... | 39 |
| 3.8. | Veri seti-7..... | 40 |
| 3.9. | Veri seti-8..... | 40 |
| 3.10. | Veri seti-9..... | 41 |
| 3.11. | Veri seti-10..... | 41 |
| 3.12. | Veri seti-11 | 42 |
| 3.13. | Veri seti-12..... | 42 |
| 3.14. | Veri seti-13..... | 43 |
| 3.15. | Veri seti-14..... | 43 |
| 3.16. | Veri seti-15..... | 44 |
| 3.17. | Veri seti-16..... | 44 |
| 3.18. | Veri seti-17..... | 45 |
| 3.19. | Veri seti-18..... | 45 |

| | | |
|----------|--|----|
| 3.20. | Veri seti-19 | 46 |
| 3.21. | Veri seti-20 | 46 |
| 3.22. | Öğrenme Hata Matrisi | 47 |
| 3.23. | Adaboost Algoritmasının Öğrenme Doğruluğuna Etkisi | 47 |
| 3.24. | Öznitelik Altküme Seçiminin Öğrenme Doğruluğuna Etkisi..... | 48 |
| 3.25. | Elde Edilen En Başarılı Modelin Gerçek Zamanlı Videoya Uygulanması | 48 |
| 4. | SONUÇLAR | 50 |
| 5. | ÖNERİLER | 51 |
| 6. | KAYNAKÇA | 52 |
| 7. | EKLER | 57 |
| ÖZGEÇMİŞ | | |

Yüksek Lisans

ÖZET

MAKİNE ÖĞRENMESİ İLE GERÇEK ZAMANLI VİDEODAN YÜZ İFADESİ
ANALİZİ

Muhammet Bekir Dabanoglu

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
İstatistik ve Bilgisayar Bilimleri Anabilim Dalı
Danışman: Yrd. Doç. Dr. Tolga BERBER
2018, 56 Sayfa, 1 Ek Sayfa

Bu çalışmada, altı temel ifadeden oluşan, mutluluk, üzüntü, korku, tikslenme, şaşırma ve öfke ifadelerinin, makine öğrenmesi yardımıyla, kişiden bağımsız olarak gerçek zamanlı videodan tanınması amaçlanmıştır.

Yüz ifadesi tanınmanın üç hayati adımı bulunmaktadır. Bunların ilki, görüntüden yüz görüntüsü elde etmek, ikincisi ifadeleri iyi temsil edecek öznitelikler elde etmek ve son adım ise başarılı bir makine öğrenme yöntemi ile birlikte ifade tanınmanın gerçekleştirilmesidir. Çalışmada görüntüden yüz görüntüsü elde etmek için “Haar Basamaklı Sınıflandırıcıları Yöntemi” kullanılmıştır. Elde edilen yüz görüntülerinden ifadeleri temsil etmek için İkili Yerel Örüntüler (Local Binary Pattern - LBP) öznitelik olarak kullanılmış ve son olarak bu öznitelikler çeşitli makine öğrenmesi yöntemleri ile sistematik olarak Cohn-Canadian veritabanından alınan görüntülerden çeşitli verisetleri oluşturularak incelenmiştir. Yapılan kapsamlı analizlerde Yerel İkili Örüntülerin yüz ifadesi tanımada etkili olduğu gözlemlenmiştir. Deneylerden sonra, yüz ifadesi tanımada en başarılı bulunan yöntem ve veri seti, gerçek zamanlı videodan alınan görüntüler üzerinde denenmiş ve sonuçlar çalışma içerisinde sunulmuştur.

Elde edilen sonuçlara göre, dört sınıftan (ifadesiz, mutluluk, şaşırma ve üzüntü) oluşan veri seti, Destek Vektör Makineleri sınıflandırıcı kullanılarak en yüksek tanıma oranı olan %85,37 tanıma doğruluğuna ulaşılmıştır. İncelenen temel altı yüz ifadesi içerisinde diğer sınıflarla en az karıştırılan iki duygu ise şaşırma ve mutluluk olarak gözlemlenmiştir.

Anahtar Kelimeler: Yüz İfadesi Analizi, Görüntü İşleme, Yerel İkili Örüntüler, Makine Öğrenmesi

Master Thesis

SUMMARY

FACIAL EXPRESSION ANALYSIS ON REAL-TIME VIDEO USING MACHINE
LEARNING

Muhammet Bekir Dabanođlu

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Statistical and Computer Science Graduate Program
Supervisor: Assist. Prof. Tolga BERBER
2018, 56 Pages, 1 Page Appendix

The purpose of this work is to recognize six basic expressions such as happiness, sadness, fear, disgust, surprise and anger streamed from a real-time video, using machine learning methods.

There are three vital steps in recognition of a facial expression. The first step is to obtain a face from the image, the second is to obtain the feature that will best represent the facial expression and the final step is to recognize facial expression with a successful machine learning method. In this work, to retrieve the facial image, "Haar Cascade Method" was used as well as Local Binary Patterns (LBP) for features to represent facial expressions. Finally, these attributes were systematically analyzed by using various machine learning methods and by generating various datasets from the images extracted from the John-Canadian Database. Local Binary Patterns (LBP) were observed to be effective to recognize the face expression as a result of comprehensive analysis. The most successful method and dataset in recognition of facial expressions were selected and tested on a real-time video stream followed by the results being presented in the study.

According to these results, which consist of four class datasets (neutral, happiness, surprise and sadness) reached the highest recognition rate of 85,37% using the Support Vector Machine classifier and among the six basic facial expressions, happiness and surprise have highest recognition rate.

Keywords: Facial Expression Analysis, Image Processing, Local Binary Patterns, Machine Learning

ŞEKİLLER DİZİNİ

| | <u>Sayfa No</u> |
|---|------------------------|
| Şekil 1. Örnek eylem birimleri (AU)..... | 3 |
| Şekil 2. Altı temel yüz ifadesi | 5 |
| Şekil 3. Sayısal görüntü ve temsili pikseller | 6 |
| Şekil 4. Sırasıyla, kenar özellikleri, çizgi özelliği ve dört dikdörtgen özellik..... | 7 |
| Şekil 5. İntegral görüntü hesaplama örneği..... | 8 |
| Şekil 6. Adaboost algoritması tarafından seçilen önemli Haar öznitelikleri | 9 |
| Şekil 7. Basamaklı sınıflandırıcının blok diyagramı | 10 |
| Şekil 8. Basit LBP operatörü..... | 11 |
| Şekil 9. Genişletilmiş LBP örnekleri..... | 12 |
| Şekil 10. Doğrusal ayrılabilen veri örneği..... | 20 |
| Şekil 11. Küçük ve büyük sınırlar | 21 |
| Şekil 12. Destek vektörleri gösterimi | 22 |
| Şekil 13. İki boyutta doğrusal ayıramayacak veri örneği..... | 24 |
| Şekil 14. Öznitelik olarak kullanılan yerel histogramlar..... | 32 |
| Şekil 15. Sistemin blok diagramı..... | 48 |
| Şekil 16. Yazılım çıktıları..... | 49 |

TABLULAR DİZİNİ

| | <u>Sayfa No</u> |
|--|------------------------|
| Tablo 1. Yüz ifadeleri tanımada göreceli performanslar | 30 |
| Tablo 2. Yüz ifadelerinin bireysel sınıflandırma performansları..... | 35 |
| Tablo 3. İncelenen veri versiyonları | 36 |
| Tablo 4. Veri seti-1 sınıflandırma performansları | 37 |
| Tablo 5. Veri seti-2 sınıflandırma performansları | 37 |
| Tablo 6. Veri seti-3 sınıflandırma performansları | 38 |
| Tablo 7. Veri seti-4 Sınıflandırma performansları..... | 38 |
| Tablo 8. Veri seti-5 sınıflandırma performansları | 39 |
| Tablo 9. Veri seti-6 sınıflandırma performansları | 39 |
| Tablo 10. Veri seti-7 sınıflandırma performansları | 40 |
| Tablo 11. Veri seti-8 sınıflandırma performansları | 40 |
| Tablo 12. Veri seti-9 sınıflandırma performansları | 41 |
| Tablo 13. Veri seti-10 sınıflandırma performansları | 41 |
| Tablo 14. Veri seti-11 sınıflandırma performansları | 42 |
| Tablo 15. Veri seti-12 sınıflandırma performansları | 42 |
| Tablo 16. Veri seti-13 sınıflandırma performansları | 43 |
| Tablo 17. Veri seti-14 sınıflandırma performansları | 43 |
| 1Tablo 18. Veri seti-15 sınıflandırma performansları | 44 |
| Tablo 19. Veri seti-16 sınıflandırma performansları | 44 |
| Tablo 20. Veri seti-17 sınıflandırma performansları | 45 |
| Tablo 21. Veri seti-18 sınıflandırma performansları | 45 |
| Tablo 22. Veri seti-19 sınıflandırma performansları | 46 |

| | |
|--|----|
| Tablo 23. Veri seti-20 sınıflandırma performansları | 46 |
| Tablo 24. Öğrenme hata matrisi..... | 47 |
| Tablo 25. Adaboost algoritmasının öğrenme doğruluğuna etkisi..... | 47 |
| Tablo 26. Öznitelik altküme seçiminin öğrenme doğruluğuna etkisi | 48 |



SEMBOLLER DİZİNİ

| | |
|-------------|--|
| FACS | : Yüz Hareket Kodlama Sistemi |
| AU | : Eylem Birimi |
| LBP | : Yerel İkili Örüntüler |
| ELBP (P, R) | : R yarıçaplı, P piksel komşuluklu genişletilmiş yerel ikili örüntüler |
| $LBP_{P,R}$ | : R yarıçaplı, P piksel komşuluklu genişletilmiş yerel ikili operatörler |
| LBP^{u2} | : Düzgün Örüntüler İçin LBP Operatörü |
| MP | : Merkezi Piksel |
| K-EYK | : K En Yakın Komşu |
| $P(A B)$ | : A olayının, B olayı gerçekleştiğindeki olasılığı |
| MSH | : Maksimum Sınıra Sahip Hiperdüzlem |
| CK | : Cohn-Kanade Veritabanı |
| HÖTBS | : Haar Öznitelik Tabanlı Basamaklı Sınıflandırıcılar |
| GYM | : Gauss Yumuşatma Filtresi |
| YB | : Yalın Bayes |
| DVM | : Destek Vektör Makinaları |
| MMN | : Minimum-Maksimum Normalizasyonu |
| JAFFE | : 10 japon kadından oluşan yüz ifadesi veri tabanı. |
| FACE94 | : Essex Üniversitesi tarafından hazırlanmış yüz ifadesi veri tabanı |
| CMUDB | : Carnegie Mellon Üniversitesi tarafından hazırlanan yüz ifadesi veri tabanı |

1. GENEL BİLGİLER

1.1. Giriş

İnsanlığın ilk dilinin yüz ifadeleri ve mimikler olduğunu söylemek yanlış olmayacaktır. Yüz ifadeleri ve mimikler, yeni doğan bir bebek ve annesi arasında dil kullanmadan önce zihinsel temas kurmanın yoludur. Dolayısıyla, duyguları ve düşünceleri ifade etmek için yüz ifadelerini kullanmak doğuştan gelen bir yetenek ve evrensel bir iletişim kurma şeklidir. Bu ifadeler ve mimiklerin hayvanların da birbirleriyle iletişim kurma yolu olduğu kabul edilmektedir. Darwin 1872'de yaptığı çalışmalarda, memeli hayvanlar ile insanların yüz ifadelerinde benzerlikler olduğunu belirtmiştir [1]. Yüzümüz vücudumuzun karmaşık, oldukça farklılaşmış bir parçasıdır ve insanoğlu için en karmaşık sinyal sistemlerinden biridir. Her biri birbirinden bağımsız olarak tetiklenebilen 40'tan fazla işlevsel otonom kas içerir. Derimizin altındaki bu kaslar, birçok konfigürasyon üretmemizi sağlar. Bu konfigürasyonlar ise duyguları oluşturur. Genel olarak yüz ifadeleri, insanların, yaşadıkları duygu veya düşünceyi göstermek için yaptıkları ani ve istem dışı yüz hareketlerdir. Dolayısıyla duygu ve düşünceleri analiz etmek için kelimelerden daha gerçekçidir çünkü taklit edilmesi ya da gizlenmeleri neredeyse imkansızdır. Psikoloji Profesörü olan A. Mehrabian, sözlü ve sözsüz mesajların göreceli önemleriyle ilgili çalışmalar yapmıştır ve insanlar arası iletişimde %7-%38-%55 kuralıyla tanınmıştır. Bu kurala göre insanlar arasındaki iletişimde %7 sözler, %38 oranında ses tonu ve %55 oranında ise beden dili önemlidir [2]. Bu kuraldan yola çıkarak başarılı bir insan bilgisayar etkileşimi, insanların yüz ifadelerini anlayabilen ve yorumlayabilen bilgisayarlarla oluşacaktır ancak otomatik yüz ifadesi analizi zorlu bir sorundur, insan bilgisayar etkileşimi ve veriye dayalı canlandırma gibi birçok alanda önemli uygulamaları mevcuttur. Geniş uygulama yelpazesi dolayısıyla, son yıllarda dikkat çeken bir çalışma alanıdır. Birçok ilerleme kaydedilmesine rağmen, yüksek doğrulukla yüz tanıma kişiden kişiye oluşan nüanslar ve yüz ifadelerinin çeşitliliğinden dolayı zordur. Yüz ifadeleri, evrensel altı duygudan oluşur; Kızgınlık, korku, üzüntü, mutluluk, şaşırma, tikslenme. Bu duygular herhangi insan ırkına ya da millete göre değişmeyen sabit duygulardır [3][1].

Yüz ifadeleri, kişinin duygusal durumlarına, niyetlerine veya sosyal iletişimlerine tepki olarak gelişen yüzdeki değişikliklerdir. Gözlerimizin zahmetsizce ve anlık

tanımlayabildiği yüz ifadeleri bilgisayarlar açısından zahmetli ve zor bir süreçtir. Genel olarak, yüz ifadesi tanıma 3 temel adımı içermektedir[62]:

- Yüz Görüntüsü Elde Etme
- Öznitelik çıkarımı
- Sınıflandırıcı Tasarımı

Bu üç temel adımın başarı ile sonuçlanmasının ardından yüzdeki duygu tanınma işlemi gerçekleştirilebilir. Temel adımlarla ilgili yapılan çalışmalara ve uygulanan yöntemlere literatür çalışması kısmında değinilmiştir. Bu çalışma kapsamında ise görüntüde yüz bulmak için Haar Öznitelikleri Tabanlı, Basamaklı Sınıflandırıcılar kullanılmıştır. Yüz ifadelerini temsil edecek öznitelikler ise daha önce doku analizi için önerilen Yerel İkili Örüntüler(LBP) kullanılmıştır. Yüz ifadelerini sınıflandırmak için ise birçok makine öğrenme yöntemi denenmiş ve en başarılı olanlar çalışmada karşılaştırılmalı olarak sunulmuştur.

1.2. FACS Yüz Kodlama Sistemi

Yüz Hareket Kodlama Sistemi, (The Facial Action Coding System - FACS) gözlemlenebilir bir yüz ifadesine karşılık gelen bir dizi yüz kas hareketini ifade eder. Yüz ifadelerini kas hareketlerinin bileşenlerine ayırarak yüz ifadelerini ölçümlenebilir bir hale getiren sistemdir. İlk olarak, Carl-Herman Hjortsjö tarafından 1970 yılında 23 yüz hareket birimi ile tanıtılmış [3], daha sonra Paul Ekman ve Wallace Friesen tarafından geliştirilmiş, bugün bildiğimiz FACS ise ilk olarak 1978'de P. Ekman ve W.Friesen tarafından önerilmiş ve 2002' de güncellenerek son halini almıştır. FACS, 44 adet Eylem birimi içermektedir [4][5][6]. FACS kapsamlı bir biçimde yüz ifadelerinin davranışlarını tanımlamaktadır. Yüz ifadesini oluşturan gözlemlenebilir yüz bileşenlerini AU (Action Unit- AU) olarak etiketler. Şeki 1'de bazı eylem birimleri görülmektedir. Bu eylem birimlerinin kombinasyonları ise yüz ifadelerini oluşturmaktadır. FACS kullanarak, bir yüz ifadesinin hangi duyguyu gösterdiği belirlenebilir. Bu sistem, şu anda gerçek zamanlı olarak duyguları değerlendirmek için mevcut tek tekniktir.



Şekil 1. Örnek eylem birimleri (AU)

FACS yüz kodlama sistemini ortaya koyan P. Ekman, altı adet yüz ifadesinin (mutluluk, üzüntü, şaşırma, korku, tikslenme ve öfke) evrensel olduğunu belirtmiştir[4]. Bu yüz ifadeleri altı temel yüz ifadesi olarak da bilinmektedir. Şekil 2’de altı temel yüz ifadesi görülmektedir.

1.2.1. Mutluluk İfadesi

Mutluluğun, tüm kültürlerde neredeyse aynı anlama sahip en evrensel yüz ifadesi olduğu söylenebilir. Mutluluk tüm insanların tecrübe etmek isteyecekleri bir duygudur. Mutluluk, korku, öfke iğrenme ve üzüntü ile karşılaştırıldığında pozitif bir duygudur. Mutluluk yüz ifadesi olarak; gözlerin kısılması, yanakların yukarı doğru hareketi ve ağız uçlarının yukarı doğru kıvrılması ile gerçekleşir.

