

**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**YÜZ GÖRÜNTÜLERİNDEN HASTALIKLARIN ÖN TANISI**

**YÜKSEK LİSANS TEZİ**

**Bilg. Müh. Beste GENÇTÜRK**

**OCAK 2013**  
**TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**YÜZ GÖRÜNTÜLERİNDEN HASTALIKLARIN ÖN TANISI**

**Bilgisayar Müh. Beste GENÇTÜRK**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde**  
**"BİLGİSAYAR YÜKSEK MÜHENDİSİ"**  
**Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 21.01.2013**  
**Tezin Savunma Tarihi : 14.01.2013**

**Tez Danışmanı : Prof. Dr. Vasif V. NABİYEV**

**Trabzon 2013**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü**  
**Bilgisayar Mühendisliği Anabilim Dalında**  
**Beste GENÇTÜRK tarafından hazırlanan**

**YÜZ GÖRÜNTÜLERİNDEN HASTALIKLARIN ÖN TANISI**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 25.12.2012 gün ve 1487-01 sayılı  
kararıyla oluşturulan jüri tarafından yapılan sınavda**

**YÜKSEK LİSANS TEZİ**  
**olarak kabul edilmiştir.**

**Jüri Üyeleri**

**Başkan : Prof. Dr. Vasif V. NABİYEV**

**Üye : Doç. Dr. Ali GANGAL**

**Üye : Yrd. Doç. Dr. Güzin ULUTAŞ**

**Prof. Dr. Sadettin KORKMAZ**  
**Enstitü Müdürü**

## ÖNSÖZ

Günümüzde ön tanı, hekim tecrübesine bağlı olarak değişmekte ve sonucunda birçok hasta yanlış yönlendirilip, gereksiz bir sürü teste tabi tutulmaktadır. Bu amaçla çalışmada, yüzden hastalık teşhisi yaparak, cinsiyetten, yaştan ve yüz ifadelerinden bağımsız otomatik ön tanı programı geliştirilmiştir. Önerilen ön tanı programı, yeterli sayıda önceden kesin tanısı koyulmuş hastalık görüntüleriyle eğitilmesi ve online hale getirilmesi durumunda tıp dünyasına büyük bir katkı sağlamış olacaktır.

Yüksek Lisans eğitimim ve özellikle de tez çalışması süresince yol gösteren, zaman ayıran Sayın Hocam Prof. Dr. Vasif V. NABİYEV'e teşekkürlerimi sunarım. Ayrıca meslektaşım Öğr. Gör. Arda ÜSTÜBİOĞLU' na ve çalışmam süresince sabır, destek ve sevgileriyle hep yanımda olan aileme ve dostlarıma çok teşekkür ederim.

Beste GENÇTÜRK  
Trabzon 2013

## **TEZ BEYANNAMESİ**

Yüksek Lisans Tezi olarak sunduğum “Yüz Görüntülerinden Hastalıkların Ön Tanısı” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Vasif V. NABİYEV ‘in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuarlarda yaptığımı/yaptırdığımı, 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. 21.01.2013

Beste GENÇTÜRK

## İÇİNDEKİLER

|                                                         | <u>Sayfa No</u> |
|---------------------------------------------------------|-----------------|
| ÖNSÖZ .....                                             | III             |
| TEZ BEYANNAMESİ.....                                    | IV              |
| İÇİNDEKİLER.....                                        | V               |
| ÖZET.....                                               | VIII            |
| SUMMARY .....                                           | IX              |
| ŞEKİLLER DİZİNİ .....                                   | X               |
| TABLolar DİZİNİ.....                                    | XIII            |
| SEMBOLLER DİZİNİ .....                                  | XIV             |
| 1. GENEL BİLGİLER.....                                  | 1               |
| 1.1. Giriş .....                                        | 1               |
| 1.2. Yüzden Teşhis Edilen Hastalıklar .....             | 3               |
| 1.2.1. Akromegali .....                                 | 3               |
| 1.2.2. Down Sendromu .....                              | 5               |
| 1.2.3. Sistemik Lupus Eritematozus .....                | 6               |
| 1.3. Çalışmanın Genel Yapısı ve Amacı.....              | 7               |
| 1.4. Özellik Çıkarımı .....                             | 9               |
| 1.4.1. Analitik Yaklaşımlar.....                        | 9               |
| 1.4.2. Bütünsel Yaklaşımlar.....                        | 11              |
| 1.4.2.1. Yerel Örüntüler.....                           | 13              |
| 1.4.2.1.1. Yerel İkili Örüntüler .....                  | 13              |
| 1.4.2.1.1.1. Orjinal Yerel İkili Örüntü Operatörü.....  | 14              |
| 1.4.2.1.1.2. Düzgün Örüntüler .....                     | 16              |
| 1.4.2.1.1.3. Yerel İkili Örüntüler Histogramı .....     | 17              |
| 1.4.2.1.2. İyileştirilmiş Yerel İkili Örüntüler.....    | 18              |
| 1.4.2.1.3. Merkezi Simetrik Yerel İkili Örüntüler ..... | 19              |
| 1.4.2.1.4. Çok Bloklı Yerel İkili Örüntüler.....        | 20              |
| 1.4.3. Hibrit Yaklaşımlar .....                         | 21              |
| 1.5. Temel Bileşen Analizi .....                        | 22              |
| 1.5.1. Temel Bileşen Analizine Giriş.....               | 22              |
| 1.5.1.1. Varyans.....                                   | 23              |

|            |                                                                   |    |
|------------|-------------------------------------------------------------------|----|
| 1.5.1.2.   | Kovaryans .....                                                   | 24 |
| 1.5.2.     | Temel Bileşen Analizinin Amacı .....                              | 25 |
| 1.5.3.     | Temel Bileşenlerin Seçilmesi .....                                | 28 |
| 1.5.4.     | Özyüz Yöntemi .....                                               | 31 |
| 1.5.4.1.   | Özyüzlerin Hesaplanması .....                                     | 32 |
| 1.6.       | Doğrusal Ayırıştırma Analizi .....                                | 37 |
| 1.6.1.     | Fisheryüzlerin Hesaplanması .....                                 | 38 |
| 1.7.       | Alt Uzay Doğrusal Ayırıştırıcı Analizi .....                      | 41 |
| 1.7.1.     | Alt uzay DAA' nın Uygulanması .....                               | 41 |
| 1.8.       | Sınıflandırma .....                                               | 41 |
| 1.9.       | Sınıflandırma Performansının Değerlendirilmesi .....              | 43 |
| 1.9.1.     | Tanısal Meta-Analiz .....                                         | 43 |
| 2.         | YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME .....                    | 47 |
| 2.1.       | Sistemin Yapısı ve Aşamaları .....                                | 47 |
| 2.1.1.     | Ön İşlemler .....                                                 | 48 |
| 2.1.1.1.   | Gri Seviyeye Dönüştürme .....                                     | 49 |
| 2.1.1.2.   | Görüntü Döndürme .....                                            | 49 |
| 2.1.1.3.   | Görüntü Kesme .....                                               | 50 |
| 2.1.1.4.   | Histogram Eşitleme .....                                          | 51 |
| 2.1.2      | Öznitelik Çıkarımı .....                                          | 52 |
| 2.1.2.1    | Yerel İkili Örüntüler .....                                       | 52 |
| 2.1.2.1.1. | İyileştirilmiş Yerel İkili Örüntüler .....                        | 57 |
| 2.1.2.1.2. | Merkezi Simetrik Yerel İkili Örüntüler .....                      | 57 |
| 2.1.2.1.3. | YİÖ ile Elde Edilen Özelliklerin Sınıflandırılması .....          | 58 |
| 2.1.2.2.   | Temel Bileşen Analizi .....                                       | 59 |
| 2.1.2.2.3. | TBA ile Elde Edilen Özelliklerin Sınıflandırılması .....          | 67 |
| 2.1.2.3.   | Doğrusal Ayırıştırıcı Analizi .....                               | 68 |
| 2.1.2.3.1. | DAA ile Elde Edilen Özelliklerin Sınıflandırılması .....          | 73 |
| 2.1.2.4.   | Alt Uzay Doğrusal Ayırıştırıcı Analizi .....                      | 74 |
| 2.1.2.4.1. | Alt uzay DAA ile Elde Edilen Özelliklerin Sınıflandırılması ..... | 75 |
| 2.1.3.     | Test Aşaması Sonuçları ve Karşılaştırmalar .....                  | 76 |
| 2.1.3.1.   | Farklı YİÖ ve İYİÖ Operatörlerinin Kullanılması .....             | 76 |
| 2.1.3.2.   | MSYİÖ' de Eşik Değerinin Belirlenmesi .....                       | 78 |