1.2.2. Üzüntü İfadesi

Üzüntü, kayıp, hayal kırıklığı veya umutsuzluk gibi durumlarda ortaya çıkan ifadedir. Üzüntü gösteren yüz ifadesi oldukça basittir: Üzüntüyü gösteren öznitelikler, yüzün özniteliklerinin azaltılmış biçimleridir. Yüzün tüm bileşenleri belirli bir alanı vurgulamaksızın aşağı yönde hareket etmesiyle meydana gelir.

1.2.3. Şaşırma İfadesi

Şaşırma ifadesi en kısa duygudur. Ortaya çıkması ve kaybolması bir anda gerçekleşir. Şaşırma ifadesi korku ifadesi ile benzerlikler gösterir. Şaşırma ifadesi en içgüdüsel yüz ifadelerinden biridir. Daha genel olarak söylemek gerekirse, beklenmedik bir şey olduğunda gözler genişler ve gözbebekleri, çevreyi daha eksiksiz bir şekilde görmek için büyür ve ağzın açılmasıyla şaşırma ifadesi meydana gelir.

1.2.4. Korku İfadesi


İnsanlar zarar görmekten korkar. Burada bahsedilen zarar, fiziksel, psikolojik veya her ikisi de olabilir. Korku ifadesi bu durumlarda meydana gelmektedir. Gözlerin genişlemesi ve kaşlar ile birlikte yukarı yönde olması ve ağzın belli bir dereceye kadar açılmasıyla meydana gelir.

1.2.5. Tiksinişme İfadesi

Tiksinişme ifadesi, hoşnutsuzluk ya da beğenmeme duygusunun ifadesidir. Bir yiyeceğin tadı, ya da rahatsız edici bir şey yeme düşüncesi bile tiksinişmeye neden olabilir. Bunların yanında rahatsız edici bir görüntü de tiksinişmeye neden olabilmektedir. Tiksinişme ifadesi, genel olarak hoş gitmeyen koku, görüntü ya da yiyeceğe verilen tepkidir. Tiksinişme ifadesi, iki kaşın birden aşağı yönde hareket etmesi, burnun yukarı doğru çekilmesi ve üst dudakın yukarı yönde hareket etmesiyle meydana gelir.

1.2.6. Öfke İfadesi

Öfke hoş olmayan, rahatsız edici veya sinir bozucu durumlarla ilişkilidir. Öfkeli olan insanlar zarar verme eğiliminde oldukları için öfkenin en tehlikeli duygu olduğu söylenebilir. Genel olarak öfke, hoş olmayan, rahatsız edici ya da sinir bozucu durumlarla ilişkilendirilmektedir. Öfke ifadesi, iç kaş uçlarının birleşerek aşağı inmesi, burun deliklerinin şişmesi ve dudakların içe doğru bastırılmasıyla meydana gelir.

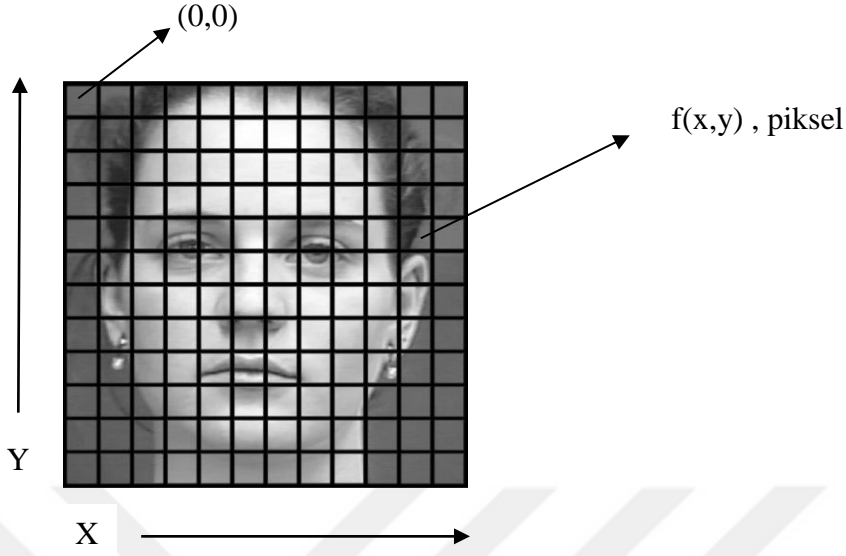


Şekil 2. Altı temel yüz ifadesi

1.3. Sayısal Görüntü İşleme

İnsanoğlu, doğuştan gelen görsel ve zihinsel yeteneklerinden dolayı görüntülerden bilgi elde etmede oldukça başarılıdır. Öğrendiğimiz bilgilerin çoğu görüntü formatındadır. Bu açıdan bakıldığında görüntülerin binlerce kelimelik bilgi içerdiği söylenebilir. Görüntüler nesnelere konumları, boyutları ve birbirleri arasındaki ilişkileri hakkında bilgiler içerir. Ancak bu bilgileri işlemek zaman açısından maliyetli bir işittir. Son yıllarda gelişen teknoloji yardımı ile görüntülerin içerdiği bilgiler, geçmiş yıllara oranla çok daha kolay bir biçimde işlenerek çeşitli alanlarda kullanılmaktadır.

Sayısal görüntü işleme, temelde iki amaç için kullanılan tekniklerden oluşmaktadır. Bu amaçların ilki, insanların yorumlaması için görüntülerin iyileştirilmesi, diğeri ise bilgisayarların görüntüyü saklaması veya işlemesine hazır hale getirmek için uygulanan ön işleme teknikleridir. Bu çalışma kapsamında görüntüden özneliklerin çıkarılması amacıyla ön işleme tabii tutulmuştur. Bir sayısal görüntü iki boyutlu bir fonksiyon olarak tanımlanabilir. $f(x,y)$, burada x ve y düzlemsel koordinatları belirtmektedir. (x,y) ikilisi de gösterdiği noktadaki gri seviyesi ya da o noktadaki görüntü yoğunluğu olarak adlandırılır. Şekil-3'te sayısal bir görüntü örneği ve temsili pikseller görülmektedir. Sayısal görüntü işleme ise sayısal bir görüntünün bilgisayarlar aracılığıyla işlenmesini ifade etmektedir.



Şekil 3. Sayısal görüntü ve temsili pikseller

1.4. Yüz Görüntüsü Elde Etme

Başarılı bir yüz ifadesi tanımanın ilk adımı, yüz görüntüsü elde etmektir. Çalışma kapsamında yüz görüntüsü elde etmek için HÖTBS Kullanılmıştır.


1.4.1. Haar Öznitelik Tabanlı Basamaklı Sınıflandırıcılar

Haar Özniteliklerini kullanarak nesne belirleme, P.Viola ve diğ. tarafından sunulan [7] etkili bir obje belirleme yöntemidir. Makine öğrenmesine dayalı bir yaklaşımdır. Fonksiyon, birçok olumlu ve olumsuz görüntüler ile eğitilir. Daha sonra, diğer görüntülerdeki objeleri belirlemek için kullanılır.

HÖTBS ile yüz algılamanın 3 önemli adımı vardır. Birincisi, makine öğrenmesinde kullanılacak özniteliklerin çok hızlı bir şekilde hesaplanmasını sağlayan integral görüntülerdir. İntegral görüntüler C.Papageorgiou ve diğ. tarafından sunulan [8] çalışmadan esinlenerek P.Viola ve diğ. tarafından Haar özniteliklerini hesaplamak için kullanılmıştır[7]. Yüz belirlemenin ikinci adımı ise AdaBoost hızlandırma algoritmasını kullanarak az sayıdaki önemli özelliğin seçilmesiyle bir sınıflandırıcı oluşturmaktır[9]. Herhangi bir görüntüde Haar özniteliklerinin sayısı, o görüntüdeki piksel sayısından fazladır. Bu nedenle öğrenmeyi hızlandırmak adına daha kritik ve önemli olan öznitelikleri belirlemek amacı ile

Adaboost yaklaşımı kullanılır. Adaboost herhangi bir öğrenme algoritmasının doğruluğunu arttırmak için kullanılan genel bir yöntemdir ve öğrenme yönteminin performansını arttıracak önemli sonuçlar verir [7][10]. Üçüncü ve son adım olarak ise, görüntünün öğrenme açısından kritik özniteliklerine yoğunlaşarak, sınıflayıcının hızını önemli ölçüde arttıran ve yöntemde de ismini veren basamaklı yapıdır. Bu basamaklı yapı, ardışık olarak daha karmaşık sınıflandırıcıları birleştirmek için bir yöntemdir.

Yüz belirleme, görüntüdeki basit özniteliklerin varlığına göre belirlenir. Direkt olarak pikselleri kullanmak yerine bu basit öznitelikleri kullanmanın birçok sebebi vardır. Bunlardan en önemlisi, ilgilenilen alan bilgisini kodlayabilmeleridir. Alan bilgileri kodlanmadan, sınırlı miktardaki eğitim kümesinden ilgi alanını öğrenmek zordur. Bir diğer sebep ise, öznitelik tabanlı sistemlerin, piksel tabanlı bir sistemden daha hızlı çalışmasıdır.



Şekil 4. Sırasıyla, kenar özellikleri, çizgi özelliği ve dört dikdörtgen özellik

Algoritmanın sınıflandırıcıyı eğitmek için birçok yüz görüntüsü içeren (pozitif) ve yüz görüntüsü içermeyen (negatif) görüntüleri gerekir. Eğitim için gereken özniteliklerin çıkarılması için ise Şekil 4'te gösterilen Haar öznitelikleri kullanılır. Her öznitelik, siyah dikdörtgenlerin içerdiği piksellerden beyaz dikdörtgenin içerdiği piksellerin çıkarılmasıyla elde edilen tek bir değerdir. Eğitim için kullanılan her görüntüyü tarayarak bu özniteliklerin hesaplanması çok fazla iş yükü gerektirmektedir. Örneğin 24x24 boyutundaki bir görüntü için bile bu öznitelikler hesaplanırsa 160.000 öznitelik ortaya çıkmaktadır. Bu iş yükünü azaltmak için P.Viola ve diğ. integral görüntüyü tanıtmışlardır[7].

(x, y) konumundaki bir integral görüntüsü, (x, y) konumunun üstündeki ve solundaki piksellerin toplamını içerir.


$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (1)$$

Burada, $ii(x, y)$ integral görüntü, $i(x, y)$ ise orijinal görüntüyü ifade etmektedir. (2) ve (3) kullanılarak, integral görüntü, orijinal görüntü üzerinden tek bir geçişle hesaplanabilir.

$$s(x, y) = s(x, y - 1) + i(x, y) \quad (2)$$

$$ii(x, y) = ii(x - 1, y) + s(x, y) \quad (3)$$

Burada $s(x, y)$ kümülatif satır toplamı, $s(x, -1) = 0$ ve $ii(-1, y) = 0$ gösterir. Şekil 5'te görülen D bölgesindeki piksellerin toplamı, dört referans ile hesaplanabilir. 1. Konumdaki integral görüntüsü, A dikdörtgenindeki piksellerin toplamına eşittir. 2. Konumundaki değer $A + B$, 3. konumunda $A + C$ ve 4. konumunda $A + B + C + D$ 'dir. D içindeki toplam $4 + 1 - (2 + 3)$ olarak hesaplanabilir[7].




Şekil 5. İntegral görüntü hesaplama örneği

Açıkça görülmektedir ki, Şekil 5'teki iki dikdörtgen arasındaki toplam piksellerin farkı sekiz referans ile hesaplanabilir. Şekil 4' te iki dikdörtgen içeren (kenar özelliği) öznitelik hesaplanırken, bitişik dikdörtgenler içereceği için altı adet referans ile hesaplanabilir. Bu öznitelik kullanılarak üç dikdörtgen içeren öznitelikler sekiz, dört dikdörtgen içeren öznitelikler ise dokuz referans kullanılarak hesaplanabilir.

İntegral görüntüler sayesinde bu öznitelikleri hesaplamak kolay olsa bile, hesaplanan özniteliklerin çoğu yüz görüntüsünü belirlemek için yetersizdir. Öğrenme adına en başarılı olan öznitelikleri seçmek için Adaboost algoritması kullanılmıştır. Adaboost algoritması bir görüntüdeki tüm Haar özniteliklerinden en değerli öznitelikleri belirlemektedir. Şekil 6'daki üst satırda Adaboost tarafından seçilen iki adet önemli öznitelik görülmektedir. Seçilen ilk öznitelik, göz bölgesinin genellikle burun ve yanak bölgelerinden daha koyu olduğu

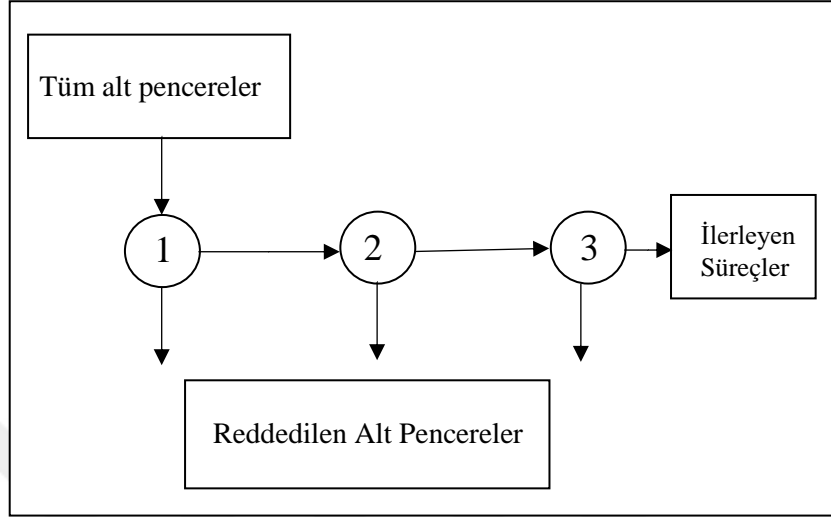
özniteliklere yoğunlaştığı görülmektedir. Seçilen ikinci öznitelik, gözlerin burun köprüsünden daha koyu olduğu özniteliklerine dayanmaktadır.



Şekil 6. Adaboost algoritması tarafından seçilen önemli haar öznitelikleri

Bundan dolayı, eğitim kümesindeki tüm görüntülerin her özelliğine Adaboost uygulanmalıdır. Her özelliği, yüz belirlemede pozitif ya da negatif olarak işaretleyerek en iyi öznitelikleri belirleyecektir. Hatalı sınıflandırma sorununun önüne geçebilmek için, minimum hata oranına sahip olan öznitelikler seçilmelidir. Adaboost en iyi öznitelikleri belirlemek için başlangıçta her görüntüye eşit derecede ağırlıklar vermektedir. Her sınıflandırmadan sonra, yanlış sınıflandırılmış görüntülerin ağırlığı artırılır. Bu da algoritmanın sınıflandırmakta güçlük çektiği görüntüler üzerinde çalışarak başarıyı arttırmayı sağlamaktadır. Süreç, arzu edilen doğruluk ya da hata oranı elde edilinceye kadar tekrar edilir. Nihai sınıflandırıcı bu zayıf sınıflandırıcıların ağırlıklı bir toplamıdır. Zayıf sınıflandırıcı olarak nitelendirilmelerinin sebebi ise, tek başına kullanıldıklarında bir görüntüyü sınıflandırmak için yeterli olmamalarıdır. Ancak diğer zayıf sınıflandırıcılar ile birlikte güçlü bir sınıflandırıcı oluştururlar. P.Viola ve diğ. Çalışmalarında, 200 öznitelik kullanarak %95 doğruluk elde etmişlerdir[7]. Son sınıflandırıcı için ise 6.000 öznitelik kullanmışlardır. Bu sayının 160.000 öznitelik içinden belirlendiği düşünüldüğünde Adaboost yönteminin faydası daha net görülecektir. Ancak 24x24 boyutunda bir görüntü için 6.000 adet öznitelik çıkararak bu görüntüde yüz olup olmadığını anlamak zaman açısından değerlendirildiğinde verimsiz bir yaklaşımdır. P.Viola ve diğ. Çalışmalarında, bu sorun için de Basamaklı Sınıflandırıcılar adında bir çözüm önermişlerdir[7]. Bu yaklaşımın blok diyagramı Şekil 7'deki gibidir. Burada görüntü alt pencerelere bölünür ve her alt

pencereye sırasıyla bir dizi sınıflandırıcı uygulanır. İlk sınıflandırıcı, çok az işlem kullanılarak çok sayıda olumsuz örneği ortadan kaldırır. Bu sayede ilgilenilmeyen pencere sayısı azaltılarak işlem sayısı düşürülür.



Şekil 7. Basamaklı sınıflandırıcının blok diyagramı.

Bir görüntüde yüz içeren kısım çok büyük değildir. P.Viola ve diğ. tüm görüntüye 6000 özelliğin tamamını uygulamak yerine, bu öznitelikleri sınıflandırıcının farklı aşamalarında gruplayarak, tek tek uygulamışlardır; Görüntü alt pencerelere bölünür, gruplanan ilk öznitelikler alt pencerede yoksa yani başarısızsa bu alt pencere tekrar işleme alınmaz. İlk aşamada başarılı olan alt pencereye ikinci aşamadaki sınıflandırıcı da uygulanır ve süreç devam ettirilir tüm aşamaları geçen bölge ise yüz bölgesidir. P.Viola ve diğ. Çalışmalarında, 6.000'den fazla öznitelik 38 aşamalı bir yapı kullanmışlardır[7]. İlk beş aşama sırasıyla 1,10,25 ve 50 öznitelik içermektedir. Bölünen tüm pencerelere ortalama olarak 10 öznitelik uygulanarak yüz belirlenebilmektedir.

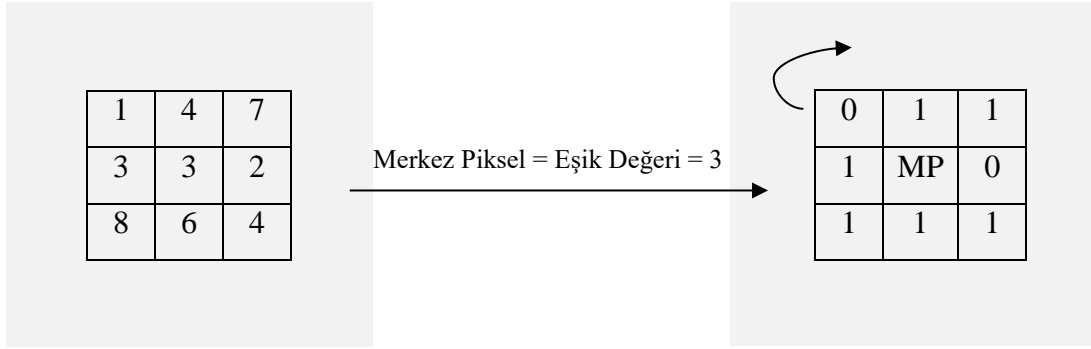
1.5. Öznitelik Elde Etme

Yüz ifadesi tanımanın hayati adımlarından birisi de, elde edilen yüz görüntüsünün hangi ifadeyi gösterdiğini iyi temsil edecek özniteliklerdir. Çalışma kapsamında, öznitelik çıkarımı için Yerel İkili Örüntüler kullanılmıştır.

1.5.1. Yerel İkili Örüntüler

Yerel ikili örüntüler (Local Binary Patterns, LBP), ilk olarak Ojala ve diğ. tarafından tanıtılmış ve doku tanımak için kullanılmıştır [11]. LBP basit ancak etkili bir doku tanımlama operatörüdür. Hesaplanması basit ve ayırt ediciliği yönünden güçlüdür. Özellikle, gri görüntü üzerindeki aydınlama farklılıklarından çok fazla etkilenmemektedir. Bu nedenle, gerçek ortamlardan elde edilen görüntüler üzerinde kullanmak idealdir ve hesaplama basitliği, görüntülerin eş zamanlı olarak işlenmesini kolaylaştırmaktadır. Bu nedenlerden dolayı birçok alanda uygulamalarına rastlanmaktadır[62]. LBP, görüntüyü 3x3 parçalar halinde ele alarak, her parçadaki merkez piksel (MP) değerini eşik değeri kabul eder. Bu eşik değeri ile geri kalan kalan 8 komşu pikseli karşılaştırarak, Şekil 8'deki gibi etiketler ve ikili bir sayı üretir. Eşikleme işlemi (4) denklemindeki gibi yapılmaktadır.

$$x = \begin{cases} 0, & \text{eğer, } x < MP \\ 1, & \text{eğer } x \geq MP \end{cases} \quad (4)$$



Şekil 8. Basit LBP operatörü.

Eşikleme işlemi sonucunda ikili sayı, sol üst köşedeki piksel değerinden başlayarak saat yönünde ilerleyerek oluşturulur. Şekil-8'deki örneğin ikili ve ondalık gösterimi sırasıyla (5) gibi gösterilir. Elde edilen bu sayılar; Yerel İkili Örüntüler veya LBP Kodları olarak adlandırılır.

$$(01101111)_2 = 103 \quad (5)$$


LBP matematiksel olarak (6) gibi ifade edilir.

$$LBP(x) = \sum_{i=1}^n f(x_i - x)2^{i-1} \quad (6)$$

$$f(y) = \begin{cases} 0, & \text{eğer } y < 0 \\ 1, & \text{eğer } y \geq 0 \end{cases} \quad (7)$$

Burada, n komşu sayısını, x_i i. sıradaki komşu piksel değeri, x merkez piksel değerini ifade etmektedir.

LBP operatörünün dezavantajı ise, 3x3 komşulukların küçük olmasından dolayı büyük ölçekli yapılarda baskın özniteliklerin yakalanamamasıdır. Bundan dolayı yapılan çalışmalarda LBP operatörünün komşulukları farklı boyutlara genişletilmiştir[12]. Dairesel komşuluğun kullanılması ve piksel değerinin lineer enterpolasyonu herhangi bir yarıçap ve komşulukta kullanılabilir. Genişletilmiş komşuluk değerli LBP operatörü Şekil 9'de görülmektedir. Bu kodlar aynı zamanda mikro örüntüleri oluşturur.



Şekil 9. Genişletilmiş LBP örnekleri.

Burada (P, R) ifadesi, dairesel simetrik bir komşu kümesi oluşturan R yarıçapında bir daire üzerinde P adet eşit aralıklı pikselleri göstermektedir. LBP operatörü $LBP_{P,R}$ 2^P adet farklı çıktı değeri üretecektir. 2^P farklı ikili desen, komşuluk setindeki P piksele tekabül eder. LBP kodları, 0 – 255 ($2^8 = 256$) arasında değer alarak 3x3 lük ilgili yapıyı ifade eder. Elde edilen bazı LBP kodları diğerlerine göre daha fazla bilgi içermektedir. Bu nedenle 2^P yerel ikili örüntülerin daha fazla bilgi içeren alt kümesi kullanılarak daha yüksek başarı ile görüntü ya da doku tanımlanabilir. Ojala ve diğ. bu temel örüntüleri, düzgün örüntüler (uniform

patterns) olarak adlandırmışlardır[12]. İkili dizi çember olarak dikkate alındığında, bir LBP eğer 0' dan 1' e ya da 1' den 0' a en fazla iki bit geçişi içeriyorsa düzgün (uniform) olarak adlandırılır. Örneğin, 00000000, 001110000 ve 11100001 düzgün örüntülerdir. Bir doku görüntüsünde bu düzgün örüntüler tüm örüntünün (8,1) komşuluğunda yaklaşık %90'ını ve (16,2) komşuluğunda ise yaklaşık %70' ini oluşturmaktadır. Tek bir ikili dizi alanında ikiden fazla geçiş içeren birikimli örüntüler bir LBP operatörü verir, $LBP_{P,R}^{u2}$ şeklinde temsil edilir ve 2^P den daha az ikiliden oluşur. Örneğin, standart bir 3x3 komşudan oluşan LBP için 8 pikseli komşuluk için etiket sayısı 256, fakat $LBP_{P,R}^{u2}$ için bu sayı 58 dir. Düzenli olmayan LBP'leri ise tek bir değer olarak etiketlemek yeterlidir. Bu durumda, $LBP_{P,R}^{u2}$ için öznitelik sayısı 59 olacaktır. LBP kodları çıkarılmış görüntü Ek 1 'de görülmektedir.

1.6. Ön İşleme Adımları

Çalışmada kullanılan görüntüler aynı ortamdan alınmış olsa da sinyalin doğası gereği tüm görüntülerin aynı olduğu söylenemez. Ön işleme, farklı görüntüleri aynı koşullara getirmek adına yapılan, gürültüyü azaltmak gibi işlemlerden oluşur. Çalışmada kullanılan görüntülere ön işlem olarak Gauss Yumuşatma Filtresi uygulanmıştır.

1.6.1. Gauss Yumuşatma Filtresi Uygulaması

Gauss yumuşatma filtresi, görüntülerdeki gürültüleri ve detayları kaldırmak için kullanılır. GYF, gauss filtresinin uygulanmasıyla olur. GYF değerleri ise Gauss fonksiyonuna göre konumlandırılan katsayılardan oluşmaktadır. (8) matisi, 3x3 GYF görülmektedir,

$$G = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (8)$$

GYF, görüntüde bulunan her piksel için ayrı ayrı uygulanmaktadır. Bu işleme konvolüsyon işlemi denmektedir. Görüntüdeki (x,y) koordinatında bulunan piksel alınır ve orijinal görüntüdeki komşularla gauss filtresinin katsayıları çarpılır ve yeni piksel değer olarak yazılır[63].

Konvolüsyon, matematiksel olarak (9) gibi ifade edilir,

$$H(x, y) = f(x, y) * g(x, y) = \sum_{i=-\infty}^{+\infty} \sum_{j=-\infty}^{+\infty} f[i, j] * g[x - i, y - j] \quad (9)$$

Burada, $H(x, y)$ çıkış görüntüsü, $f(x, y)$ filtre uygulanmak istenen görüntü, $g(x, y)$ ise uygulanmak istenen filtreyi göstermektedir. Konvolüsyon işlemi pratik olarak aşağıdaki gibi hesaplanır,

$$f(x, y) = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{bmatrix} \quad ve \quad g(x, y) = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$$

olduğu varsayılınsın, bu durumda, $f(1,1)$ değeri (9) denklemi kullanılarak aşağıdaki gibi hesaplanır,

$$\begin{aligned} H(1,1) &= (1x1) + (2x2) + (3x1) + (4x2) + (5x4) + (6x2) + (7x1) \\ &+ (8x2) + (9x1) = 80 \end{aligned}$$

Konvolüsyon işlemi uygulandıktan sonra orijinal görüntüde değeri $f(1,1) = 5$ olan piksel değeri, $H(1,1) = 80$ olarak hesaplanmıştır.

1.7. Makine Öğrenmesi

Algoritma, verilen giriş değerini istenen bir çıktıya dönüştürmek için gerekli talimatları gerçekleştiren sıralı emirler dizisidir. Bir algoritma yardımı ile sıralama, arama ya da şifreleme yapılabilir. Ancak bazı problemleri çözmek için kesin bir algoritma bulunmamaktadır. Örneğin, bir metin içeriğinin olumlu ya da olumsuz olduğunu bulmak için basit bir algoritma tasarımı yapmak çok zordur. Bu problem için girdi, metnin içerdiği kelimeler, çıktı ise olumlu ya da olumsuz durum olmalıdır. Ancak, alınan girdilerin nasıl çıktıya dönüştürüleceği bilinmemektedir. Verilen örnek problemi, olumlu ve olumsuz olguları ayırt edebilecek bir bilgi bulunmadığı için standart bir algoritma ile çözmek imkansızdır. Bu problemi çözmek için olumlu ve olumsuz örneklerden oluşan bir veri

kümesi girdi olarak verilmeli ve algoritmanın olumlu ve olumsuz kavramlarını *öğrenmesi* sağlanmalıdır. Bu problemin çözümü makine öğrenmesi ile çözülebilir. Gerçek hayatta, bir algoritması olmayan ancak örnek verilere bakılarak çözülebilecek birçok problem bulunmaktadır. Gelişen teknoloji ile birlikte insanlar her an veri üretmektedirler; sosyal medya paylaşımları, mesajlar ve faturalar bunlara örnek gösterilebilir. İnsanların, alışveriş alışkanlıklarını ya da internette gezinme alışkanlıkları tam olarak bilinmemektedir. Ancak toplanan verilerin incelenmesiyle bu konular ile ilgili tahminler yapılabilir. Bu tahminler bir algoritmanın yaptığı sayı sıralamada olduğu gibi kesin sonuçlar değildir ve süreci tam olarak açıklamamaktadır. Ancak yüksek doğruluğa sahip tahminler makine öğrenmesi yöntemleri kullanılarak yapılabilir.

Makine öğrenme yöntemlerinin büyük veritabanlarına uygulanması veri madenciliği olarak adlandırılır [13]. Başka bir deyişle, veri madenciliğinde büyük miktarda veri arasından ilgili alanda kullanılmak üzere kullanışlı bilgiler elde edilmeye çalışılır. Birçok alanda uygulamaları mevcuttur; bankaların kredi uygulamalarında, perakende sektöründe tüketici alışkanlıkları belirlemede, telekomünikasyonda, arama modelleri ve ağ optimizasyonunda kullanılmaktadır. Fakat makine öğrenimi sadece bir veritabanı problemi değildir; Aynı zamanda yapay zekanın bir parçasıdır ve konuşma tanıma, örüntü tanıma ve robotik alanlarında kullanılmaktadır. Kısaca, makine öğrenmesi örnek verileri ya da geçmiş deneyimleri kullanarak bir performans ölçütünü optimal değere ulaştırmak için bilgisayarların programlanmasıdır [13].

1.7.1. Makine Öğrenmesi Kategorileri

Makine öğrenimi için birçok algoritma bulunmaktadır. Her makine öğrenmesi algoritması, belirli türde problemleri çözmek üzere geliştirilmiştir. Bu algoritmaları, nasıl öğrendiklerine göre dört grupta kategorize edilebilir.

- **Danışmanlı Öğrenme:** Bu tür öğrenme yöntemlerine sağlanan veri satırları etiket verisine de sahip olmalıdır[13]. Diğer bir deyişle her girdi için bir çıkış değeri olmalıdır. Danışmanlı öğrenmede eğitim seti matematiksel olarak $(x_1, y_1), (x_2, y_2) \dots (x_n, y_n)$ şeklinde ifade edilmelidir. Burada x_i ler öznitelik vektörlerini y ise etiket verisini temsil etmektedir. Örnek verilecek olursak, x_i

ler kelimeleri y_i ler ise olumlu ya da olumsuz olmak üzere etiketleri temsil edebilir. Yeni gelen bir örneğin hangi sınıfa ait olduğu tahmin edilmelidir.

- **Danışmansız Öğrenme:** Danışmansız öğrenmede ise sağlanan girdiler için bir çıkış/etiket değeri bulunmamaktadır. Verilen girdiler aralarındaki benzerlik ya da yakınlık gibi öznitelikler ile sınıflandırılır. Matematiksel olarak girdi kümesi $x_1, x_2 \dots x_n$ şeklinde sadece özniteliklerden oluşmaktadır. Burada sınıf bilgisi olmadığı için tahmin değil, benzerlik ve yakınlık ölçütlerine göre yeni gelen örnek bir kümeye dahil edilir. Kısaca, danışmansız öğrenme, girdilere göre her bir örneği sınıflandıracak şekilde kendi kurallarını oluşturur[13][14].
- **Takviyeli Öğrenme:** Bir sistemi kontrol etmeyi öğrenmekle ilgili bir öğrenme şeklidir. Bir hedefe varmak için gereken bir sayısal ölçüyü maksimuma çıkarmak ile ilgilenir. Takviyeli Öğrenme bulunduğu ortamı algılayan ve kendi başına kararlar alabilen bir sistemin hedefine ulaşabilmesinde doğru kararlar almayı nasıl öğrenebileceğini gösterir[13][14]. Takviyeli öğrenmede, sistemin çıktısı değerlerinin iyi veya kötü olup olmadığına dair bilgi verilir. Ancak danışmanlı öğrenmedeki gibi sisteme net bir bilgi vermez veya veremez. Ödül ve ceza sinyalleri vardır. Sistem bir karar verdiğinde bu kararın doğru olduğu durumlar için sistemi ödüllendirir ve yanlışlar için de cezalandırır. Denenen doğru veya yanlış tüm durumları hatırlar. Bu bilgilere göre sistem kendini en iyi hedefe ulaşmak için eğitir. Sisteme verilen geribildirimler gecikmelidir. Örneğin, satranç oyunu için eğitilen bir sistemde yapılan hamlenin iyi olup olmadığı oyun bittikten sonra öğrenilir ve geçmişte yapılan hamleler sistemin ilerideki hareketlerini etkiler. Sistem geçmişteki yanlış ve doğru hareketlerini öğrenerek başarısını artırır.
- **Yarı Danışmanlı Öğrenme:** Gerçek dünyadan toplanan verileri manuel olarak etiketlemek maliyetli bir iştir. Yarı danışmanlı öğrenme eldeki büyük miktarda etiketsiz verinin yanında etiketli verilerin de kullanılmasıyla öğrenir. Kısaca yarı danışmanlı öğrenme, uygun bir fonksiyon veya sınıflandırıcı oluşturmak için etiketli ve etiketsiz örnekleri birleştirerek öğrenir[13][14].

1.7.2. Bazı Makine Öğrenmesi Yöntemleri

Bu başlıkta çalışma kapsamında kişiden bağımsız yüz ifadesi tanıma için karşılaştırmalı öğrenme performansları verilen makine öğrenimi yöntemleri incelenmiştir.

1.7.2.1. K-En Yakın Komşu Sınıflandırma Yöntemi

K - En Yakın Komşu Sınıflama Yöntemi ilk olarak 1950'lerin başında tanıtılmıştır. Yöntem büyük veri setlerinde hesaplama yükü fazla olduğundan dolayı 1960'lara kadar popüler olamamıştır. Ancak bilgisayarın gelişmesi ile işlem gücü artmış ve bu yöntem de örüntü tanıma alanında sık kullanılan bir yöntem haline gelmiştir [14].