|          |                                                                           |    |
|----------|---------------------------------------------------------------------------|----|
| 2.1.3.3. | Chi karesinde Ağırlık Matrisinin Seçimi .....                             | 79 |
| 2.1.3.4. | Farklı Sayıdaki Özvektörlerin Kullanımı .....                             | 82 |
| 2.1.3.5. | TBA’ da Temel Bileşenlerin Seçilmesi .....                                | 83 |
| 2.1.3.6. | Ön İşlemler .....                                                         | 83 |
| 2.1.3.7. | Farklı Boyuttaki Görüntülere DAA Uygulanması.....                         | 84 |
| 2.1.3.8. | Hastalıkları Göre Sınıflandırıcı Performanslarının Değerlendirilmesi..... | 85 |
| 2.1.3.9. | Ön Tanı Programı Sonuçları.....                                           | 89 |
| 3.       | SONUÇLAR VE ÖNERİLER.....                                                 | 95 |
| 4.       | KAYNAKLAR .....                                                           | 98 |
| ÖZGEÇMİŞ |                                                                           |    |

Yüksek Lisans Tezi

ÖZET

## YÜZ GÖRÜNTÜLERİNDEN HASTALIKLARIN ÖN TANISI

Beste GENÇTÜRK

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı  
Danışman: Prof. Dr. Vasıf V. NABİYEYEV  
2013, 105 Sayfa

Ön tanı, hekim tecrübesine bağlı olarak değiştiğinden, hastalar gerekli gereksiz bir sürü teste tabi tutulmakta, bu durum hastayı hem psikolojik hem de maddi açıdan yormaktadır. Tıbbi testler sonucunda en doğru teşhisin konulacağı kesindir, ancak ön tanı doğruluğu teşhis sürecini önemli ölçüde hızlandırmaktadır. Bundan ötürü günümüzde ön tanının hekimden hekime değişmediği, maliyeti düşük, otomatik ön tanı sistemlerine ihtiyaç duyulmaktadır. Bu amaçla tez kapsamında, yüzden hastalık teşhisi yaparak, cinsiyetten, yaştan ve yüz ifadelerinden bağımsız otomatik ön tanı programı gerçekleştirilmiştir.

Çalışma, veri tabanının oluşturulması, ön işlemler, özellik çıkarımı ve sınıflandırma olmak üzere dört kısımdan oluşmaktadır. Eğitim veritabanı Akromegali, Down sendromu, Lupus, sağlam ve bu sınıfların dışındaki hastalık ve farklı görüntüleri içeren diğer bir sınıf olmak üzere beş sınıf içermektedir. Ön işlemler aşamasında, eğitim ve test görüntülerine çeşitli ön işlemler uygulanarak, görüntüler aynı formata getirilmiş ve sistem performansı artırılmıştır. Özellik çıkarımında karşılaştırmalı olarak bütünsel yaklaşımlar incelenmiştir. Giriş görüntüsünü sınıflandırmada temel yöntemler kullanılmıştır. En son kısımda da sınıflandırıcı sonuçlarına Borda Sayısı yöntemi uygulanarak ön tanı performansı artırılmıştır.

Önerilen ön tanı sistemi %95 oranında tanıma performansı göstermiştir.

**Anahtar Kelimeler:** Akromegali, Down sendromu, Lupus, Özellik Çıkarımı, Sınıflandırma, Tanısal Testler, Borda Sayısı

Master Thesis

SUMMARY

THE PRE-DIAGNOSIS OF DISEASES FROM FACIAL IMAGES

Beste GENÇTÜRK

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Computer Engineering Graduate Program  
Supervisor: Assoc. Prof. Dr. Vasıf V. NABİYEV  
2013, 105 Pages

Pre-diagnosis varies depending on the experience of the physician. Therefore, patients are subjected to a lot of test required or unnecessary and it strains the patient in terms of finance and psychology. The most accurate diagnosis will be placed as a result of certain medical tests, but the success of pre-diagnosis accelerates the process of diagnosing. Hence pre-diagnosis system with low-cost, automatically, not changeable from one physician to another is needed. For this purpose in this study automatic pre-diagnosis program is developed by diagnosing the disease from face photos that is independent from sex, age and facial expressions.

This study consists of four parts: creating databases, pre-processing, feature extraction and classification. Training database includes five image classes these are Acromegaly, Down syndrome, Lupus, Normal and other disease or non-face. Various pre-processing techniques applied on the training and test database images in the pre-processing stage, so images turned into same format and system performance improved. In the feature extraction, holistic approaches is studied comparatively. Basic approaches are used to classify the input image. In the last stage pre-diagnosis performance increased by applying the Borda Count method to the classifier results.

Our proposed pre-diagnosis system shows %95 recognition performance.

**Key Words:** Acromegaly, Down syndrome, Lupus, Feature Extraction, Local Patterns, Subspace-based methods, Classification, Diagnostic Tests, Borda Count

## ŞEKİLLER DİZİNİ

### Sayfa No

|             |                                                                                                           |    |
|-------------|-----------------------------------------------------------------------------------------------------------|----|
| Şekil 1.1.  | Hastalıklı yüzler.....                                                                                    | 2  |
| Şekil 1.2.  | Sistemin genel akış şeması.....                                                                           | 8  |
| Şekil 1.3.  | Yüzün geometrik özellikler.....                                                                           | 9  |
| Şekil 1.4.  | Graflarla gösterilmiş yüz görüntüleri.....                                                                | 10 |
| Şekil 1.5.  | Elastik deste graf.....                                                                                   | 11 |
| Şekil 1.6.  | DDA, TBA+DAA ve TBA izdüşümleri.....                                                                      | 12 |
| Şekil 1.7.  | Farklı aydınlatma koşullarındaki görüntülerin aynı YİÖ kodları.....                                       | 13 |
| Şekil 1.8.  | YİÖ operatörleri.....                                                                                     | 15 |
| Şekil 1.9.  | YİÖ(8,1) in hesaplanması.....                                                                             | 15 |
| Şekil 1.10. | İYİÖ(8,1) kodunun hesaplanması.....                                                                       | 19 |
| Şekil 1.11. | YİÖ ve MSYİÖ' nün ikili kod oluşumları ve komşulukları.....                                               | 20 |
| Şekil 1.12. | ÇBYİÖ kodunun hesaplanması.....                                                                           | 21 |
| Şekil 1.13. | TBA' nın belirlediği yeni eksenler.....                                                                   | 23 |
| Şekil 1.14. | Temel Bileşenlere bağlı olarak özdeğerlerin davranışı.....                                                | 30 |
| Şekil 1.15. | Yüz görüntüleri arasındaki varyasyon.....                                                                 | 31 |
| Şekil 1.16. | Yüz görüntüsünden yüz vektörü oluşturma.....                                                              | 32 |
| Şekil 1.17. | Kovaryans matrisinin özvektörlerine karşılık gelen Özyüzler.....                                          | 35 |
| Şekil 1.18. | Alt uzaya yansıma.....                                                                                    | 37 |
| Şekil 1.19. | İkili tanı testi grafiği.....                                                                             | 45 |
| Şekil 2.1.  | Sistemin temel işlem adımları.....                                                                        | 48 |
| Şekil 2.2.  | Ön işlem aşamaları.....                                                                                   | 48 |
| Şekil 2.3.  | Görüntüyü döndürme.....                                                                                   | 50 |
| Şekil 2.4.  | Görüntü kesme.....                                                                                        | 50 |
| Şekil 2.5.  | (a) Akromegali görüntüsü (b) görüntü histogramı (c) histogram eşitlemeden sonraki görüntü histogramı..... | 51 |
| Şekil 2.6.  | Down sendromlu örnekler üzerinde ön işlem adımları.....                                                   | 52 |
| Şekil 2.7.  | YİÖ 'le özellik çıkarımı.....                                                                             | 53 |
| Şekil 2.8.  | Görüntülerin YİÖ kodları.....                                                                             | 54 |