K-EYK benzetme yoluyla öğrenmeye dayanmaktadır. Verilen bir test verisini eğitim verileri ile karşılaştırarak benzerliğini belirler. Sınıfı bilinmeyen bir veri işleme alındığında, var olan eğitim kümesindeki k adet en yakın komşu bulunarak yani test verisine en çok benzeyen k adet veri bulunarak, sınıfı bilinmeyen test verisinin sınıfı belirlenir.

Yakınlık ya da benzerlik ölçüsü ise Öklid Uzaklığı gibi bir mesafe metriği ile tanımlanır. Veri kümesi içindeki iki veri satırı, $X_1 = (x_{11}, x_{12}, \dots, x_{1n})$ ve $X_2 = (x_{21}, x_{22}, \dots, x_{2n})$ olsun. X_1 ve X_2 arasındaki Öklid Uzaklığı (10) gibi hesaplanmaktadır,

$$D(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (10)$$

K-EYK sınıflandırma yöntemi uzaklık temelli karşılaştırma kullanır ve doğası gereği veri kümesindeki tüm özniteliklere eşit ağırlıklar atar. Bu nedenle ilgisiz ve gürültü içeren veriler barındıran veri kümeleri için başarı değeri düşük olacaktır. Doğruluğun artırılmasında kullanılacak uzaklık metriği seçimi kritik bir rol oynamaktadır. Öklid uzaklığı dışındaki uzaklık metrikleri de kullanılabilir. Örneğin, veri kümesi içindeki iki veri satırı, $X_1 = (x_{11}, x_{12}, \dots, x_{1n})$ ve $X_2 = (x_{21}, x_{22}, \dots, x_{2n})$ için Manhattan uzaklık metriği (11) gibi hesaplanmaktadır,

$$D(X_1, X_2) = \sum_{i=1}^n |x_{1i} - x_{2i}| \quad (11)$$

Başka bir deyişle, her sayısal öznitelik için X_1 ve X_2 veri satırlarında o öznitelige karşılık gelen değerlerin arasındaki farkı birikimli olarak toplanmaktadır. (10) veya (11) denklemleri kullanılmadan önce veri kümesine normalizasyon işlemleri yapılması karşılaştırma işlemlerini kolaylaştıracaktır.

K-EYK sınıflama yöntemi, sınıfı bilinmeyen veriyi k adet komşusu arasında bulunan en yaygın sınıfa atar. Örneğin, k=1 ise sınıfı bilinmeyen veri kendisine en yakın komşusunun sınıfına atanır. K sayısının belirlenmesi için özel bir yöntem yoktur. Eldeki veriye göre deneylerle belirlenebilir. k=1 alınarak denemelere başlanmalı ve k artırılarak en düşük hata oranı veren k seçilmelidir.

K-EYK sınıflama yöntemi, her yeni örnek için uzaklık hesaplayacağı için yavaş çalışır. Öznitelik ve eğitim kümesindeki veri sayısının da artışıyla hesaplamalar da artacağı için hesaplama süresi artacaktır.

1.7.2.2. Yalın Bayes Sınıflandırma Yöntemi

Yalın bayes yöntemi istatistiksel bir sınıflama yöntemidir. Verilerin hangi sınıfa ait olduğunu, olasılıklarını hesaplayarak tahmin eder[13][14]. Temelleri Bayes Teoremine dayanmaktadır. YB Sınıflandırıcıları bir özniteliğin sınıf değerine etkisinin, diğer özniteliklerden bağımsız olduğunu varsayar. Bayes Teoremi adını, 18.yy. da olasılık ve karar teorileri çalışmaları yapan Thomas Bayes 'den almıştır[13][14]. X , bir veri satırı olsun ve n adet öznitelik ile ifade edilsin. H , bu veri satırının C sınıfına ait olduğuna dair bir hipotez olsun. Sınıflandırma problemleri için $P(H|X)$ yani, X veri satırının öznitelikleri gözlemlendiğinde H hipotezinin doğru olma olasılığı belirlenmeye çalışılır. Yani X 'in C sınıfına ait olma olasılığı aranmaktadır. $P(H|X)$ gösterimi H hipotezinin X koşulundaki olasılığıdır; D eğitim kümesi verileri olsun. Bu eğitim kümesindeki her bir satır $X = (x_1, x_2, \dots, x_n)$ ile ifade edilsin. Sırasıyla bu x değerleri, A_1, A_2, \dots, A_n olsun. Örnek bir sınıflama problemi için m adet sınıf C_1, C_2, \dots, C_m olarak isimlendirilsin. Verilen X verisi için YB sınıflandırma yöntemi, X koşulunda tüm sınıflar için ait olma olasılığını hesaplar.

En yüksek olasılığa sahip koşullu olasılık X 'in hangi sınıfa ait olduğunu belirler. Verilen X veri satırının herhangi bir C_i sınıfına ait olma olasılığı (12) gibi gösterilir.

$$P(C_i|X) = P(C_j|X) \quad , \quad 1 \leq j \leq m, j \neq i \quad (12)$$

Bu gösterimden hareketle $P(C_i|X)$ maksimize edilmeye çalışılır. Bayes Teoremine göre (13) gibi hesaplanmaktadır[13][14].

$$P(C_i|X) = \frac{P(X|C_i).P(C_i)}{P(X)} \quad (13)$$


1.7.2.3. Destek Vektör Makineleri Sınıflandırma Yöntemi

Destek Vektör Makineleri Yönteminin temelleri 1960'lara dayansa da ilk olarak B.E. Boser ve diğ. tarafından 1992 yılında tanıtılmıştır[15]. Yöntem, orijinal eğitim veri kümesindeki verileri daha yüksek boyuta dönüştürmek için doğrusal olmayan bir haritalama kullanır. Dönüştürülen bu yeni boyutta doğrusal olan ve veriyi en doğru şekilde ayıran hiperdüzlem aranır. Bir diğer deyişle, veri kümelerini birbirinden ayıracak karar sınırlarını belirlemeye çalışır. Yeterince yüksek bir boyutta, uygun bir doğrusal olmayan haritalama kullanıldığında iki sınıftaki veriler her zaman birbirinden bir hiperdüzlem ile ayrılabilir. Yöntem, bu hiperdüzlemi destek vektörleri ve sınırları kullanarak bulur. DVM yönteminin eğitim süreleri yavaş olmasına rağmen, karmaşık ve doğrusal olmayan sınırları modelleme yeteneğinden dolayı oldukça kullanışlıdır. DVM, el yazısı tanıma, nesne tanıma ve konuşmacı kimliği saptama gibi alanlarda birçok alana uygulanmıştır. DVM sınıflandırıcı verilerin doğrusal ayrılma ya da ayrılamama durumlarında ele alınabilir [16].

1.7.2.3.1. DVM Sınıflandırıcılarda Verilerin Doğrusal Ayrılabilme Durumu

Eğitim kümesindeki veriler (D) doğrusal ayrılabilir ve $(X_1, y_1), (X_2, y_2), \dots, (X_{|D|}, y_{|D|})$ olsun. Burada X_i , y_i ile etiketlenmiş veri satırları ve y_i iki değer alabilen bir değişken olsun. Örneğin, $y_i \in \{+1, -1\}$ burada, *görüntü yüz içeriyor = evet* ve

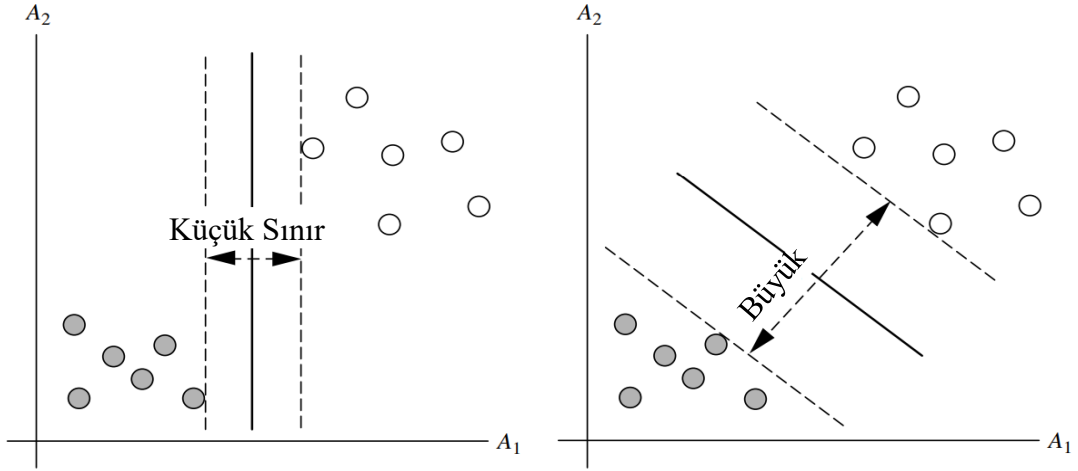
görüntü yüz içeriyor = hayır şeklinde iki sınıf olsun. Bu sınıfı tanımlamak için iki adet öznitelik olduğunu varsayalım. Sırasıyla A_1 ve A_2 olsun.



Şekil 10. Doğrusal ayrılabilen veri örneği

Şekil 10'da da görüleceği gibi veriler doğrusal ayrılabilir. İki veri kümesini ayırmak için sonsuz sayıda düz çizgi çizilebilir. Ancak burada amaç iki sınıfı ayıracak en iyi doğruyu bulmaktır. En iyi doğru ise yeni verileri en düşük sınıflandırma hatası ile sınıflandıracak olanıdır. Gösterimin kolay olması amacıyla iki boyutta çizilebilir bir örnek seçilmiştir. Öznitelik sayısının ikiden fazla olması durumunda bu sınıflar, hiperdüzlemler yardımı ile ayrılabilirler.

DVM Yöntemi en iyi hiperdüzlemi arar. Şekil 11' de, örnek veriler için iki adet muhtemel ayırıcı doğrular ve onların veri kümesine olan uzaklıkları (sınırları) görülmektedir. Görülen iki doğru da şekildeki verileri doğru bir biçimde ayırmış yani sınıflamıştır. Ancak görüleceği üzere veriler arasında daha büyük sınırları olan doğrunun yeni gelen verileri sınıflandırırken daha başarılı olacağı aşikardır. En iyi hiperdüzlem verilere en büyük uzaklığı olan hiperdüzlemdir. Bundan dolayı DVM, Maksimum Sınır Sahip Hiperdüzlemi (MSH) bulmaya çalışır. Ayırdığı veri kümelerine uzaklığı eşit olan hiperdüzlem en iyi hiper düzlemdir denilebilir.



Şekil 11. Küçük ve büyük sınırlar

Ayrılcı hiperdüzlem (14) ile ifade edilebilir,

$$W \cdot X + b = 0 \quad (14)$$

Burada, W , ağırlık vektörü $W = \{w_1, w_2, \dots, w_n\}$, n öznitelik sayısı ve b ise hata payını göstermektedir. İki adet öznitelik olduğunu varsayarsak, $X = \{x_1, x_2\}$, x_1 ve x_2 değerleri sırasıyla A_1 ve A_2 olsun. b değerinin de ek bir ağırlık değeri w_0 olduğunu varsayalım denklemin,

$$w_0 + w_1 x_1 + w_2 x_2 = 0 \quad (15)$$

(15) ile ifade edilebilir. Böylece hiperdüzlem üzerindeki herhangi bir nokta (16) denklemini sağlayacaktır,

$$w_0 + w_1 x_1 + w_2 x_2 > 0 \quad (16)$$

Benzer şekilde, hiperdüzlem altındaki herhangi bir nokta da (17) denklemini sağlar,

$$w_0 + w_1 x_1 + w_2 x_2 < 0 \quad (17)$$

Bu iki denklem kullanılarak hiperdüzlemin kenar sınırları (18) ve (19) gibi tanımlanabilir,


$$H_1: w_0 + w_1x_1 + w_2x_2 \geq +1 \quad , y_i = +1 \text{ için} \quad (18)$$

$$H_2: w_0 + w_1x_1 + w_2x_2 \leq -1 \quad , y_i = -1 \text{ için} \quad (19)$$

Yani, H_1 'in üzerindeki ve yukarıdaki herhangi bir nokta +1 sınıfına, H_2 'nin üzerindeki ve altındaki herhangi bir nokta ise -1 sınıfına aittir. Bu (18) ve (19) kullanarak (20) denklemini elde edilebilir,

$$y_i(w_0 + w_1x_1 + w_2x_2) \geq 1, \quad \forall i \quad (20)$$

Hiperdüzlem H_1 veya H_2 'nin üzerine düşen herhangi bir eğitim verisi (20) numaralı denklemi sağlar ve destek vektörleri olarak adlandırılır. Şekil 12'de daha kalın sınırlarla gösterilmiştir. H_1 veya H_2 hiperdüzlemleri MSH'a eşit derecede yakındırlar.



Şekil 12. Destek vektörleri gösterimi

Destek vektörleri sınıflandırmanın en zor olduğu verilerdir ve sınıflama ile ilgili en çok bilgiyi destek vektörleri verir. Buradan hareketle, MSH'a ait bir formül belirlenebilir.

H_1 üzerindeki herhangi bir noktadan ayırıcı hiperdüzleme olan mesafe $\frac{1}{\|W\|}$ dir. Burada, $\|W\|$ ifadesi W 'nın Öklid formudur. $W = \{w_1, w_2, \dots, w_n\}$ ve $\|W\| = \sqrt{W \cdot W} = \sqrt{w_1w_2 \dots w_n}$ dir. Benzer şekilde, H_2 üzerindeki herhangi bir noktadan ayırıcı düzleme olan


uzaklık da bu değere eşittir. Bu nedenle en büyük sınır ise $\frac{1}{\|w\|}$ olacaktır. DVM yöntemi, her iki veri kümesine de eşit uzaklıkta olan hiperdüzlemi (MSH) (20) numaralı denklemi Lagrange formülleri ile Karush-Kuhn-Tucker koşullarını kullanarak bulur [15]. Lagrange formülleri kullanılarak elde edilen MSH karar sınırı olarak (21) gibi ifade edilir,

$$d(X^T) = \sum_{i=1}^l y_i \alpha_i X_i X_i^T + b_0 \quad (21)$$

Burada, X^T test verisi, y_i sınıf değeri, l destek vektörleri sayısı, α ve b_0 ise optimizasyon ile otomatik olarak karar verilen numerik parametrelerdir. Bulunan MSH bir doğrudur ve anlatılan bu yöntem sadece doğrusal ayrılabilen veriler için geçerlidir.

1.7.2.3.2. DVM Sınıflandırıcılarda Verilerin Doğrusal Ayrılamama Durumu

Verilerin doğrusal olarak ayrılamadığı durumlarda, doğrusal DVM yöntemi genişletilerek kullanılabilir. Bunun için iki temel adım vardır. İlk adım, orijinal eğitim verilerini doğrusal olmayan haritalama kullanarak daha yüksek boyutlu bir uzaya taşımaktır. Yöntem olarak birçok doğrusal olmayan haritalama yöntemi kullanılabilir. İkinci adım ise, yeni uzayda verileri ayırabilecek doğrusal hiperdüzlem aramaktır. Bu adımlar sonunda, elde edilen denklem bir kuadratik optimizasyon problemidir ve Doğrusal DVM yönteminde kullanılan formulasyon ile çözülebilir. Yeni uzayda bulunacak maksimum sınıra sahip hiperdüzlem, orijinal uzayda doğrusal olmayan ayırıcı bir hiper yüzeye tekabül eder. Şekil 13'te doğrusal olarak ayrılamayan veri kümesi görülmektedir.