|             |                                                                                                    |    |
|-------------|----------------------------------------------------------------------------------------------------|----|
| Şekil 2.9.  | Görüntülerin düzenli YİÖ histogramları.....                                                        | 55 |
| Şekil 2.10. | 10*10' luk alt bölgeye ayrılmış 126*147 boyutundaki görüntü.....                                   | 56 |
| Şekil 2.11. | Bölgesel YİÖ histogramlarının çıkarılması ve birleştirilmesi.....                                  | 56 |
| Şekil 2.12. | Alt bölgelere ayrılmış ve ağırlıklandırılmış görüntü.....                                          | 58 |
| Şekil 2.13. | Sınıflandırma sonuçları.....                                                                       | 59 |
| Şekil 2.14. | TBA eğitim algoritması aşamaları.....                                                              | 60 |
| Şekil 2.15. | Eğitim matrisinin oluşturulması.....                                                               | 60 |
| Şekil 2.16. | Ortalama yüz.....                                                                                  | 61 |
| Şekil 2.17. | Eğitim görüntüsünden ortalama yüzün çıkarılması.....                                               | 61 |
| Şekil 2.18. | Özyüzler.....                                                                                      | 62 |
| Şekil 2.19. | Döküntü grafiği.....                                                                               | 63 |
| Şekil 2.20. | Döküntü grafiği ile seçilen özyüzler.....                                                          | 63 |
| Şekil 2.21. | Görüntünün özyüz uzayına izdüşümü.....                                                             | 64 |
| Şekil 2.22. | TBA' dan geri dönüşüm işlemi ile A'nın elde edilmesi.....                                          | 65 |
| Şekil 2.23. | Orjinal görüntünün elde edilmesi.....                                                              | 66 |
| Şekil 2.24. | Farklı sayılardaki temel bileşenle oluşturulan görüntüler.....                                     | 66 |
| Şekil 2.25. | Eşleşen test-eğitim görüntüleri.....                                                               | 67 |
| Şekil 2.26. | DAA eğitim algoritması aşamaları.....                                                              | 68 |
| Şekil 2.27. | Eğitim matrisinin oluşturulması.....                                                               | 69 |
| Şekil 2.28. | (a) Akromegali (b) Down sendrom (c) Lupus (d) Sağlam(e) Diğer sınıf ortalama yüzü $\mu_{ci}$ ..... | 69 |
| Şekil 2.29. | Ortalama yüzlerden ortalamanın çıkarılması.....                                                    | 71 |
| Şekil 2.30. | Sıralı ilk 12 Fisheryüz.....                                                                       | 72 |
| Şekil 2.31. | Görüntünün Fisheryüz uzayına izdüşümü.....                                                         | 73 |
| Şekil 2.32. | DAA ile sınıflandırma sonuçları.....                                                               | 74 |
| Şekil 2.33. | Alt uzay Doğrusal Ayrıştırıcı Analizi.....                                                         | 75 |
| Şekil 2.34. | Alt uzay DAA ile sınıflandırma sonuçları.....                                                      | 76 |
| Şekil 2.35. | Farklı YİÖ operatörlerin sınıflandırıcılara göre tanıma oranları.....                              | 77 |
| Şekil 2.36. | Farklı İYİÖ operatörlerin sınıflandırıcılara göre tanıma oranları.....                             | 77 |
| Şekil 2.37. | MSYİÖ(8,1) için T değerine göre sınıflandırıcıların doğruluk değerleri.....                        | 78 |
| Şekil 2.38. | MSYİÖ(8,2) için T değerine göre sınıflandırıcıların doğruluk değerleri.....                        | 79 |

|             |                                                                        |    |
|-------------|------------------------------------------------------------------------|----|
| Şekil 2.39. | Kullanılan 7x7' lik maskeler.....                                      | 80 |
| Şekil 2.40. | Kullanılan 10x10' luk maskeler.....                                    | 81 |
| Şekil 2.41. | Farklı sayıdaki özvektörlerin tanıma performansına etkisi.....         | 82 |
| Şekil 2.42. | Ön tanı programı test sonuçları.....                                   | 90 |
| Şekil 2.43. | Test görüntüsünün ön tanı sonuçları 1.....                             | 91 |
| Şekil 2.44. | (a)(b)(c)Test görüntülerinin ön tanı sonuçları 2.....                  | 92 |
| Şekil 2.45. | (a)(b)(c)Yanlış bulunan test görüntüleri.....                          | 93 |
| Şekil 2.46. | Yanlış bulunan test görüntülerinin Borda sayısı yöntemi sonuçları..... | 94 |

## TABLÖLAR DİZİNİ

|                                                                                                                                                 | <b><u>Sayfa No</u></b> |
|-------------------------------------------------------------------------------------------------------------------------------------------------|------------------------|
| Tablo 1.1. Düzgün ve düzgün olmayan örüntülere örnekler.....                                                                                    | 16                     |
| Tablo 1.2. Düzgün YİÖ örüntülerinin etiketleri ve histogram bölmeleri.....                                                                      | 17                     |
| Tablo 1.3. İkili tanı testi durumları.....                                                                                                      | 44                     |
| Tablo 2.1. Maskelere göre sınıflandırıcıların doğruluk değerleri.....                                                                           | 81                     |
| Tablo 2.2. Temel Bileşen seçimi yöntemlerinin tanıma yüzdesi.....                                                                               | 83                     |
| Tablo 2.3. Histogram eşitlemenin başarı oranına etkisi.....                                                                                     | 84                     |
| Tablo 2.4. DAA için farklı görüntü boyutlarındaki tanıma oranı.....                                                                             | 84                     |
| Tablo 2.5. Akromegali teşhisinde YİÖ(8,1), YİÖ(8,2) ve YİÖ(16,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri.....    | 85                     |
| Tablo 2.6. Akromegali teşhisinde İYİÖ(8,1), İYİÖ(8,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri.....               | 85                     |
| Tablo 2.7. Akromegali teşhisinde TBA, DAA ve Alt uzay DAA kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri.....           | 86                     |
| Tablo 2.8. Down sendromu teşhisinde YİÖ(8,1), YİÖ(8,2) ve YİÖ(16,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri..... | 86                     |
| Tablo 2.9. Down sendromu teşhisinde İYİÖ(8,1), İYİÖ(8,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri.....            | 87                     |
| Tablo 2.10. Down sendromu teşhisinde TBA, DAA ve Alt uzay DAA kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri.....       | 87                     |
| Tablo 2.11. Lupus teşhisinde YİÖ(8,1), YİÖ(8,2) ve YİÖ(16,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri.....        | 87                     |
| Tablo 2.12. Lupus teşhisinde İYİÖ(8,1) ve İYİÖ(8,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri.....                 | 88                     |
| Tablo 2.13. Lupus teşhisinde TBA, DAA ve Alt uzay DAA kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri.....               | 88                     |
| Tablo 2.14. Yöntemler ve Doğruluk değerleri.....                                                                                                | 89                     |