Şekil 13: İki boyutta doğrusal ayrılamayacak veri örneği

Orijinal verilerin daha yüksek boyuta doğrusal olmayan transformasyonu için üç boyutlu bir girdi vektörü $X = (x_1, x_2, x_3)$ olsun. Z , $h_1(X) = x_1$, $h_2(X) = x_2$, $h_3(X) = x_3$, $h_4(X) = (x_1)^2$, $h_5(X) = x_1 \cdot x_2$ ve $h_6(X) = x_1 x_3$ eşitliklerini kullansın. Yeni yüksek boyutlu uzayda karar hiperdüzlemi, $d(Z) = WZ + b$ olur. Burada Z ve W vektördür. Görüldüğü üzere doğrusal bir denklemdir. Eğer W ve b çözülür ve yerine koyulursa, yeni uzayda (Z) doğrusal bir karar hiperdüzleme karşılık gelir. Bu hiperdüzlem orijinal üç boyutlu girdide doğrusal olmayan ikinci dereceden polinoma karşılık gelir.

$$d(Z) = w_1 x_1 + w_2 x_2 + w_3 x_3 + w_4 (x_1)^2 + w_5 x_1 x_2 + w_6 x_1 x_3 + b \quad (22)$$

$$d(Z) = w_1 z_1 + w_2 z_2 + w_3 z_3 + w_4 z_4 + w_5 z_5 + w_6 z_6 + b \quad (23)$$

Önemli bir problem, daha yüksek boyutlu bir uzaya doğrusal olmayan haritalamanın nasıl seçileceğidir. Verilen bir test girdisi için (X^T) artacak hesaplama maliyeti de bir diğer problemdir. Verilen her bir test verisi, her bir destek vektörü ile çarpılmalıdır; $X^T = (x_1^T, x_2^T, \dots, x_n^T)$ ve $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$ çarpımları, $x_1^T \cdot x_{i1} + x_2^T \cdot x_{i2} + \dots + x_n^T \cdot x_{in}$ olacaktır. Bu çarpım, her n boyut için bir çarpım ve bir toplama içermektedir. Sınıflama eğitimi sırasında da MSH' 1 bulurken bu çarpımlar birkaç kez yapılacaktır. Bu nedenle gerekli hesaplamalar oldukça maliyetlidir. Maliyeti azaltmak adına bazı düzenlemeler yapılabilir. Örneğin, Doğrusal DVM için ikinci dereceden optimizasyon problemi çözerken, eğitim verileri için eğitim verileri çarpım durumunda $h(X_i) \cdot h(X_j)$ şeklinde karşılaşılabılır. Burada $h(X)$ eğitim verilerini dönüştürmek için gerekli olan doğrusal olmayan haritalama fonksiyonudur. Dönüştürülen verilerin noktasal çarpımını hesaplamak yerine, verilere bir çekirdek fonksiyonu $K(X_i, X_j)$ uygulamak matematiksel olarak eşdeğerdir. Burada K ,

$$K(X_i, X_j) = h(X_i) \cdot h(X_j) \quad (24)$$

Şeklinde hesaplanır.

Diğer bir deyişle, eğitim verileri dönüşürken gördüğümüz her $h(X_i) \cdot h(X_j)$ ifadesinin yerine, $K(X_i, X_j)$ ifadesini koyulmalıdır. Bu sayede, tüm hesaplamalar potansiyel olarak daha düşük boyuta sahip olan orijinal girdi alanında yapılır. Bu sayede haritalama ortadan kalkmış olur. Süreç, bu işlemler uygulandıktan sonra bir önceki bölümde anlatılan adımlara benzer şekilde

ilerler. $K(X_i, X_j)$ çekirdek fonksiyonunun yerine kullanılabilecek üç fonksiyon (25),(26) ve (27) numaralı denklemlerdir[17].

$$\text{Polinomial Çekirdek Fonksiyonu: } K(X_i, X_j) = (X_i X_j + 1)^h \quad (25)$$

$$\text{Gauss Radyal Çekirdek Fonksiyonu: } K(X_i, X_j) = e^{-\|X_i X_j\|^2 / 2\sigma^2} \quad (26)$$

$$\text{Sigmoid Çekirdek Fonksiyonu: } K(X_i, X_j) = \tanh(\alpha X_i X_j + r)^h \quad (27)$$

Bu çekirdek fonksiyonlarının her biri orijinal girdi alanında doğrusal olmayan bir sınıflandırıcıya dönüşür. DVM sınıflandırıcısının hangi çekirdek fonksiyon ile daha başarılı sonuçlar vereceğine dair bir kural bulunmamaktadır. Pratikte ise seçilen çekirdek fonksiyon sonuçlar üzerinde genellikle çok büyük farklılıklar yaratmamaktadır [14].

1.8. Önceki Çalışmalar

Otomatik yüz ifadesi tanıma Darwin' in 1872 yılında yaptığı çalışmalarından [1] bu yana davranış bilimcilerin dikkatini çekmiştir ve o çalışmalardan bu yana yüz ifadeleri ile ilgili birçok çalışma yapılmıştır. Önceki çalışmalar, giriş kısmında bahsedilen yüz ifadesi tanımak için gerekli 3 temel adım temel alınarak incelenmiştir.

1.8.1. Yüz Görüntüsü Elde Etme

Görüntüden yüz görüntüsü çıkarma için birçok yöntem önerilmiştir. Bir görüntüdeki yüzleri tespit etmek için mevcut teknikler genel olarak dört kategoriye ayrılabilir [18].

1.8.1.1. Bilgi Tabanlı Yöntemler

Bu yöntemler, tipik bir yüzü oluşturan bilgileri kodlayarak bir kural oluşturur. Genellikle kurallar yüz öznitelikleri arasındaki ilişkiyi ele alır. Bu yaklaşımı kullanmanın avantajı, insan yüzünü tanımlamak için basit kurallar üretmenin kolay olmasıdır. Ancak, bu yaklaşım türetilen kuralların çok genel olması halinde yanlış bölgeleri de yüz olarak algılayabilir. Türetilen kuralların çok spesifik ve katı olması halinde ise bazı yüzleri tespit edemeyebilir.

M.H. Yang ve diğeri tarafından ele alınan yüz tanıma bilgisi temelli yaklaşımı, kural tabanlı bir yaklaşımdır[18]. Bu yaklaşımı kullanarak yüz algılama, insan yüzü bilgisinden türetilen bazı kurallara dayanarak yapılır. Bu kurallar, yüzdeki öznitelikleri ve aralarındaki ilişkiyi, göreceli uzaklıkları ve konumları açısından tanımlar. Basitçe örnek verilecek olursa, yüz görüntüsü birbirine simetrik iki gözün birleşimi, bir burun ve bir ağız olarak tanımlanabilir. Böylece, bu kuralları sağlayan bir görüntü insan yüzü olarak algılanır.

J.Jiang ve diğeri görüntülerdeki insan yüzlerinin yerlerini saptamak için bağımsız bir ölçek tekniği sunmuştur [19]. Üç farklı seviyede gerçekleşen bir yaklaşımdır. İlk seviyede, görüntüdeki insan yüzünü algılamak için göz modeli kullanarak belirli kurallar türetmişlerdir. İkinci seviyede ise Yang ve diğeri [18] tarafından önerilen mozaik görüntü modelini ilk seviyede belirlenen görüntülerin tutarlı olup olmadığını belirlemek için kullanmışlardır. Son seviyede ise, Destek Vektör Makinaları(SVM) na dayalı yüz modeli, ikinci seviyeden elde edilen hatalı görüntüleri gidermek için kullanılmıştır.

S. Devadethan ve diğeri çalışmalarında burun deliklerini ve gözleri kullanmışlardır [20]. Yapılan çalışmada ele alınan görüntüde ön yüz görüntüsünün olduğu varsayılmaktadır. İlk olarak gözler tespit edilerek ele alınacak yüz bölgesi belirlenir. Daha sonra, burun deliği, göz köşeleri, dudak köşeleri vb. diğer öznitelikler elde edilmeye çalışılır. Son olarak ise, göz mesafesi hesaplanarak uygun olan bölgeler yüz olarak algılanır.

1.8.1.2. Özellik Tabanlı Yöntemler

Bu yöntemler, ışık ve duruş değiştiğinde bile var olan özellikleri bulmaya çalışır. Örneğin, ten rengi, gözler, burun vb. gibi öznitelikleri ayıklayarak yüzü bulmak için kullanılır. Bu yöntemdeki dezavantaj ise, kullanılan özelliklerin aydınlanma ve gürültüye bağlı olarak bozulmasıdır.

M.H. Yang ve diğeri çalışmalarında İnsanın farklı poz ve aydınlatma şartlarında yüzlerin zahmetsizce algılayabileceği varsayımına dayanarak, göz, burun delikleri ve saç çizgisi özelliklerini kullanmışlardır[18]. Daha sonra, özelliklerin arasındaki ilişkiyi istatistiksel bir model oluşturarak, belirlenen bölgede yüz olup olmadığını belirlemişlerdir.

Gizatdinova Y. ve diğeri çalışmalarında, yüz görüntüsü olabilecek bölgeleri, karakteristik kenar desenli bölgeler seçilerek elde etmişlerdir[21]. Yöntem, kenarları belirler ve kenar haritalarını iki çözünürlük düzeyinde oluşturmuş ve belirlenen bölgelerde yüz

ifadesinden bağımsız olarak yüz bileşenlerini tanımışlardır. Ancak burun ve ağız tespitinde mutluluk ve tikslenme ifadesi olan görüntülerde başarılı olamamışlardır.

M. Z. Osman ve diğerleri çalışmalarında çevrimiçi örnekleme yapan ve çevrimdışı eğitime ihtiyaç duymayan bir yöntem önermişlerdir[22]. Sistemin dinamik bir cilt detektörü bulunmaktadır. Bu detektör, renkli alanları birleşimi olan bir detektördür.

1.8.1.3. Şablon Eşleme Yöntemleri

Bu yöntemde bir yüzün standart şekilleri saklanır ve girdi görüntüleri ile karşılaştırılarak önceden saklanan yüz şekillerinin korelasyonuna bakılır. Avantajlı olduğu kısım kolay uygulanmasıdır. Ancak, bu yöntemler, duruş şekilleri değiştiğinde başarısız olmaktadır.

T.Smitha ve diğerleri çalışmalarında cilt rengini algılama ve şablonu eşleme yöntemini birleştirmişlerdir[23]. Cilt algılandıktan sonra, Sobel kenar algılama metodu kullanarak göz, burun ve ağız yerlerini bulmak için şablon eşleme yapmışlardır.

T.Venugopal ve diğerleri çalışmalarında, Şablon tabanlı yaklaşım ile istatistiksel temelli(PCA) bir yüz tanıma yaklaşımını karşılaştırmışlardır[24]. Kullanılan veritabanı için istatistik temelli yaklaşım %70-75 civarında doğruluk sağlamış ve aydınlanma değişikliklerinde başarısız olmuştur. Şablon eşleme yöntemi ise %20 civarında daha doğru sonuçlar vermiştir.

1.8.1.4. Görünüşe Dayalı Yöntemler

Görünüşe dayalı yöntemler şablon eşleştirmeye benzer, ancak önceden tanımlanmış şablonlar kullanmak yerine, yüzleri algılamak için makine öğrenme tekniklerini kullanır. Görüntü, bir yüz olma veya olma olasılığı olmayan rastgele bir değişken olarak düşünülür. Bir başka yaklaşım, yüz ve yüz olmayan kısımlar arasında bir ayırt edici fonksiyon tanımlamaktır.

A.R. Mohan ve diğerleri çalışmalarında yüz alanının öz vektörlerinden oluşan zayıf sınıflandırıcıları boosting yöntemi ile hızlandırarak, yüz olmayan bölgeleri eleyecek bir sınıflandırıcı oluşturmuşlardır[25].

A. Bouzalmat ve diğeri çalışmaları yüz algılanması için, öznitelik vektörü Fourier Gabor Filtresi'ne dayanarak elde etmiş ve tanıma için yapay sinir ağları kullanmışlardır[26].

J. Ruan ve diğeri çalışmaları cilt bölgelerini görüntüden süzmüş ve daha sonra yüz olmayan kısımları ayıklamak için doğrusal SVM kullanmışlardır[27]. Son olarak, yüz görüntüsü olarak seçilen kısımları gözler ve ağız tespit ederek seçmişlerdir.

1.8.2. Öznitelik Elde Etme

Yüz görüntüsü elde edildikten sonraki adım ise yüz görüntüsünü tanımlayacak öznitelikleri elde etmektir. Yapılan çalışmalarda, en yaygın kullanılan öznitelikler üç başlık altında toplanabilir. Geometrik öznitelikler, görünüş öznitelikleri ve bu iki öznitelik türünü kullanan karma yöntemler. Geometrik öznitelikler, yüz bileşenlerinin şeklini ve yerlerini (ağız, gözler, kaşlar, burun vb) kapsamaktadır. Görünüş öznitelikleri ise yüzün dokusuyla (kırıklıklar vb) ilgilenir. Görünüş öznitelikleri yüzün bir kısmından ya da yüzün tamamından elde edilebilir. Görünüş öznitelikleri kullanılarak yapılan yüz ifadeleri tanıma çalışmaları ise, Önemli Bileşenler Analizi(PCA), Lineer Diskriminant Analizi(LDA) ve Bağımsız Bileşenler Analizi(ICA) yöntemleri kullanılmıştır.

Z.Zhang ve diğeri çalışmaları, yüze ait 34 noktanın geometrik konumlarını yüz görüntülerini temsil etmek için kullanmışlardır[28]. Görüntü dizilerinde, bu noktaların yer değiştirmelerini ölçerek yüz ifadesi tanıma çalışması yapmışlardır.

Y. Tian ve diğeri çalışmaları, geometrik özniteliklere (kaşlar, gözler, ağız) ve görünüş temelli özniteliklere (yüz çizgileri) dayanan yüz ifadelerini kullanarak otomatik yüz ifadesi analizi yapmışlardır[29].

M. Pantic ve diğeri çalışmaları, ön veya profil renkli yüz görüntülerinde yüz ifadelerini tanımak için otomatik bir sistemi geliştirmişlerdir[30]. Ağız ve gözler gibi bileşenleri ayıklayarak 19 adet öznitelik çıkarmışlardır.

D. Ghimire ve diğeri çalışmaları, yüz ifadelerini tanımak için geometrik öznitelik bölgelerinin yer değiştirmelerini kullanarak yüz ifadesi tanıma yapmışlardır[31].

M.N. Patil ve diğeri çalışmaları, yüz ifadelerinin tanımak için Temel Bileşen Analizi (PCA) ve Bağımsız Bileşen Analizi (ICA) kullanarak aralarında bir performans değerlendirmesi yapmışlardır[32]. Öklid uzaklık sınıflandırıcısı ve kosinüs benzerlik

ölçümü, görüntülerin test edilmesi ve doğrulanması için maliyet fonksiyonu olarak kullanmışlardır.

J.H. Shah ve diğerleri çalışmalarında, çok boyutlu veriler karmaşıklığı azaltmak ve yanlış etiketlemeyi en aza indirmek için Lineer Diskriminasyon Analizi (LDA) ve üç katmanlı destek vektör makinesi (SVM) teknikleri kullanarak işlemişlerdir[33].

C.Shan ve Diğerleri çalışmalarında, kişiden bağımsız yüz ifadesi tanıma için, Yerel İkili Örüntülere(LBP) dayalı olarak yüz ifadesini değerlendirmişler ve çeşitli veritabanlarından alınan yüz görüntülerini farklı makine öğrenme yöntemleri ile incelemişlerdir[34].

1.8.3. Sınıflandırıcı Tasarımı

Yüz ifadesi tanımanın en son adımı ise sınıflandırıcı seçimidir. Sınıflandırıcı yanlış seçilirse elde edilen ve yüzü iyi temsil eden öznitelikler işlevsiz kalacaktır. Yüz ifadesi tanıma konusunda yapılan çalışmalar incelendiğinde birçok farklı yöntemin önerildiği görülmüştür.

C. Padgett ve Diğerleri çalışmalarında, Yapay Sinir Ağları kullanarak insanların tek bir duyguyu sürekli olarak tanımladığı bir veritabanından alınan yeni yüz görüntüleri üzerinde %86 başarı sağlamışlardır[45].

Y. Tian çalışmasında, farklı çözünürlüklerdeki görüntüler için yapay sinir ağları ile yüz ifadelerini tanımaya çalışmıştır[46].

M.S. Bartlett ve Diğerleri çalışmalarında, yüz ifadesi tanıma problemi için SVM sınıflandırıcısını kullanmışlardır. Sistemin başarı oranını arttırmak için Adaboost yöntemini kullanmışlardır[47].

I.Cohen ve Diğerleri çalışmalarında, Bayes Ağları Sınıflandırma, Dağılımı Gauss' tan Couchy'e değiştirilmiş Naive Bayes sınıflandırma ve Tree-Augmented Naive Bayes sınıflandırıcılarını kullanmışlardır[48].

V.J. Mistry ve diğerleri çalışmalarında, yüz ifadeleri tanımda kullanılan özniteliklerin göreceli performanslarına dayalı bir tablo yayınlamıştır [49]. Performanslar, Tablo 1'de görülmektedir.

Tablo 1. Yüz ifadeleri tanımda göreceli performanslar

| SIRA | YÖNTEM / TEKNİK | VERİTABANI | SONUÇ/DOĞRULUK |
|------|--|--|---|
| 1 | Yapay Sinir Ağı + Kaba Kontur Kestirim Rutini (RCER) [50] | Kendi veri tabanları | %92,1 Tanıma oranı |
| 2 | Temel Bileşen Analizi (PCA) [51] | FACE94 | %35 daha az hesaplama zamanı ve %100 tanıma oranı |
| 3 | PCA + Eigenfaces [52] | JAFFE, CK | CK' da %83 Şaşırma, JAFFE' de %83 Mutluluk tanıma oranı, Korku en çok karışan ifade |
| 4 | 2D Gabor Filtresi [53] | Rastgele görüntüler | Kenar bulmak için 12 Gabor Filtre bankası kullanılmıştır |
| 5 | Lokal Gabor Filtresi + PCA + LDA [54] | JAFFE | PCA + LDA öznelikleri yardımıyla %97,33 oranında tanıma oranı elde edildi |
| 6 | PCA + AAM [55] | Fg-net konsorsiyumundan görüntü dizileri | Çıkarılan yüzlerden ifade tanınması için performans oranları %100'dür. Genel görüntüde tanıma oranı %88 |
| 7 | Gabor + SVM + HAAR + Adaboost [56] | ck | %99,54 G+S ve %82,81 H+A Ağız Eylem Birimleri için tanıma oranı |
| 8 | Dinamik HAAR benzerlik öznelikleri [57] | CMUDB+ Kendi veri tabanları | Önerilen yöntemin ümit verici bir performans gösterdiğini göstermiştir. |
| 9 | 2D görünüm tabanlı yerel yaklaşım + Radyal Simetri Dönüşümü [58] | JAFFE | Mutluluk ve şaşırma ifadeleri için %83, öfke ve üzüntü ifadeleri için %78'lik bir doğruluk. |
| 10 | 2D LDA + SVM [59] | JAFFE | Tanıma oranı, tek seferlik doğrulama kullanılarak %95,71. Çapraz doğrulama kullanılarak %94,13. |
| 11 | 2D Gabor Filtresi [60] | Palm Print veri tabanı | İki veritabanında 12 parametre setinin test edilmesi için 24 doğrulama testi gerçekleştirilmiştir |

2. YAPILAN ÇALIŞMALAR

Yapılan yüz ifadesi tanıma çalışmaları, bir dizi duygusal yüz ifadelerini; iğrenme, korku, sevinç, şaşırma, üzüntü ve öfke ifadelerinin tanınması üzerine çalışmalar yapılmıştır.

2.1. Kullanılan Veritabanı

Yapılan çalışmalar, bu konudaki en kapsamlı veritabanlarından biri olan Cohn-Kanade Veritabanı (CK) kullanılmıştır[61]. Veritabanı, yüz ifadeleri kaydedilen yaşları 18 ile 50 arasında değişen 210 kişinin görüntülerinden oluşmaktadır. Görüntüsü kaydedilen deneklerin %69'u kadın, %31'i ise erkeklerden oluşmaktadır. Bu deneklerin %81'i Beyaz Amerikalı, %13'ü Afroamerikan ve geri kalan %6'sını da diğer ırklar oluşturmaktadır. Görüntüler, deneklerin oturabileceği bir sandalye karşısındaki fotoğraf makinası yardımı ile elde edilmiştir. Deneklerden 23 adetlik bir yüz görüntüsü dizisi istenmiştir. Bunlardan altı tanesi temel yüz ifadelerinden (tiksinme, korku, sevinç, şaşırma, üzüntü ve öfke) oluşmaktadır. Görüntüler 640x490 boyutlarında 8 bit gri tonlamalı olarak, .png formatında kaydedilmiştir. Yapılan çalışmalar için bu veritabanından 378 adet görüntü seçilmiştir. Seçim kriteri ise altı adet yüz ifadesinden biri olmasıdır. Ancak veritabanında her yüz ifadesi eşit sayıda değildir. Seçilen 378 adet görüntüde, 67 adet şaşırma, 37 adet üzüntü, 29 adet kızgınlık, 56 adet tiksinme, 40 adet korku, 82 adet sevinç ve 67 adet nötr ifade içermektedir. Seçilen 378 adet görüntü sınıflandırma algoritmalarının tanıma performansının değerlendirilmesi için 10 kat çapraz doğrulama (10 fold cross validation) testi yapılmıştır. Çapraz doğrulamayı daha iyi anlatmak gerekirse, veri kümesi, rastgele, yaklaşık olarak eşit sayıda ifade içerecek şekilde 10 adet guruba bölünmüştür. Bu 10 gruptan 9 tanesi sınıflama yöntemini eğitmek için geri kalanı ise test için kullanılmıştır. Bu süreç, 10 kez her grup için tekrar edilir her grup sırasıyla eğitim sürecinden çıkarılarak test kümesi olarak kullanılmış ve sınıflama performansı bu işlemler sonucunda belirlenmiştir.


2.2. Yüz Görüntüsü Elde Etme ve Ön İşlemler

CK veritabanından alınan görüntülerdeki yüz ifadeleri HÖTBS kullanılarak otomatik olarak belirlenmiştir. Veritabanındaki görüntüler ön kısımdan oluştukları için kafanın küçük konum değiştirmeleri dikkate alınmamıştır. Elde edilen yüz görüntülerine 5x5 boyutlarında

GYF uygulanmıştır. Yapılan deneylerde GYF uygulanan görüntüler yüz ifadesi tanımada daha yüksek başarı göstermiştir. Veritabanındaki görüntülerde bazı aydınlanma farklılıkları bulunmaktadır ancak çalışmada öznelik olarak kullanılan LBP bu aydınlatma farklılıklarından etkilenmediği için bu farklılıkları kaldırmak için herhangi bir girişimde bulunulmamıştır.

2.3. Öznelik Elde Etme

Ön işlemeden sonra elde edilen görüntülerin LBP'leri çıkarılmıştır. Öznelik olarak ise, LBP'leri elde edilen görüntülerin histogramları kullanılmıştır. Tüm görüntünün histogramı, ifade tanıma konusunda yeterli bir öznelik oluşturmamaktadır. LBP kodu eğer 0' dan 1' e ya da 1' den 0' a en fazla iki bit geçişi içeriyorsa düzgün olarak adlandırılır. Örneğin, 00000000, 001110000 ve 11100001 düzgün örüntülerdir. Düzgün LBP'ler yüz görüntüsünü elde etmede daha etkili oldukları için histogramda düzgün LBP'ler dikkate alınmıştır. Düzgün olmayan LBP'ler ise histogramda tek bir değer olarak etiketlenmişlerdir ve daha etkili olmaları için bölünerek yerel histogramları öznelik olarak kullanılmıştır. Şekil 14'te yerel histogramların birleştirilerek öznelik olarak kullanılması görülmektedir.



Şekil 14. Öznelik olarak kullanılan yerel histogramlar

2.4. Yüz İfadeleri Tanıma İçin Makine Öğrenmesi

Elde edilen öznelikler yardımıyla kişiden bağımsız yüz ifadesi tanıma için çeşitli makine öğrenmesi yöntemleri denenmiştir. Kullanılan veri setleri çeşitli parametreler

değiştirilerek (LBP boyutu, yerel histogram sayısı) hazırlanmıştır. Sonuçlar sınıflama yöntemine göre verilmiştir.

2.5. Öğrenme Doğruluğunu Arttırmak İçin Yapılan İşlemler

Sınıflama yöntemlerinde kullanılan veriler, LBP'lerin oluşturduğu çıktılardan oluşmaktadır. Veriler üzerinde yapılacak veri ön işleme teknikleri verilerin kalitesini arttırabilir ve daha sonra uygulanacak makine öğrenmesi tekniklerinin doğruluğunu arttırmaya yardımcı olacaktır. Verideki anormallikleri belirlemek ve öğrenmeye katkısı olmayan verileri azaltmak öğrenme doğruluğunun artmasını sağlayacaktır. Bu bölümde, makine öğrenmesinde öğrenme performansının arttırılması için yapılacak işlemler başlıklar halinde sunulmuş ve öğrenme doğruluğuna etkileri sonuçlar kısmında verilmiştir.

2.5.1. Normalizasyon İşlemleri

Normalizasyon en basit haliyle, eldeki verilerin daha küçük bir aralığa düşecek şekilde $([0,1])$ ölçeklendirilmesidir. Diğer bir deyişle normalizasyon bir ölçeklendirme tekniğidir. Normalizasyon, veriler tahmin amacıyla kullanılacaksa tahmin doğruluğunu arttırmak için faydalıdır [3]. Çalışmada normalizasyon tekniği olarak, Minimum-Maksimum Normalizasyonu kullanılmıştır. $X = (x_1, x_2, \dots, x_n)$ Eğitim kümesi içindeki bir öznitelik olsun. x_{min} X Özniteliğinin en küçük, x_{maks} de en büyük değeri olduğu varsayalım. x_1, x_2, \dots, x_n Değerlerinin Minimum-Maksimum Normalizasyonu hesaplanmış hali x'_1, x'_2, \dots, x'_n olduğu varsayırsa, bu değerler (28) gibi hesaplanır,

$$x'_i = \frac{x_i - x_{min}}{x_{maks} - x_{min}}, \quad i = 1, 2, \dots, n \quad (28)$$

2.5.2. Öznitelik Altküme Seçimi

Çalışmada kullanılan veriler orijinal veritabanı içindeki görüntülerden, yüz bölgelerinin görüntüden elde edilmesi, ardından da elde edilen yüz görüntüsündeki yerel ikili görüntülerin hesaplanması ile elde edilen özniteliklerden oluşmaktadır. Ancak otomatik olarak elde edilen yüz görüntüleri yüz ifadesi oluşmasında etkisi olmayan kısımları da

içermektedir. Yüz görüntüsü saçların ya da kulakların bir kısmını da içerebilir, ancak bu kısımların yüz ifadesi oluşturmada herhangi bir etkisi bulunmamaktadır. Öznitelik seçimi alakasız veya gereksiz verileri kaldırmak için kullanılır. Kısaca, eldeki özniteliklerden sınıfları en iyi şekilde niteleyen bir öznitelik alt kümesini bulmaktır denilebilir. Çalışmada Kademeli İleri Seçim algoritması kullanılarak öznitelik seçimi yapılmıştır. Kademeli İleri Seçim Algoritması, mümkün olan tüm alt grupların tamamını üretmeden, en uygun alt kümeyi bulmaya çalışır. Süreç boş bir alt kümeyle başlar ve her iterasyonda bir öznitelik eklenir. Alt küme boş bir öznitelik kümesi ile başlar ve öznitelikleri sırasıyla dener. Denenen özniteliklerden en alakalı olanlar alt kümeyle alınır. Bu durum eklenecek bir veri kalmayana kadar devam eder. Alt küme içinde kalan öznitelikler ise yeni öznitelik setini oluşturmuş olurlar.

2.5.3. Adaboost Hızlandırma Algoritması

Boosting herhangi bir öğrenme algoritmasının doğruluğunu arttırmak için kullanılan genel bir yöntemdir. Kökleri Leslie Vailant'ın geliştirdiği PAC adı verilen bir makine öğrenmesi yöntemine dayanmaktadır [14]. Boosting yaklaşımı nispeten zayıf ve hatalı öğrencileri birleştirerek yüksek doğruluğa sahip bir öğrenme kuralı oluşturma fikrine dayanır. Veri setine ait bir önceki sınıflandırmada yanlış tahmin edilen örnekler, bir sonraki sınıflandırıcı tarafından kullanılacak eğitim setindeki doğru tahmin edilen verilere göre daha fazla tekrar edilerek örnekleri daha doğru tahmin edebilen bir sınıflandırıcı oluşturulmaya çalışılır. Bu yöntemin temelinde, her bir gözlem için hata durumuna göre bir ağırlık değerinin atanması vardır ve herhangi bir makine öğrenme yöntemi ile birlikte kullanılabilir.

3. BULGULAR, TARTIŞMA

Bu bölümde, yüz ifadelerinin genel tanıma performansları, hazırlanan farklı veri setleri ile incelenmiştir. Hazırlanan veri setleri, yerel ikili örüntüler ve genişletilmiş yerel ikili örüntülerin çeşitli versiyonlarının derlenmesiyle oluşmuştur. Kullanılan tüm versiyonlar Tablo.3'te verilmiştir. Oluşturulan tüm verisetleri görüntülerdeki yüz ifadesinden bağımsız kısımları (saçlar, kulaklar) çıkarmak için elde edilen yüz görüntülerin sağ ve solundan %10'luk bir kırılma gerçekleştirilerek elde edilen kırılmış görüntüler üzerinde de denenmiştir. Kırılma işlemi otomatik olarak yapılmıştır. Oluşturulan öznitelikler yedi sınıf (ifadesiz, mutluluk, üzüntü, şaşırma, korku, tikslenme, öfke), altı sınıf (mutluluk, üzüntü, şaşırma, korku, tikslenme, öfke), dört sınıf (ifadesiz, mutluluk, üzüntü, şaşırma) şeklinde ayrılarak incelenmiş ayrıca tüm temel yüz ifadelerinin bireysel sınıflandırma performansları da bu bölümde verilmiştir.

3.1. Yüz İfadelerinin Bireysel Sınıflandırma Performansları

Yüz ifadelerinin bireysel sınıflandırma performansları, yedi sınıflı tanımda en yüksek başarıyı gösteren Veri seti-2'de kullanılan öznitelik elde etme yöntemleri ile elde edilmiştir. Sınıflandırma yöntemi olarak ise yedi sınıfta, Veri seti-2'de en yüksek tanıma başarısını gösteren sınıflama performansını gösteren destek vektör makinaları kullanılmıştır. Sonuçlara göre, bireysel sınıflandırmada en yüksek başarı mutluluk ve öfke ifadelerinde elde edilmiştir. Bu bölümdeki sonuçlar, ifadesiz sınıfı ile temel altı yüz ifadesi sınıflarının ikili sınıflandırma doğruluklarından oluşmaktadır. Elde edilen sonuçlar Tablo 2'de verilmiştir.

Tablo 2. Yüz ifadelerinin bireysel sınıflandırma performansları

| Bireysel Sınıflandırma Performansları (%) | | | | | | |
|---|----------|---------|--------|------|-----------|-------|
| İfade Türleri | Mutluluk | Şaşırma | Üzüntü | Öfke | Tikslenme | Korku |
| Snf. Yöntemi | | | | | | |
| Destek Vektör Makinaları | 100 | 90,29 | 84,61 | 100 | 97,56 | 98,13 |

Tablo 3. İncelenen veri setleri versiyonları

| Veri Seti | Öznitelik Elde Etme Yöntemi | Sınıf Sayısı | | |
|--------------|---|--------------|---|---|
| | | 7 | 6 | 4 |
| Veri seti-1 | LBP + 4 Yerel Histogram | + | + | + |
| Veri seti-2 | LBP + 4 Yerel Histogram + Kırılmış görüntüler | + | + | + |
| Veri seti-3 | LBP + 8 Yerel Histogram | + | + | + |
| Veri seti-4 | LBP + 8 Yerel Histogram + Kırılmış görüntüler | + | + | + |
| Veri seti-5 | ELBP (8,1) + 4 Yerel Histogram | + | + | + |
| Veri seti-6 | ELBP (8,1) + 4 Yerel Histogram + Kırılmış görüntüler | + | + | + |
| Veri seti-7 | ELBP (8,1) + 8 Yerel Histogram | + | + | + |
| Veri seti-8 | ELBP (8,1) + 8 Yerel Histogram + Kırılmış görüntüler | + | + | + |
| Veri seti-9 | ELBP (8,2) + 4 Yerel Histogram | + | + | + |
| Veri seti-10 | ELBP (8,2) + 4 Yerel Histogram + Kırılmış görüntüler | + | + | + |
| Veri seti-11 | ELBP (8,2) + 8 Yerel Histogram | + | + | + |
| Veri seti-12 | ELBP (8,2) + 8 Yerel Histogram + Kırılmış görüntüler | + | + | + |
| Veri seti-13 | ELBP (16,1) + 4 Yerel Histogram | + | + | + |
| Veri seti-14 | ELBP (16,1) + 4 Yerel Histogram+ Kırılmış görüntüler | + | + | + |
| Veri seti-15 | ELBP (16,1) + 8 Yerel Histogram | + | + | + |
| Veri seti-16 | ELBP (16,1) + 8 Yerel Histogram + Kırılmış görüntüler | + | + | + |
| Veri seti-17 | ELBP (16,2) + 4 Yerel Histogram | + | + | + |
| Veri seti-18 | ELBP (16,2) + 4 Yerel Histogram + Kırılmış görüntüler | + | + | + |
| Veri seti-19 | ELBP (16,2) + 8 Yerel Histogram | + | + | + |
| Veri seti-20 | ELBP (16,2) + 8 Yerel Histogram + Kırılmış görüntüler | + | + | + |

3.2. Veri seti-1

Veri seti-1 hazırlanırken, görüntülerin yerel ikili örüntüleri hesaplanmış ve dört adet yerel histogram kullanılmıştır. Histogramdaki veriler düzgün yerel ikili örüntüler dikkate alınmış, diğer yerel ikili örüntüler ise tek değer olarak etiketlenmiştir. Elde edilen sonuçlar, Tablo 4’te verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 4. Veri seti-1 sınıflandırma performansları

| Sınıf | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-------------------------------------|-------------------|-------------------|-------------------|
| Sınıflandırma Yöntemi | | | |
| Destek Vektör Makineleri (%) | 70,63 | 72,02 | 85,37 |
| K En Yakın Komşu, K=21 (%) | 56,08 | 59,80 | 73,12 |
| Yalın Bayes (%) | 55,55 | 56,91 | 71,14 |

3.3. Veri seti-2

Veri seti-2 hazırlanırken, kırılmış görüntülerin yerel ikili örüntüleri hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 5’te verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 5. Veri seti-2 sınıflandırma performansları

| Sınıf | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-------------------------------------|-------------------|-------------------|-------------------|
| Sınıflandırma Yöntemi | | | |
| Destek Vektör Makineleri (%) | 71,42 | 75,24 | 84,98 |
| K En Yakın Komşu, K=21 (%) | 52,91 | 55,62 | 74,30 |
| Yalın Bayes (%) | 55,29 | 59,80 | 69,96 |