## SEMBOLLER DİZİNİ

|          |                                        |
|----------|----------------------------------------|
| SLE      | Sistemik Lupus Eritematozus            |
| DLA      | Dinamik Link Mimarisi                  |
| EBGM     | Elastik Deste Graf Eşleme              |
| TBA      | Temel Bileşen Analizi                  |
| FAA      | Fisher Ayırıştırma Analizi             |
| DAA      | Doğrusal Ayırıştırıcı Analizi          |
| BBA      | Bağımsız Bileşen Analizi               |
| ÇTBA     | Çekirdek Temel Bileşen Analizi         |
| YİÖ      | Yerel İkili Örüntüler                  |
| ASM      | Aktif Şekil Modelleri                  |
| AAM      | Aktif Görünüm Modelleri                |
| İYİÖ     | İyileştirilmiş Yerel İkili Örnekler    |
| MSYİÖ    | Merkezi Simetrik Yerel İkili Örüntüler |
| ÇBYİÖ    | Çok Bloklı Yerel İkili Örüntüler       |
| Alt uzay | Alt Uzay Doğrusal Ayırıştırıcı Analizi |
| DAA      |                                        |
| NN       | En yakın komşu                         |
| NM       | En yakın ortalama                      |

## 1. GENEL BİLGİLER

### 1.1. Giriş

Hastalık teşhisi sürecinde, hasta birtakım test ve ölçümlerden geçirilmektedir. Uzmanlar, bu testlere başvurmadan önce, hastanın dış görünüşüne bakarak ön tanı koymaktadırlar. Bu amaçla referans kitaplarda bulunan ve daha önce kesin tanısı konulmuş hastalara ait özelliklerin karşılaştırılmasıyla tanı sağlayan bir yöntem kullanılmaktadır [1]. Karşılaştırma yapılarak uygulanan yöntemde uzman hekimin daha önceden karşılaştığı vakalardan elde ettiği tecrübeye göre tanı koyulmaktadır. Tanı, hekim tecrübesine bağlı olarak değiştiğinden, yöntem öznel bir yöntem olarak düşünülmektedir. Bu nedenle günümüzde özneliği ortadan kaldıran, yani ön tanının hekimden hekime değişmediği, maliyeti düşük, otomatik ön tanı sistemlerine ihtiyaç duyulmaktadır.

Ön tanıda hastalık belirtilerinin vücutta fiziksel olarak açığa çıkması, ön tanı sürecini hızlandırıp kolaylaştırmaktadır. Özellikle de belirtilerin yüz bölgesinde görüldüğü hastalıklarda ön tanı, fiziksel belirti vermeyen hastalıklara göre oldukça kolaydır. Bununla birlikte belirtileri yüz bölgesinde görülen hastalıkların çok çeşitli ve bu yüzlerden bazılarının sağlam yüzlere benzer olması, tanıyı bir o kadar da zorlaştırmaktadır.

Yüzden teşhis edilebilecek hastalıklı yüzlere örnek olarak, Hipokrat yüzü, Parkinson yüzü, Akromegali yüzü, Lupus yüzü, Lepra yüzü, Adenoid yüzü, Down sendromu yüzü gibi birçok yüz örneği verilebilir. Bu yüzlerden:

- Hipokrat yüzü; malign hastalıklar ve hastalıkların ileri dönemlerinde görülen, yanakların çöktüğü ve burun yapısının ileri derecede belli olduğu yüz şeklidir (pankreas kanseri).

- Parkinson yüzü; yüzün donuk hal alması ile oluşan yüz şeklidir.

- Akromegali yüzü; kaş kemerleri, burun, ağız, yanak kemikleri ve alt çene büyümesiyle oluşan yüz şeklidir.

- Lupus yüzü; yüzün hem kelebek tarzında kırmızı renk aldığı, hem de derinin bir miktar kabarıklık gösterdiği yüz şeklidir.

- Lepra yüzü; yüzün üzerinde çeşitli büyüklüklerde nodüler lezyonların görülmesi ile oluşan yüz şeklidir. Bir diğer adıyla aslan yüzüdür.

- Adenoid yüzü; küçük çocuklarda farenksteki adenoid doku hipertrofisine bağlı olarak ağzın açık ve çenenin düşük olduğu yüz şeklidir.

- Down sendromu yüzü; yüzde, burun kökü yassı, kulaklar kafada normalden düşük bir seviyede duran ve gözlerin birbirinden ayrı ve çekik görüldüğü yüz şeklidir [2].

Şekil 1' de bu hastalıklı yüzlere örnekler verilmektedir.



Şekil 1.1. Hastalıklı yüzler

Çalışmada kişinin yüz görüntüsünden otomatik ön tanı koyabilen bir sistem gerçekleştirilmiştir. Literatürde yüzden hastalık teşhisi konusunda sınırlı sayıda çalışma olmakla birlikte var olan çalışmalar tek bir hastalığın tanınmasına yöneliktir. Harald J. Schneider, Robert P. Kosilek, Manuel Günther, Josefine Roemmler, Günter K. Stalla, Caroline Sievers, Martin Reincke, Jochen Schopohl ve Rolf P. Würtz, otomatik yüz sınıflandırması yaparak Akromegali hastalığını teşhis etmeye yönelik çalışmışlardır [3]. Bu çalışmada

Akromegali derecesine göre gruplandıkları hastaların ön ve yan yüz görüntülerini alarak, gabor ve geometrik fonksiyonlara dayalı benzerlik analizi yapmışlardır. Yine Ralph E. Miller, Erik G. Learned-Miller, Peter Trainer, Angela Paisley ve Volker Blanz, iki boyutlu yüz görüntülerini üç boyuta dönüştürmüş, ikili sınıflandırma ile Akromegali tanısı üzerine çalışmışlardır [4]. Yüz görüntüsünden tanınan hastalıklarla ilgili Akromegali dışında Kurt Burçin, Nabiye V. Vasif, Yerel İkili Örüntüler ile Down sendromu tanıma amaçlı bir çalışma yapmıştır [5]. Down sendromu tanıma amaçlı yapılan çalışmada yüz görüntülerinin özellikleri Yerel İkili Örüntüler (8,1) operatörü ile çıkarılıp Öklit ve ağırlıklandırılmış Manhattan uzaklıklarına göre sınıflandırma yapılmıştır. Down sendromu dışında çeşitli sendromlar için de yapılan birkaç çalışma mevcuttur [6, 7]. Sistemik Lupus Eritematozusu ve birden çok hastalığı tanıma üzerine literatürde yapılan bir çalışma bulunmamaktadır.

Yüzden otomatik ön tanı koyabilme amaçlı geliştirilen bu çalışmada, ilk olarak sistemde tanımlı hastalıklarla ilgili bilgilendirme verildikten sonra, çalışmanın genel yapısı ve amacı verilmekte, daha sonra özellik çıkarımdan bahsedilmekte, ardından giriş görüntüsünün sınıflandırılması ve en son kısımda yapılan çalışmalar ve sonuçlar yer almaktadır.

## **1.2. Yüzden Teşhis Edilen Hastalıklar**

Çalışmada ön tanı amaçlı hastaların yüz görüntüleri değerlendirilerek, en tipik yüzlerden olan Akromegali, Down sendromu, Lupus yüzleri teşhis edilmeye çalışılmıştır.