3.4. Veri seti-3

Veri seti-3 hazırlanırken, görüntülerin yerel ikili örüntüleri hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 6’da verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 6. Veri seti-3 sınıflandırma performansları

| Sınıf | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-------------------------------------|-------------------|-------------------|-------------------|
| Sınıflandırma Yöntemi | | | |
| Destek Vektör Makineleri (%) | 55,02 | 60,12 | 63,63 |
| K En Yakın Komşu,K=21 (%) | 41,00 | 45,98 | 54,15 |
| Yalın Bayes (%) | 36,24 | 36,01 | 54,15 |

3.5. Veri seti-4

Veri seti-4 hazırlanırken, kırılmış görüntülerin yerel ikili örüntüleri hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 7’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 7. Veri seti-4 sınıflandırma performansları

| Sınıf | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-------------------------------------|-------------------|-------------------|-------------------|
| Sınıflandırma Yöntemi | | | |
| Destek Vektör Makineleri (%) | 60,05 | 61,09 | 73,91 |
| K En Yakın Komşu,K=21 (%) | 45,23 | 51,12 | 54,94 |
| Yalın Bayes (%) | 35,44 | 33,76 | 55,73 |

3.6. Veri seti-5

Veri seti-5 hazırlanırken, görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(8,1)) hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 8’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 8. Veri seti-5 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 53,43 | 56,59 | 64,03 |
| K En Yakın Komşu, K=23 (%) | 41,79 | 42,76 | 54,54 |
| Yalın Bayes (%) | 48,14 | 53,69 | 62,05 |

3.7. Veri seti-6

Veri seti-6 hazırlanırken, kırılmış görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(8,1)) hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 9’da verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 9. Veri seti-6 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 56,61 | 61,41 | 69,56 |
| K En Yakın Komşu, K=23 (%) | 47,61 | 50,48 | 67,98 |
| Yalın Bayes (%) | 52,64 | 54,98 | 65,21 |

3.8. Veri seti-7

Veri seti-7 hazırlanırken, görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(8,1)) hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 10'da verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 10. Veri seti-7 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 43,12 | 46,42 | 56,12 |
| K En Yakın Komşu, K=23 (%) | 29,10 | 38,58 | 41,50 |
| Yalın Bayes (%) | 30,68 | 32,79 | 51,77 |

3.9. Veri seti-8

Veri seti-8 hazırlanırken, kırpılmış görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(8,1)) hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 11'de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 11. Veri seti-8 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 52,38 | 55,62 | 69,96 |
| K En Yakın Komşu, K=23 (%) | 40,47 | 43,72 | 51,38 |
| Yalın Bayes (%) | 40,47 | 36,97 | 65,03 |

3.10. Veri seti-9

Veri seti-9 hazırlanırken, görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(8,2)) hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 12’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 12. Veri seti-9 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 52,38 | 58,84 | 61,26 |
| K En Yakın Komşu, K=23 (%) | 39,15 | 42,12 | 60,07 |
| Yalın Bayes (%) | 45,50 | 45,01 | 50,98 |

3.11. Veri seti-10

Veri seti-10 hazırlanırken, kırılmış görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(8,2)) hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 13’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 13. Veri seti-10 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 58,73 | 62,37 | 74,70 |
| K En Yakın Komşu, K=23 (%) | 48,14 | 47,58 | 66,79 |
| Yalın Bayes (%) | 52,64 | 57,55 | 66,40 |

3.12. Veri seti-11

Veri seti-11 hazırlanırken, görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(8,2)) hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 14’te verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 14. Veri seti-11 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 42,32 | 52,41 | 57,70 |
| K En Yakın Komşu, K=23 (%) | 30,95 | 36,65 | 41,10 |
| Yalın Bayes (%) | 32,35 | 34,72 | 55,33 |

3.13. Veri seti-12

Veri seti-12 hazırlanırken, kırılmış görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(8,2)) hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 15’te verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 15. Veri seti-12 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 56,61 | 59,48 | 68,77 |
| K En Yakın Komşu, K=23 (%) | 42,59 | 38,58 | 52,17 |
| Yalın Bayes (%) | 39,68 | 47,26 | 63,63 |

3.14. Veri seti-13

Veri seti-13 hazırlanırken, görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(16,1)) hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 16’da verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 16. Veri seti-13 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 48,67 | 55,30 | 60,47 |
| K En Yakın Komşu, K=23 (%) | 37,56 | 41,15 | 50,98 |
| Yalın Bayes (%) | 42,59 | 43,72 | 58,49 |

3.15. Veri seti-14

Veri seti-14 hazırlanırken, kırılmış görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(16,1)) hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 17’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 17. Veri seti-14 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 55,02 | 58,52 | |
| K En Yakın Komşu, K=23 (%) | 44,97 | 49,51 | |
| Yalın Bayes (%) | 46,56 | 46,62 | |

3.16. Veri seti-15

Veri seti-15 hazırlanırken, görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(16,1)) hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 18’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 18. Veri seti-15 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 44,70 | 51,12 | 59,28 |
| K En Yakın Komşu, K=23 (%) | 27,51 | 31,18 | 41,50 |
| Yalın Bayes (%) | 30,15 | 36,33 | 53,75 |

3.17. Veri seti-16

Veri seti-16 hazırlanırken, kırılmış görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(16,1)) hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 19’da verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 19. Veri seti-16 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 51,58 | 58,19 | 73,91 |
| K En Yakın Komşu, K=23 (%) | 37,03 | 42,76 | 49,01 |
| Yalın Bayes (%) | 36,77 | 34,72 | 57,70 |

3.18. Veri seti-17

Veri seti-17 hazırlanırken, görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(16,2)) hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 20’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 20. Veri seti-17 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 50,79 | 55,62 | 62,05 |
| K En Yakın Komşu,K=23 (%) | 38,35 | 40,51 | 51,77 |
| Yalın Bayes (%) | 35,44 | 39,22 | 56,91 |

3.19. Veri seti-18

Veri seti-18 hazırlanırken, kırılmış görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(16,2)) hesaplanmış ve dört adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 21’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 21. Veri seti-18 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 54,23 | 63,34 | 65,61 |
| K En Yakın Komşu,K=23 (%) | 46,82 | 50,48 | 62,45 |
| Yalın Bayes (%) | 39,68 | 40,51 | 63,63 |

3.20. Veri seti-19

Veri seti-19 hazırlanırken, görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(16,2)) hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 22’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 22. Veri seti-19 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 40,74 | 50,48 | 58,89 |
| K En Yakın Komşu, K=23 (%) | 29,10 | 36,97 | 38,33 |
| Yalın Bayes (%) | 28,57 | 30,86 | 50,19 |

3.21. Veri seti-20

Veri seti-20 hazırlanırken, kırılmış görüntülerin genişletilmiş yerel ikili örüntüleri (ELBP(16,2)) hesaplanmış ve sekiz adet yerel histogram kullanılmıştır. Elde edilen sonuçlar, Tablo 23’de verilmiştir. Bu sonuçlara göre, tüm sınıflar için en başarılı tanıma DVM Sınıflandırma yöntemi ile elde edilmiştir.

Tablo 23. Veri seti-20 sınıflandırma performansları

| Sınıf Sınıflandırma Yöntemi | Yedi Sınıf | Altı Sınıf | Dört Sınıf |
|-----------------------------------|------------|------------|------------|
| Destek Vektör Makineleri (%) | 53,17 | 56,91 | 68,37 |
| K En Yakın Komşu, K=23 (%) | 38,35 | 45,33 | 52,96 |
| Yalın Bayes (%) | 37,03 | 33,44 | 58,49 |

3.22. Öğrenme Hata Matrisi

Bu bölümde, yedi sınıfta en yüksek doğruluğa DVM Sınıflandırma yöntemi ile ulaşılan Veri seti-2'ye ait öğrenme hata matrisi Tablo 24'te verilmiştir. Verilen tabloya göre, sınıflar arasında en yüksek tanınan yüz ifadeleri, şaşırma, ifadesiz ve mutluluk sınıflarıdır. En az tanınma doğruluğuna sahip sınıflar ise öfke ve üzüntüdür.

Tablo 24. Öğrenme hata matrisi

| | İfadesiz | Şaşırma | Üzüntü | Öfke | Tiksinme | Korku | Mutluluk |
|----------|----------|---------|--------|------|----------|-------|----------|
| İfadesiz | 56 | 7 | 2 | 0 | 1 | 1 | 0 |
| Şaşırma | 6 | 59 | 0 | 0 | 2 | 0 | 0 |
| Üzüntü | 15 | 3 | 15 | 1 | 1 | 2 | 0 |
| Öfke | 0 | 0 | 0 | 7 | 6 | 4 | 12 |
| Tiksinme | 1 | 2 | 0 | 3 | 39 | 11 | 0 |
| Korku | 0 | 1 | 0 | 5 | 13 | 20 | 1 |
| Mutluluk | 0 | 0 | 0 | 5 | 0 | 3 | 74 |

3.23. Adaboost Algoritmasının Öğrenme Doğruluğuna Etkisi

Elde edilen tanıma performanslarını yükseltmek için yedi sınıfta en yüksek tanıma doğruluğu olan sınıf (Veri seti-2) verilerine normalizasyon uygulanmıştır. Sonuçlar Tablo 25'te görülmektedir.

Tablo 25. Adaboost algoritmasının öğrenme doğruluğuna etkisi

| Sınıflandırma Yöntemi | Yedi Sınıf | | Altı Sınıf | | Dört Sınıf | |
|------------------------------|------------|-------|------------|-------|------------|-------|
| | Önce | Sonra | Önce | Sonra | Önce | Sonra |
| Destek Vektör Makineleri (%) | 72,42 | 69,31 | 75,24 | 73,63 | 84,98 | 83,04 |
| K En Yakın Komşu, K=21 (%) | 52,91 | 53,43 | 55,62 | 55,62 | 74,30 | 73,12 |
| Yalın Bayes (%) | 52,29 | 57,14 | 59,80 | 60,12 | 69,96 | 75,88 |

3.24. Öznitelik Altküme Seçiminin Öğrenme Doğruluğuna Etkisi

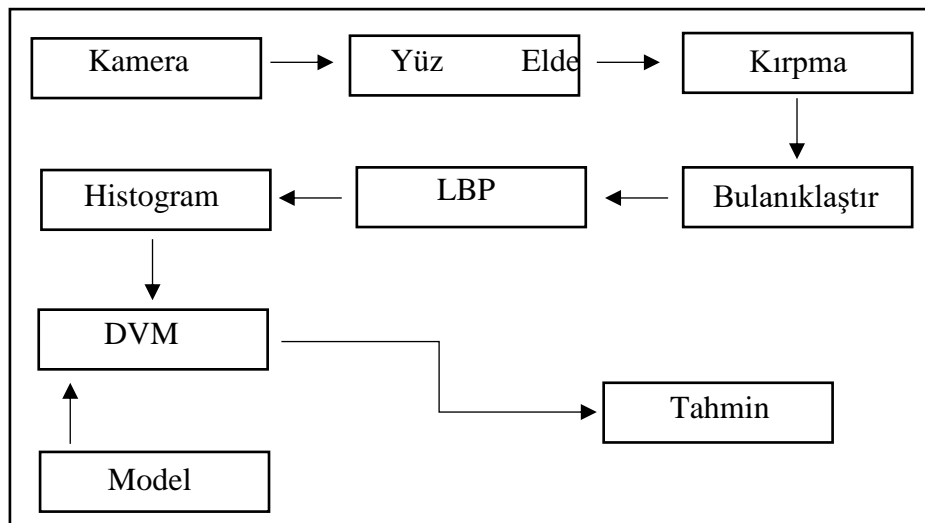
Elde edilen tanıma performanslarını yükseltmek için yedi sınıfta en yüksek tanıma doğruluğu olan sınıf (Veri seti-2) verilerine normalizasyon uygulanmıştır. Sonuçlar Tablo 26'daki gibidir.

Tablo 26. Öznitelik altküme seçiminin öğrenme doğruluğuna etkisi

| Sınıflandırma Yöntemi | Yedi Sınıf | | Altı Sınıf | | Dört Sınıf | |
|------------------------------|------------|-------|------------|-------|------------|-------|
| | Önce | Sonra | Önce | Sonra | Önce | Sonra |
| Destek Vektör Makineleri (%) | 72,42 | 65,60 | 75,24 | 68,81 | 84,98 | 80,63 |
| K En Yakın Komşu, K=21 (%) | 52,91 | 59,25 | 55,62 | 62,05 | 74,30 | 75,88 |
| Yalın Bayes (%) | 52,29 | 60,31 | 59,80 | 66,23 | 69,96 | 79,84 |

3.25. Elde Edilen Başarılı Modellerin Gerçek Zamanlı Videoya Uygulanması

Yapılan analizler sonucunda, elde edilen en yüksek tanıma doğruluğuna ait model gerçek zamanlı videodan yüz ifadesi tanımak için kullanılmıştır. Veri seti-2 ve DVM Sınıflama Yöntemi kullanılarak geliştirilen yazılım, bilgisayar kamerası yardımıyla alınan görüntüleri tanımaktadır. Görüntüler 0.2 milisaniye aralıklarla işlenmektedir.



Şekil 15. Sistemin blok diyagramı


Geliştirilen yazılımın blok diyagramı Şekil 15’te görülmektedir. Bilgisayar kamerasıyla alınan görüntülerden öncelikle yüz elde ederek, kırpma işlemi yapılmaktadır. Daha sonra görüntünün LBP kodları hesaplanarak öznitelikler elde edilmektedir. Elde edilen öznitelikler, daha önceden eğitilerek kaydedilen model üzerinde denenmekte ve sistem çıktı vermektedir.

Yapılan deneylerde yedi sınıflı tanıma başarısı, eğitim kümesinden elde edilen tanıma başarısından daha düşük olmuştur. Deneylerin sakallı bireyler için başarısı, sakalsız insanlara göre daha düşük olarak gözlemlenmiştir. Yedi sınıflı tanımada ifadesiz, korku ve tikslenme sınıfları üzüntü sınıfıyla karıştırıldığı, sürpriz ifadesinin ise mutluluk ile karıştırıldığı gözlemlenmiştir. Eğitim için kullanılan verilerin son derece kontrollü bir ortamdan toplanmış olması ve bilgisayar kamerasına göre daha yüksek çözünürlüklü bir fotoğraf makinesi ile toplanmış olmasının tanıma başarısını düşürdüğü düşünülmektedir.

Yapılan ilk deneyde diğer ifadelerin, en fazla karıştırıldığı sınıf olan üzüntü ifadesi eğitim sınıflarından çıkarılarak, mutluluk, şaşırma, korku, tikslenme ve öfke ifadelerinden oluşan veri seti eğitilerek yeni bir model oluşturulmuştur. Yeni model ile yapılan deneylerde, şaşırma ve ifadesiz sınıflarını tanıyabilmiş ancak diğer grupları birbirlerine karıştırarak tanıma yapmıştır.

Yedi sınıflı tanıma için eğitim kümesinde gösterilen başarıdan uzak bir performans sergileyen yazılım, dört sınıflı eğitim kümesi ile eğitilen model ile denenmiştir. Eğitim kümesi, ifadesiz, şaşırma, üzüntü ve mutluluk sınıflarından oluşan yeni model ile yapılan deneylerde, şaşkınlık ve ifadesiz sınıflarını tanıırken, diğer grupları yedi ve altı sınıflı modellere göre daha başarılı bir şekilde tanımıştır.

Çoklu sınıf denemelerinden sonra, sınıflar ifadesiz sınıftan ayrılacak şekilde ikili sınıflar halinde eğitilmiş ve çoklu sınıfların kullanıldığı deneylere göre daha başarılı olmuş, en yüksek doğrulukla tanıma ise mutlu ve şaşkın sınıfları için olmuştur. Şekil 16’da sistemin çıktıları görülmektedir.



Şekil 16. Yazılım çıktıları

4. SONUÇLAR

Çalışma kapsamında analiz edilmek üzere, 124 adet, değişik yöntemlerle öznitelikleri elde edilmiş, çeşitli sınıflarda verisetleri hazırlanmıştır. Hazırlanan bu verisetlerinden 66 tanesi çalışma içerisinde sunulmuştur. Söz konusu verisetleri arasında yüz ifadelerini tanıma anlamında yedi sınıf için en başarısız olan grup, Veri seti-19'dur. En başarılı olan ise Veri seti-2'dir. Veri seti 19'da öznitelikler genişletilmiş yerel ikili örüntüler (ELBP(16,2)) ile elde edilmiş ve sekiz yerel histogram kullanılmıştır. Veri seti-2'de ise kırılmış görüntülerden LBP kodları elde edilmiş ve dört yerel histogram kullanılmıştır. Genişletilmiş yerel ikili örüntüler büyük görüntüler için daha uygundur. Bundan dolayı, bu çalışmadaki veri setine uygulandığında ayrıntılar kaybolmuş ve tanıma oranı düşmüştür. Çalışmada kullanılan görüntüler için yerel ikili örüntüler ve dört yerel histogram yüz ifadelerini tanımak için en uygun kombinasyon olarak belirlenmiştir.

Çalışmada verisetlerinin analizinde kullanılan öğrenme yöntemleri, elde edilen en başarılı model, gerçek zamanlı videodan yüz ifadeleri analizinde kullanılacağı için uygulanması ve hesaplanma süreleri diğer öğrenme yöntemlerine göre kolay ve daha kısa olabilecek yöntemler seçilmiştir. Seçilen öğrenme yöntemlerinden, K En Yakın Komşu Yönteminin yedi sınıfta en yüksek tanıma oranı %56,08 olarak Veri seti-1'de elde edilmiştir. Yalın Bayes Yönteminin ise yedi sınıfta en yüksek tanıma oranı ise, %55,55 olarak Veri seti-1'de elde edilmiştir.

Yedi sınıfta, elde edilen en yüksek başarı olan DVM sınıflandırıcı ve Veri seti-2'nin öğrenme hata matrisine de çalışmada yer verilmiştir. Tablo incelendiğinde, mutluluk ifadesinin en az karıştırılan sınıf olduğu gözlemlenmektedir. En çok birbirine karıştırılan ifadeler ise tikslenme ve korku ifadeleri olmuştur.

Elde edilen öğrenme doğruluklarını arttırmak için sonuçlarda verilen tüm verisetlerindeki değerlere normalizasyon yapılmıştır. Önerilen diğer yöntemler ise ayrı başlıklarda, yedi sınıfta elde edilen en yüksek başarılı veri seti olan Veri seti-2 için incelenmiştir. Sonuçlar incelendiğinde, Adaboost Algoritmasının, DVM sınıflandırıcı için başarısı düşerken, KNN ve Yalın Bayes Yöntemleri için öğrenme doğruluğunun arttığı görülmektedir. Performansı arttırmak için önerilen diğer yöntem olan Öznitelik Altküme Seçimi uygulandıktan sonra, 237 olan öznitelik sayısı, 15'e düşürülmüştür. Elde edilen yeni öznitelikleri ile öğrenme yöntemleri uygulandığında DVM sınıflandırıcısının başarısı düşmüş, KNN ve Yalın Bayes yöntemlerinde öğrenme başarısı artmıştır.

5. ÖNERİLER

Yüz ifadesi tanıma bilgisayar bilimleri alanında sıklıkla çalışılan bir alandır. Bu çalışma kapsamında da kişiden bağımsız gerçek zamanlı video sekansından elde edilen görüntüler üzerinde, yerel ikili örüntüler temel alınarak, yüz ifadesi tanıma çalışması yapılmıştır. Farklı sınıflandırma teknikleri ile, yüz ifadesi konusundaki en geniş veritabanı olan Cohn-Kanade veritabanından alınan görüntülerle incelenmiştir.

Yüz ifadelerinden oluşan veritabanları, kontrollü ortamda toplanan yüksek çözünürlüklü verilerden oluşmaktadır. Bu çalışmada olduğu gibi, gerçek zamanlı bir videodan alınan görüntüler ise, düşük çözünürlüklü olabilir. Yüksek çözünürlüklü veriler ile eğitilen modeller, gerçek dünyadan alınan veriler ile denendiğinde performans kayıpları olmaktadır. Gerçek ortamlardan toplanan veriler ile eğitilen modeller, gerçek zamanlı yapılan yüz ifadeleri tanımak için daha başarılı olacağı ön görülmektedir.

Eğitim verilerinin dışındaki veriler test olarak alındığında, performans kayıpları gözlemlenmiştir. Farklı ortamlardan toplanan görüntülerin eğitim için kullanılması, elde edilen modelin diğer veriler üzerinde de başarılı olmasını sağlayacaktır.

Çalışmada elde edilen performansların gerçek dünyada elde edilememesinin bir diğer sebebi ise fotoğrafları çekilen deneklerin ilgili yüz ifadelerini taklit etmeleri ve bazı ifadeleri de abartarak yapmaları sonucudur. Eğitim verilerin doğal yüz ifadelerinden oluşması da gerçek zamanlı videolarda yüz ifadesi tanıma konusunda performansı arttıracığı düşünülmektedir.

6. KAYNAKÇA

1. Darwin, C., The Expression of Emotion in Man and Animals, Animals, 1227 1872. 372.
2. Mehrabian, A., Silent Messages., Wadsworth Pub. Co, California, 1971.
3. Hjortsjö, C.-H., Universitäts-Und Landesbibliothek Tirol Man's Face and Mimic Language, Malmö, 1970.
4. EKMAN and P., Facial Action Coding System FACS, A Human Face, 2002.
5. Ekman, P. and Friesen, W. V., The Facial Action Coding System., Consulting, 1982.
6. Ekman, P. and Friesen, W. V., The Facial Action Coding System., Consulting, 1978.
7. Viola, P. and Jones, M., Rapid Object Detection Using a Boosted Cascade of Simple Features, 2001, Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001,I-511-I-518.
8. Papageorgiou, C.P., Oren, M. and Poggio, T., A General Framework for Object Detection, 1998. Sixth International Conference On Computer Vision, 6, Ocak 1998, Bildiriler Kitabı: 555–562.
9. Freund, Y. and Schapire, R.E., A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting, Journal of Computer and System Sciences, 55, Ocak 1997, Bildiriler Kitabı:119–139.
10. Schapire, R.E., Freund, Y., Bartlett, P. and Lee, W.S., Boosting the Margin: A New Explanation for the Effectiveness of Voting Methods, Annals of Statistics, 26, Mayıs 1998, Bildiriler Kitabı: 1651–1686.
11. Ojala, T., Pietikäinen, M. and Harwood, D., A Comparative Study of Texture Measures with Classification Based on Featured Distributions, Pattern Recognition, 29, Ocak 1996 Bildiriler Kitabı: 51–59.
12. Ojala, T., Pietikainen, M. and Maenpaa, T., Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns, IEEE Transactions on Pattern Analysis and Machine Intelligence, 24, Temmuz 2002, Bildiriler Kitabı: 971–987.
13. Alpaydın, E., Introduction to Machine Learning, 1107, MIT Press, Massachusetts, 2014.
14. Jiawei, H., Kamber, M., Han, J., Kamber, M. and Pei, J., Data Mining: Concepts and Techniques, Elsevier, New York, 2012.


15. Boser, B.E., Guyon, I.M. and Vapnik, V.N., A Training Algorithm for Optimal Margin Classifiers, Proceedings of the fifth annual workshop on Computational learning theory - COLT, 1992,144–152.
16. Gunn, S.R., Support Vector Machines for Classification and Regression, Image Speech and Intelligent Systems Technical Report, 14,Mayıs 1998, Bildiriler Kitabı: 230–67.
17. Lin, H. and Lin, C., A Study on Sigmoid Kernels for SVM and the Training of Non-PSD Kernels by SMO-Type Methods, Neural Computation, Şubat 2003, Bildiriler Kitabı: 1–32.
18. Yang, M.H., Kriegman, D.J. and Ahuja, N., Detecting Faces in Images: A Survey, IEEE Transactions on Pattern Analysis and Machine Intelligence, 24,Ocak 2002, Bildiriler Kitabı: 34–58.
19. Jiang, J. and Ip, H.H.S., A Real-Time Hierarchical Rule-Based Approach for Scale Independent Human Face Detection, 6496 2007 64960P.
20. Devadethan, S., Titus, G. and Purushothaman, S., Face Detection and Facial Feature Extraction Based on a Fusion of Knowledge Based Method and Morphological Image Processing, 2014 Annual International Conference on Emerging Research Areas: Magnetics, Machines and Drives, AICERA/ICMMD 2014 - Proceedings, 2014.
21. Gizatdinova, Y. and Surakka, V., Feature-Based Detection of Facial Landmarks from Neutral and Expressive Facial Images, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28,Ocak 2006, Bildiriler Kitabı: 135–139.
22. Osman, M.Z., Maarof, M.A. and Rohani, M.F., Improved Dynamic Threshold Method for Skin Colour Detection Using Multi-Colour Space, American Journal of Applied Sciences, 2016.
23. Tripathi SOIT, S., Bhopal Varsha Sharma SOIT, R., Bhopal Sanjeev Sharma SOIT, R. and Bhopal, R., Face Detection Using Combined Skin Color Detector and Template Matching Method, International Journal of Computer Applications, 26,Temmuz 2011, Bildiriler Kitabı: 975–8887.
24. Archana, T.. and Venugopal, T., Face Recognition: A Template Based Approach, 2015, Proceedings of the 2015 International Conference on Green Computing and Internet of Things, ICGCIoT 2015, Bildiriler Kitabı: 966–969.
25. Mohan, A.R. and Sudha, N., Fast Face Detection Using Boosted Eigenfaces, 2009, ISIEA 2009. IEEE Symposium on Industrial Electronics Applications, 2009, Bildiriler Kitabı: 1002–1006.
26. Bouzalmat, A., Belghini, N., Zarghili, A. and Kharroubi, J., Face Detection And Recognition Using Back Propagation Neural Network And Fourier Gabor Filters, An International Journal SIPIJ, 2,Mart 2011.

27. Ruan, J. and Yin, J., Face Detection Based on Facial Features and Linear Support Vector Machines, Communication Software and Networks, 2009. ICCSN '09. International Conference On, 2009, Bildiriler Kitabı: 371–375.
28. Zhang, Z., Lyons, M., Schuster, M., Akamatsu, S. and Cedex, F.-S., Comparison Between Geometry-Based and Gabor-Wavelets-Based Facial Expression Recognition Using Multi-Layer Perceptron, Automatic Face and Gesture Recognition, 1998. Proceedings. Third IEEE International Conference, 1998, Bildiriler Kitabı: 454–459.
29. Tian, Y.L., Kanade, T. and Conn, J.F., Recognizing Action Units for Facial Expression Analysis, IEEE Transactions on Pattern Analysis and Machine Intelligence, 23, Şubat, 2001, Bildiriler Kitabı: 97–115.
30. Pantic, M. and Rothkrantz, L.J.M., Facial Action Recognition for Facial Expression Analysis From Static Face Images, IEEE Transactions on Systems, Man and Cybernetics, Part B Cybernetics, 34, Mart 2004, 1449–1461.
31. Ghimire, D. and Lee, J., Geometric Feature-Based Facial Expression Recognition in Image Sequences Using Multi-Class AdaBoost and Support Vector Machines., Sensors Basel, Switzerland, 13,6 2013 7714–34.
32. Patil, M.N., Iyer, B. and Arya, R., Performance Evaluation of PCA and ICA Algorithm for Facial Expression Recognition Application, 2016, Advances in Intelligent Systems and Computing, 965–976.
33. Shah, J.H., Sharif, M., Yasmin, M. and Fernandes, S.L., Facial Expressions Classification and False Label Reduction Using LDA and Threefold SVM, Pattern Recognition Letters, 2017.
34. Chen, S., Sun, Y. and Yin, B., A Novel Hybrid Approach Based on Sub-Pattern Technique and Extended 2DPCA for Color Face Recognition, 2009, ISM 2009 - 11th IEEE International Symposium on Multimedia, 630–634.
35. Aswathy, M.R., A Literature Review on Facial Expression Recognition Techniques, IOSR Journal of Computer Engineering, 1 2013 2278–661.
36. Belhumeur, P.N., Hespanha, J.P. and Kriegman, D.J., Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 19, Temmuz 1997, Bildiriler Kitabı: 711–720.
37. Sirovich, L. and Kirby, M., Low-Dimensional Procedure for the Identification of Human Faces, J. Opt. Soc. Amer. A, 4, Mart 1987, Bildiriler Kitabı: 519–524.
38. Draper, B.A., Baek, K., Bartlett, M.S. and Beveridge, J.R., Recognizing Faces with PCA and ICA, Computer Vision and Image Understanding, 91, Şubat 2003, Bildiriler Kitabı: 115–137.

39. Jian Yang, Zhang, D., Frangi, A.F. and Jing-yu Yang, Two-Dimensional Pca: A New Approach to Appearance-Based Face Representation and Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 26, Ocak 2004, Bildiriler Kitabı: 131–137.
40. Torres, L., Reutter, J.Y. and Lorente, L., The Importance of the Color Information in Face Recognition, 1999, Image Processing, 1999. ICIP 99. Proceedings. 1999 International Conference on, 627–631 vol.3.
41. Chen, S., Sun, Y. and Yin, B., A Novel Hybrid Approach Based on Sub-Pattern Technique and Extended 2DPCA for Color Face Recognition, ISM 2009 - 11th IEEE International Symposium on Multimedia, 2009, Bildiriler Kitabı: 630–634.
42. Thomas, M., Kambhamettu, C. and Kumar, S., Face Recognition Using a Color Subspace LDA Approach, 2008, Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI, 231–235.
43. Vasilescu, M.A.O. and Terzopoulos, D., Multilinear Image Analysis for Facial Recognition, 2002, International Conference on Pattern Recognition, 511–514 vol.2.
44. Barbu, T., The Publishing House Gabor Filter-Based Face Recognition Technique, Proceedings Of The Romanian Academy, 11,3 2010 277–283.
45. Padgett, C. and Cottrell, G.W., Representing Face Images for Emotion Classification, Advances in Neural Information Processing Systems, 1997 894–900.
46. Tian, Y.L., Evaluation of Face Resolution for Expression Analysis, 2004, IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops.
47. Bartlett, M.S., Littlewort, G., Frank, M., Lainscsek, C., Fasel, I. and Movellan, J., Recognizing Facial Expression: Machine Learning and Application to Spontaneous Behavior, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005, Bildiriler Kitabı: 568–573.
48. Cohen, I., Sebe, N., Garg, A., Chen, L.S. and Huang, T.S., Facial Expression Recognition from Video Sequences: Temporal and Static Modeling, Computer Vision and Image Understanding, 91, Ocak 2003, Bildiriler Kitabı: 160–187.
49. O.P.Satish and P.G.Salunke, A Survey on Face Recognition and Facial Expression Identification, International Journal of Engineering and Advanced Technology International Journal of Engineering and Advanced Technology, 44 2014.
50. Chang, J., Chen, J., Chang, J.-Y. and Chen, J.-L., Automated Facial Expression Recognition System Using Neural Networks, Journal of the Chinese Institute of Engineers, 24, Mart 2001, Bildiriler Kitabı: 345–356.

51. Abdullah, M., Wazzan, M. and Bo-Saeed, S., OPTIMIZING FACE RECOGNITION USING PCA, International Journal of Artificial Intelligence & Applications IJAIA, 3,2 2012.
52. G. R. S. Murthy and R.S.Jadon, Effectiveness of Eigenspaces for Facial Expressions Recognition, International Journal of Computer Theory and Engineering, 1,5 2009.
53. Andrysiak, T. and Chor, M., IMAGE RETRIEVAL BASED ON HIERARCHICAL GABOR FILTERS, Int. J. Appl. Math. Comput. Sci, 15,Nisan 2005, Bildiriler Kitabı: 471–480.
54. Deng, H.-B., Jin, L.-W., Zhen, L.-X. and Huang, J.-C., A New Facial Expression Recognition Method Based on Local Gabor Filter Bank and PCA plus LDA * A New Facial Expression Recognition Method Based on Local Gabor Filter Bank and PCA plus LDA, International Journal of Information Technology, 2005.
55. V.Praseeda Lekshmi, M.Sasikumar and S.Naveen, Analysis of Facial Expressions from Video Images Using PCA, Proceedings of the World Congress on Engineering , 2008.
56. Whitehill, J.R., Automatic Real-Time Facial Expression Recognition for Signed Language Translation, 2006.
57. Yang, P., Liu, Q. and Metaxas, D.N., Boosting Coded Dynamic Features for Facial Action Units and Facial Expression Recognition.
58. Sarode, N. and Bhatia, S., Facial Expression Recognition, International Journal on Computer Science and Engineering, Mayıs 2010, Bildiriler Kitabı: 1552–1557.
59. Shih, F.Y., Chuang, C.-F. and Wang, P.S.P., Performance Comparisons Of Facial Expression Recognition In Jaffe Database, International Journal of Pattern Recognition and Artificial Intelligence, 22,Mart 2008, Bildiriler Kitabı: 445–459.
60. Kong, W.K., Zhang, D. and Li, W., Palmprint Feature Extraction Using 2-D Gabor Filters, Pattern Recognition, 36 2003 2339–2347.
61. Kanade, T., Cohn, J.F. and Tian, Y., Comprehensive Database for Facial Expression Analysis, 2000, Fourth IEEE International Conference on Automatic Face and Gesture Recognition.
62. Shan, C., Gong, S. and McOwan, P.W., Facial Expression Recognition Based on Local Binary Patterns: A Comprehensive Study, Image and Vision Computing, Haziran 2009, Bildiriler Kitabı: 803–816.
63. Gonzales, R.C. and Woods, R.E., Digital Image Processing, Prentice Hall, New Jersey 2008.

7. EKLER



Ek 1. LBP Kodları Hesaplanmış Görüntü

ÖZGEÇMİŞ

M. Bekir Dabanođlu, Diyarbakır'da doğdu. Karadeniz Teknik Üniversitesi, İstatistik ve Bilgisayar Bilimleri Bölümü'ndeki eğitimini 2014 yılında tamamladıktan sonra 2015 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik ve Bilgisayar Anabilim Dalı'nda yüksek lisans programına başladı. 2014 yılından itibaren çeşitli şirketlerde yazılım geliştirici olarak, istatistiksel yazılımlar, veri görselleştirme, görüntü işleme, makine öğrenmesi ve finans yazılımları konularında çalışmaktadır.