### **1.2.1. Akromegali**

Akromegali, büyüme hormonunun aşırı miktarda salgılanması sonucu gelişen bir hastalıktır. Akromegali oluşumuna, hipofiz ön lobunun aşırı ölçüde çalışmasıyla birlikte büyüme hormonu yapımının ileri derecede artması yol açmaktadır. Büyüme hormonunun artması sonucu kemik, bağ ve kas dokularında, iç organlar ve damarlarda genişleme görülmektedir. Yıllarca klinik belirtiler, hipofizde gelişen bir adenomun yol açtığı büyüme hormonu fazlalığına bağlanarak açıklanmıştır. Fakat çok az olguda yalnızca hipofiz bezinde hücre artışına (hiperplazi) bağlı aşırı çalışma söz konusudur [8]. Hastalığın tedavisinde

tümörün çıkarılması ile klinik iyileşme çoğu zaman sağlanmaktadır. Fakat cerrahi girişimden sonra tümörün yeniden gelişme riski tartışılabilir. Cerrahi girişime ilişkin tartışılabilir bir başka konu da tümörün, sinir uçları arasında iletişimi sağlayan maddelerle ilgili bozukluklardan ya da GHRF' nin (Growth Hormone Releasing Factor hipotalamustan salgılanan ve hipofiz bezinden büyüme hormonunu serbestleştiren etken) salgısını düzenleyen hipotalamus içi süreçlerdeki değişikliklerden kaynaklandığı görüşüdür. Hipotalamus kaynaklı nedenleri devre dışı bırakan etmenler ise bazı hastalarda büyüme hormonu salgısının bütünüyle otonom olmaması (kan şekerinin yükselmesiyle bastırılması, düşmesiyle uyarılması) ve sinir uçları arasındaki iletişimi sağlayan maddelerin benzerlerinin, akromegalili hastalarda büyüme hormonu düzeyinin başarılı bir şekilde düşürülebilmesidir. Diğer bir yandan ilaç tedavisinde başarı elde edilemeyen hastalarda tümörün çıkarılmasından sonra gözlenen iyileşme, nedenin daha çok hipofiz düzeyinde olduğunu desteklemektedir. Bu iki yaklaşım birlikte değerlendirildiğinde; İlk aşamada hipotalamus içi süreçlerdeki değişim, daha sonra ise tümörün kendi başına hormon salgılaması hastalığın oluşumunu açıklamaktadır [8].

Akromegali çok seyrek görülebilen bir hastalıktır. Hastalığın 10 binde bir kişide görüldüğü ifade edilmektedir. Dünyada yapılan bir incelemede hastalık başladığından teşhis konulana kadar geçen sürenin ortalama 7 yıl olduğu bildirilmiştir [9]. Hastalığın önemli bir özelliği de vücutta bütün sistemleri etkilemesidir. Hastalık başta kalp damar sistemi olmak üzere bütün sistemleri etkileyerek kalp damar hastalıklarına yol açmakta, uzun süre tedavi edilmeyen vakalar ise kanserle sonuçlanmaktadır.

Büyüme hormonu fazlalığı Akromegali hastalarına tipik bir görüntü kazandırarak vücutta, ellerde, ayaklarda, çenede, burunda büyümelere yol açmaktadır. Hastalardan elde edilen en önemli tespit hastanın yüzündeki tipik görünümüdür. Yüz kemiklerinde, burun ve kulaklarda büyüme olur. Çene ve alın kemiklerindeki abartılı büyüme nedeniyle yüz genişler ve kabalaşır. Dil ve dudak büyür.

Akromegali tanısı klinik ve biyokimyasal testler sonucunda konulmaktadır. Akromegaliden şüphelenildiği zaman serum IGF-1 (İnsülin Benzeri Büyüme Faktörü) değerinin ölçümü ilk olarak yapılmaktadır. IGF-1 değerleri de yaş ve cinsiyet göz önüne alınarak değerlendirilir ve daha sonra hastaya glukozun oral olarak verilip, büyüme hormonu değerlerinin belirli aralıklarda alınması ile GH (Büyüme Hormonu) değerleri ölçülmektedir. GH supresyonunun olmaması sadece akromegali için spesifik olmayıp başka hastalıklarda da

görülebilmektedir. Bu nedenle akromegali tanısı için OGTT sonuçları yanında mutlaka klinik bulgular ve serum IGF-1 değerleri de göz önüne alınmalıdır. Klinik bulgular akromegaliyi desteklediğinde ise hipofiz görüntülemesi için MR istenmektedir.

### 1.2.2. Down Sendromu

İnsanlarda en çok görülen kromozom anomalisi türü Down Sendromudur. Trizomi 21 ya da mongolizm olarak da adlandırılan Down sendromu, vücut hücrelerindeki kromozom sayısının anormalliği sonucunda meydana gelen, bir hastalıktan daha çok genetik bir anormalliktir.

Down sendromlu insanlar yüzyıllardır gerek sanatta gerekse de edebiyatta tasvir edilmiş ve kullanılmıştır. 19. yüzyılda İngiliz doktor John Langdon Down, Down Sendromlu insanlar için, ayrıntılı bir tanımlamayı içeren akademik çalışmasıyla bu sendromun babası olarak tanınmış ve daha sonraları hastalık onun adı ile anılmaya başlanmıştır. Down' dan önce de bazı bilim adamları bu sendromun karakteristikleri hakkında çalışmalar yaptılarsa da ilk kez Down bu sendromun kesin tanımlarını ve farklılıklarını ortaya koyan kişi olmuştur [10].

İnsan vücut hücrelerinin çekirdeklerinde 23 çift, toplam 46 kromozom bulunmaktadır. Down sendromlu hastalarda ise 21 numaralı kromozomda bir çift yerine üç kromozom bulunması toplam kromozom sayısını 47 yapmaktadır. Down sendromlu çocuklarda farklılık olmasının nedeni bu fazlalık kromozomdur. Fakat bu farklılığa neden olan faktörün henüz ne olduğu bilinmemektedir [11]. Bu şekilde bir kromozom anormallitesine sahip olan anne karnındaki bebek genellikle gelişememekte ve sonuç olarak hayatını kaybetmektedir. Eğer bebek gelişebilir ve doğmayı başarabilirse Down sendromlu olarak doğmuş olmaktadır.

Down sendromlu bebekler doğduklarında farklı ve tipik bir yüz görünümüne sahip olmaktadır. Bebeğin kafası küçük, ensesi geniş ve kısa, kafatasının arka kısmı yassıdır. Ense boğum boğum bir görünüm almıştır. Boyları daha kısadır. Göz ve burun normal kişilerden daha farklı görünür. Gözler arasındaki mesafe daha fazladır ve çekik gözler vardır. Burnun kök tarafı yassıdır. Dil, normalden daha büyük ve geniştir. Bu yüzden konuşmayı engeller. Kulaklar, olması gereken yerden daha aşağıdadır.

Bu bebeklerin avuç içlerinde simian çizgisi denilen tek bir çizgi vardır. Parmaklar içe doğru bükük durur ve şiştir. Normal boyutlarından daha kısadır. Fakat eller daha geniştir.

Down sendromlu çocukların diğer çocuklara göre zeka seviyeleri daha düşüktür ve gelişimleri daha yavaştır. Küçük yaşlarda kalp problemleri, solunum yolu hastalıkları oldukça fazla görüldüğü için ölüm oranları yüksektir. 18-20 yaşa ulaşmaları zor olmakla birlikte eğer iyi bakılırlarsa bu yaşlara ulaşabilmektedirler [11].

En sık rastlanan kromozom bozukluğu olan Down sendromunun ortaya çıkmasında annenin yaşı çok büyük etken oluşturmaktadır. Canlı doğumlarda görülme sıklığı 1/850' dir. Bu sıklık 20 li yaşlarda 1/1500 iken, 45 yaşında 1/28' e kadar yükselmektedir. Anne rahmindeki bebekte Down sendromu olma riski anne yaşıyla birlikte artmaktadır. Risk altındaki belirli yaş üstü annelere Down sendromu teşhisi için çeşitli tarama testleri önerilmektedir [12].

Down Sendromlu çocuğun gelişiminde öncelikle destekleyici tedavi uygulanmaktadır. Bu yöntem sayesinde öğrenme daha kolaylaştırılır ve çocuk gelişimini daha erken sağlar. Fizyoterapist eşliğinde uygulanan tedavi ile çocuğun hareket kabiliyeti geliştirilmektedir. Bu programların uygulanması sırasında çocuğa şefkatle yaklaşmak oldukça faydalı olup, çocuğun gelişimini pozitif yönde etkilemektedir.

### 1.2.3. Sistemik Lupus Eritematozus

“Lupus” kelimesi, latince “kurt” anlamına gelmektedir. Bu hastalık; çeşitli bulguların yanında, yanaklarda ve burun derisinde kızarıklık (eritem) yapan bir hastalıktır. Eski zamanlarda; derinin bu görüntüsü, kurtların deriyi kemirip zarar vermesine benzetildiği için “Lupus” adı ortaya atılmıştır. Derideki kızarıklığı vurgulamak için, “eritem” sözcüğü de eklenmiş ve “Lupus Eritematozus” ifadesi ortaya çıkmıştır. Daha sonraları, bu hastalığın, iç organları da tutabildiği, yani sistemik olabileceği anlaşıncı "Sistemik Lupus Eritematozus (SLE)" ifadesi yerleşmiştir [13].

SLE cilt, eklem, böbrek, kalp zarı, akciğer zarı gibi birçok doku ve organlar dâhil neredeyse vücudumuzun tüm sistemlerini etkileyen, nedeni tanımlanamayan iltihabi bir hastalıktır [14]. SLE, vücudun savunma mekanizmasının bozulması ile birlikte vücudun kendi

hücrelerini yok etmesi sonucunda ortaya çıkan bağışıklık sistemi hastalığıdır. SLE tek bir sebebe bağlı olarak ortaya çıkmamaktadır. Hastaların bir kısmında genetik olarak yatkınlık söz konusudur. Yani bu hastaların ailesinde de SLE hastalığı görülmektedir. Bu nedenle hastalığın ortaya çıkışında en önemli etkenin genetik (kalıtsal=aileden gelen) faktörler olduğu tahmin edilmesine rağmen, genetik yatkınlığın yanı sıra, ultraviyole ışık gibi bazı çevresel faktörler ve bazı hormonal faktörler hastalığın altta yatan sebepleri olabilmektedir. Son yıllarda yapılan çalışmalarda, sebebin viral bir enfeksiyon olabileceği üzerinde de durulmaktadır [14].


Kadınlarda erkeklere göre daha sık görülüp, sıklıkla 15-40 yaş arası kadınlarda daha çok rastlanan bir hastalıktır. Hastalığın tanısının koyulması oldukça güçtür. Sıklıkla önceleri yorgunluk ve eklem iltihabı gibi genel bulgularla başlayıp, hastalık ilerlemeye başladığı zamanlardaki bulgularla tanı konulacak hale gelmektedir. Zaman zaman alevlenme ve iyileşme dönemleri ve aktif olmayan dönemlerle seyretmektedir. SLE' li hastaların yaklaşık on tanesinden dokuzunda ilk şikayet ve bulgu, artrit denilen eklem iltihabı ve artralji denilen eklem ağrısıdır. El parmak eklemleri, el bileği ve dirseklerde ve ayak bileğinde ağrı oluşmaktadır. SLE hastalığında görülen en önemli belirtiler genellikle ciltte oluşmaktadır. Güneş ışığı ile artan yüzde görülen kelebek tarzı kırmızı döküntü SLE için spesifiktir. Bu hastalarda saç dökülmesi de görülebilir. SLE hastaları ışığa karşı duyarlıdırlar, ışıktan rahatsız olurlar.

Hastalığın tedavisinde çok çeşitli ilaçlar kullanılabilenkte, bu ilaçlar anti-romatizmal ilaçlar, kortizon, kinin-kinidin ve bağışıklığı baskılayan ilaçlar olmaktadır. Cerrahi operasyonlar, enfeksiyon, doğum, düşük yapma, psikolojik baskılar hastalığı şiddetlendirmektedir. Bu dönemlerde ilaç dozları yeniden düzenlenmektedir.

### **1.3. Çalışmanın Genel Yapısı ve Amacı**

Çalışmada yüz görüntülerini değerlendirerek, yaşdan, cinsiyetten ve yüz ifadelerinden bağımsız otomatik ön tanı koyabilen etkin bir sistem gerçekleştirilmiştir. Sistemin bunun için öncelikle, test ve ölçümler sonucunda kesin tanısı konulmuş yüzler ile eğitilmesi gerekmektedir. Bu amaçla Akromegali, Down sendromu, Lupus, sağlam ve bu hastalıkların dışındaki yüzleri içeren diğer bir sınıf olmak üzere beş sınıflı bir eğitim seti oluşturulmaktadır.

Eğitim seti oluşturulduktan sonra görüntüler çeşitli ön işlemlerden geçirilmekte, ardından eğitim setindeki tüm yüz görüntülerinin özellikleri çıkarılmaktadır. Test görüntüsü için de aynı işlemler uygulanmaktadır. Şekil 1.2’ de test görüntüsü için sistemin genel akış şeması verilmektedir.



Şekil 1.2. Sistemin genel akış şeması

Özellik çıkarımında karşılaştırmalı olarak, yüze ait çok küçük örneklerin betimlenmesinde oldukça etkili olan, hesaplaması diğer yöntemlere göre daha az karmaşık ve hızlı bir yöntem olan Yerel İkili Örüntüler (YİÖ), İyileştirilmiş Yerel İkili Örüntüler (İYİÖ) ve Merkezi Simetrik Yerel İkili Örüntüler (MSYİÖ), Alt uzay temelli izdüşüm yöntemlerinden yüz tanıma için yaygın olarak kullanılan etkin bir karakteristik dönüşüm olan Temel Bileşen Analizi (TBA), Doğrusal Ayrıştırıcı Analizi (DAA) ve Alt uzay Doğrusal Ayrıştırıcı Analizi (Alt uzay DAA) ele alınmıştır.


Test görüntüsünün sınıflandırma için ise çeşitli uzaklık ölçütleri ve Kosinüs benzerliği kullanılarak En yakın komşu (NN) ve En yakın ortalama (NM) sınıflandırıcıları incelenmiştir.

## 1.4. Özellik Çıkarımı

Özellik çıkarımı aşaması, yüz tanıma en önemli kısımlardan bir tanesidir. Özellik çıkarımı için birçok algoritma önerilmiştir. Literatürde yüz tanıma amaçlı özellik çıkarım yöntemleri analitik (özellik tabanlı, geometrik), bütünsel (görünüm tabanlı) ve hibrit yaklaşımlar olmak üzere üç kısımda toplanmaktadır. Gabor dalgacıkları görünüm özelliklerinin, geometrik özelliklerden daha etkili olduğunu kanıtlamıştır [15].

### 1.4.1. Analitik Yaklaşımlar


Analitik yaklaşımlar, yüz görüntüleri üzerinde bazı özellik noktaları tespit ederek ve bu özellik noktaları arasındaki mesafeler ya da açılar gibi değişmeyen özellikleri kullanırlar. Bu yaklaşım, şablon ve geometrik özellik tabanlı olmak üzere iki kısma ayrılmaktadır. Şablon tabanlı yöntemde, yüz bölgeleri gözlerin, burun ve ağzın şablonlarıyla ayrı ayrı eşleştirildikten sonra bu yerel bölgelerin benzerlik ölçüleri birleştirilerek, yüz tanıma için genel bir benzerlik ölçütü elde edilmektedir. Geometrik özellik tabanlı metotta ise öncelikli olarak gözlerin burun ve ağzın yüz üzerinde yeri algılanmaktadır. Ardından tanıma için, burun genişliği ve uzunluğu, ağzın yüz üzerindeki konumu, çenenin şekli gibi özellikler bir sınıflandırıcıya giriş olarak verilmektedir. Şekil 1.3' te bu geometrik özelliklerin nasıl ölçüldüğü ve örnek olarak çene şeklinin, ağzın merkezi ve çene kenarı arasındaki uzaklık ile nasıl temsil edildiği görülmektedir.



Şekil 1.3. Yüzün geometrik özellikler [16].


Bu özellik noktaları manuel olarak seçilebileceği gibi tamamen otomatik de seçilebilmektedir. Bu metotta, yüz bölgesel olarak işlendiğinden büyük boyutlu orjinal yüz görüntüsü daha düşük boyutlu özellik vektörleri ile temsil edilebilmektedir. Böylece boyut problemi çözümlenmiş olmaktadır. Bununla birlikte yöntemin her sınıf için sadece bir yüz görüntüsü örneği olduğu durumda, tanıma performansının daha yüksek olduğu görülmüştür [17]. Yöntemin bir dezavantajı da özellik çıkarımında, görüntünün gri seviye değerleri gibi tanımda faydalı bazı bilgilerin hiç kullanılmamasından bu bilgilerin kaybolmasıdır.

Literatürde analitik yaklaşımlar kullanılarak yapılmış birçok çalışma mevcuttur. Yüz görüntülerinin temsili için Lades ve arkadaşları tarafından Dinamik Link Mimarisi (DLA) olarak adlandırılan bir graf yapısı önerilmiştir [18]. Bu sistemde, yüzü graf ile eşleyebilmek için bir elastik graf eşleştirme süreci kullanılır. Yüzler uygun graf ile temsil edildikten sonra, gabor jetleri adı verilen gabor düğümlerinden yüz tanımda kullanılmak üzere gabor özellikleri çıkarılır. Şekil 1.4' te graflarla gösterilmiş iki örnek yüz verilmektedir.



Şekil 1.4. Graflarla gösterilmiş yüz görüntüleri [19].

Daha sonra Wiskott ve arkadaşları DLA yöntemini genişleterek, seçilen özellik noktası kadar graf düğümünün yerleştirildiği Elastik Deste Graf Eşleme (EBGM) yöntemini önermişlerdir [18]. Şekil 1.5' te EBGM için graf düğümleriyle temsil edilmiş örnek bir yüz taslağı verilmektedir.



Şekil 1.5. Elastik deste graf [20].

#### 1.4.2. Bütünsel Yaklaşımlar

Bütünsel yaklaşımlar yüz görüntüsünün tamamını giriş olarak almaktadırlar. Yüz görüntüsü matrisleri görüntü vektörlerine dönüştürülmekte böylece görüntüler büyük boyutlu tek bir vektör ile temsil edilmektedir. Eğitim setindeki yüz görüntülerinin sayısına bağlı olarak bu yaklaşımda boyut problemi de ortaya çıkmaktadır. Bu nedenle bütünsel metotlarda boyut indirgenmesi için alt uzay temelli yöntemleri kullanılmaktadır. Alt uzay temelli yöntemler ile orijinal büyük boyutlu yüz uzayı, veriyi en iyi temsil edecek düşük boyutlu bir alt uzaya izdüşürülmektedir. Literatürde bütünsel yaklaşımlardan, yüz tanımda boyut indirgeme amacı ile kullanılan altuzay yöntemlerinin lineer ve lineer olmayan pek çok uygulaması vardır [21]. Bu yöntemler, Temel Bileşen Analizi, Fisher Ayırıştırma Analizi (FAA) ve türevi yöntemlerdir. Temel Bileşen Analizine dayalı yüz temsili ve yüz tanıma amaçlı kullanılan Özyüz yöntemi ilk olarak Kirby ve Sirovich tarafından geliştirilmiştir [22]. Özyüz yönteminde tüm yüz görüntüsü bir özellik vektörüne dönüştürülmekte ve eğitim seti özyüzleri hesaplamak için kullanılmaktadır. Ancak Temel Bileşen Analizinde yüz görüntüleri arasındaki toplam dağılımı maksimize eden izdüşüm yönleri seçilirken, görüntüler arasındaki aydınlatma ve ifade farklılıkları gibi istenmeyen değişimler de tutulmaktadır [23]. Bu da bu metodun, aydınlatma ve ifade farklılıkları gibi sınıf içi değişimlere karşı etkili bir yöntem olmadığını göstermektedir. Bu durumdan hareketle Doğrusal Ayırıştırıcı Analizi önerilmiştir. Doğrusal Ayırıştırıcı Analizi sınıf içi dağılımı minimize, sınıflar arası dağılımı maksimize edecek bir izdüşüm tanımlamaktadır. Bu izdüşüm ile temel bileşen analizinin sınıflandırma performansı iyileştirilmiş olmaktadır. Zhao ve arkadaşları ise Doğrusal Ayırıştırıcı Analizi uygulanmadan

önce temel bileşen analizini boyut indirgeme amaçlı uygulamayı önermiştir [24]. Şekil 1.6' da DAA, TBA+DAA ve TBA izdüşümleri görülmektedir.



Şekil 1.6. DAA, TBA+DAA ve TBA izdüşümleri [25].

Yüz tanıma için diğer bir metotta Bartlett, Movellan ve Sejnowski tarafından önerilen Bağımsız Bileşen Analizi (BBA) dir. BBA' nın lineer, ortogonal olmayan eksenlerinin doğrultusu, orjinal verideki ikinci ve daha yüksek dereceden istatistiklerle belirlenen bir koordinat sistemi belirlemektedir. Amaç istatistiksel olarak bağımsızlık sağlayan lineer bir dönüşüm sağlamaktır. Bazı uygulamalarda BBA, TBA' dan daha iyi performans göstermektedir. TBA ve BBA, danışmansız öğrenme yöntemleri olarak adlandırılabilirken; DAA, eğitim sürecinde her bir resim için sınıf bilgisine ihtiyaç duyduğundan danışmalı öğrenme yöntemi olarak adlandırılmaktadır [26]. TBA, DAA ve BBA ile yapılan çalışmaların sonuçlarına bakıldığında; bir çalışmada TBA ve DAA' nın birlikte DAA' dan daha iyi sonuç verdiği [27], bir başka çalışmada ise farklı uzaklık ölçümleri kullanılarak yapılan testlerde TBA algoritmasının DAA' dan daha iyi sonuç verdiği belirtilmektedir [28].

Son zamanlarda doğrusal olmayan veriler için çekirdek yöntemler kullanılmaktadır. TBA ya da DAA özellik uzayına uygulandığında Çekirdek Temel Bileşen Analizi (ÇTBA) ve


Genelleştirilmiş Ayırıştırıcı Analizi (GAA) adını almaktadır [29]. Çalışmalar ÇTBA ve GAA'nın doğrusal olmayan özellikleri çıkarabilmekte ve bu sayede yüz tanıma uygulamalarında yüksek performans elde edebildiklerini göstermektedir [30].

Bütünsel yaklaşımlardan bir başka yöntemde Yerel İkili Örüntülerdir. Yerel İkili Örüntüler operatörü, ilk olarak Ojala ve arkadaşları tarafından ortaya çıkarılmış ve doku tanımlayıcısı olarak önerilmiştir [31]. Daha sonra yüzleri betimlemek için de etkili bir yol olduğu görülmüştür [32, 33]. Bu yöntemde yüz görüntüsü alt bölgelere ayrıldıktan sonra her bir bölge için üretilen düzgün YİÖ histogramlarının birleştirilmesiyle, yüz için verimli bir vektörel gösterim şekli oluşturulmaktadır.

#### 1.4.2.1. Yerel Örüntüler

##### 1.4.2.1.1. Yerel İkili Örüntüler

Yerel İkili Örüntüler teorikte basit, çok güçlü ve gri seviyeden bağımsız bir doku analiz yöntemidir. YİÖ operatörünün birçok bilgisayarlı görü uygulamasında, çok başarılı bir doku tanımlayıcısı olduğu kanıtlanmıştır [36, 37, 38]. YİÖ'nün en önemli özelliklerinden birisi de ışık kaynağının şiddetindeki değişimlerden bağımsız oluşudur. Şekil 1.7' de farklı ışık şiddetindeki görüntülerin YİÖ kodlarının aynı olduğu görülmektedir.



Şekil 1.7. Farklı aydınlatma koşullarındaki görüntülerin aynı YİÖ kodları

Diğer özellik çıkarım yöntemlerine göre YİÖ operatörünün hesaplama kolaylığı da önemli bir avantajıdır.


#### 1.4.2.1.1.1. Orjinal Yerel İkili Örüntü Operatörü

İlk olarak Ojala ve arkadaşları tarafından ortaya atılan orjinal YİÖ operatörü, bir görüntünün yerel yapısını özetleyen 3x3' lük parametrik olmayan bir çekirdektir [39]. YİÖ operatörü, görüntüdeki her piksel için bir etiket değeri oluşturmaktadır. YİÖ kodu üretilecek piksel merkez piksel olarak kabul edilip, komşu pikselleri ona göre eşiklendirilerek ikili bir kod elde edilmektedir. Daha sonra bu ikili kod ilişkilendirilmiş katsayılar ile çarpılmakta ve elde edilen çarpımlar toplanarak bir piksel için YİÖ kodu üretilmiş olmaktadır. Bu ikili kodunun onlu sayıya çevrilmiş hali pikselin etiketidir. Görüntünün YİÖ kodundan çıkarılmış histogramı görüntünün özellik vektörü olarak alınmaktadır. YİÖ kodu (1.1) ve (1.2) eşitlikleriyle hesaplanmaktadır.

$$YİÖ_{P,R}(x_c, y_c) = \sum_{n=0}^{P-1} s(g_n - g_c) * 2^n \quad (1.1)$$


$$s(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases} \quad (1.2)$$

Burada  $g_c$  YİÖ kodu üretilecek  $(x_c, y_c)$  merkez pikselinin gri seviye değerini,  $g_n$  komşu piksellerin gri seviye değerlerini,  $P$  değeri  $(x_c, y_c)$ ' nin komşu sayısını,  $R$  değeri merkez pikselin komşulara olan birim uzaklığını ve  $t$  ise komşu piksel ile merkez piksel arasındaki farkı ifade etmektedir. Orjinal YİÖ operatöründe  $P=8$  ve  $R=1$ ' dir. Bu komşu sayısı Ojala ve arkadaşları tarafından farklı yarıçap uzunluklarındaki çevresel komşuluklarla genişletilmiştir [40]. Böylece farklı ölçeklerdeki baskın özellikler de yakalanmış olmaktadır. YİÖ(P,R) gösterimi, bir pikselin  $R$  uzaklıktaki  $P$  çembersel komşuluğunu ifade etmektedir. Şekil 1.8' de çeşitli YİÖ operatörlerine örnekler verilmiştir.



Şekil 1.8. YİÖ operatörleri

Şekil 1.9' da  $P=8$ ,  $R=1$  için YİÖ kodunun hesaplanışına örnek verilmektedir. Şekil 1.9' daki örüntü 00111001 iken etiket değeri 57' dir.



Şekil 1.9. YİÖ(8,1)' in hesaplanışı

Komşu sayısı ( $P$ ) arttıkça mümkün yerel örüntü sayısı da bir o kadar hızlı artmaktadır. Örneğin  $P=16$  iken  $2^{16}$  farklı YİÖ kodu oluşmakta ve dolayısıyla özellik vektörü olarak kabul edilen histogram boyutu da  $2^{16}$  olmaktadır. Özellik vektörünün büyük boyutlu olması hesaplama karmaşıklığını artırmaktadır. Bunun için Mäenpää ve arkadaşları tüm örüntüleri almak yerine düzgün örüntüler adını verdiği 0-1 yada 1-0 geçiş sayısının maksimum 2 olduğu örüntüleri önermişlerdir. Çünkü bu şekilde alınan düzgün örüntülerin, YİÖ(8,1)' de görüntünün tüm yerel örüntülerinin %90'ı, YİÖ(16,2)'de %70' i gibi büyük bir çoğunluğa

sahip olduğu görülmüştür [41]. Tablo 1.1’ de 8 komşuluk için örnek düzgün örüntüler verilmektedir.

Tablo 1.1. Düzgün ve düzgün olmayan örüntülere örnekler

| Çevresel İkili Örüntü | 0-1 veya 1-0 Geçişleri | Düzgün Örüntü |
|-----------------------|------------------------|---------------|
| 11111111              | 0                      | Evet          |
| 00001111              | 2                      | Evet          |
| 01110000              | 2                      | Evet          |
| 11001110              | 4                      | Hayır         |
| 11001001              | 4                      | Hayır         |

#### 1.4.2.1.1.2. Düzgün Örüntüler

P komşu için tanımlanacak yerel ikili örüntü sayısı  $2^P$ ’ dir. Tüm YİÖ’ nün alt kümesi olan düzgün örüntüler  $U(x)$  düzgünlük ölçütüne göre belirlenmektedir.  $U(x)$ , YİÖ kodundaki bit geçiş sayısını gösterir. Geçiş sayısı düzgün örüntüler için en fazla ikidir. Dolayısıyla  $U(X) \leq 2$  dir. Tüm düzgün örüntülerin sayısı  $P*(P-1)+2$  tanedir. Diğer örüntüler yani düzgün olmayan örüntüler için  $U(x) > 2$  olmaktadır. Düzgünlük ölçütü ve etiket değerinin hesaplanması eşitlik (1.3) ve (1.4)’ te verilmektedir.

$$U(YiÖ_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^P |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (1.3)$$

$$YiÖ_{P,R}^{u2} = \begin{cases} I(YiÖ_{P,R}(x, y)) & \text{eğer } U(YiÖ_{P,R}) \leq 2, I(z) \in [0, (P - 1) * P + 2) \\ (P - 1) * P + 3 & \text{değilse} \end{cases} \quad (1.4)$$

Burada düzgün YİÖ operatörü  $YiÖ_{P,R}^{u2}$  ile gösterilmektedir.  $u2$ , düzgünlük derecesinin en fazla 2 olabileceğini ifade etmektedir. Eğer düzgünlük derecesi  $U(x)$ , 2 den küçükse piksel  $I(z)$

fonksiyonu ile etiketlenir. Aksi taktirde  $(P - 1) * P + 3$  etiketini almaktadır. İndex fonksiyonu  $I(z)$ ,  $(P-1)*P+2$  tane index içerir ve düzgün örüntülerin her birine belirli bir index değeri verir. Örneğin 8 komşuluk için 256 farklı YİÖ kodu oluşmakta ve bunların  $(8-1)*8+2=58$  tanesi düzgün olmaktadır. Geri kalan 198 tanesi ise düzgün olmayan örüntülerdir. Düzgün olan örüntüler 0'dan 58 'e kadar etiket değeri alırken, düzgün olmayan örüntülerin hepsi tek bir etiket değeri ile etiketlenmektedir. Böylece histogram bölmesi 256' dan 59' a düşmüş olmaktadır. Tablo 1.2' de tüm düzgün YİÖ örüntülerinin etiketleri ve onlara karşılık histogram bölmeleri verilmiştir.

Tablo 1.2. Düzgün YİÖ örüntülerinin etiketleri ve histogram bölmeleri

| DüzgünEtiket<br>(Ondalık) | DüzgünEtiket<br>(İkili) | Geçiş Sayısı | YİÖ <sup>u2</sup> <sub>(8,R)</sub><br>Histogram<br>Bölmesi |
|---------------------------|-------------------------|--------------|------------------------------------------------------------|
| 0                         | 00000000                | 0            | 1                                                          |
| 1                         | 00000001                | 1            | 2                                                          |
| 2                         | 00000010                | 2            | 3                                                          |
| 3                         | 00000011                | 2            | 4                                                          |
| 4                         | 00000100                | 2            | 5                                                          |
| .                         | .                       | .            | .                                                          |
| .                         | .                       | .            | .                                                          |
| .                         | .                       | .            | .                                                          |
| 251                       | 11111011                | 2            | 54                                                         |
| 252                       | 11111100                | 2            | 55                                                         |
| 253                       | 11111101                | 2            | 56                                                         |
| 254                       | 11111110                | 2            | 57                                                         |
| 255                       | 11111111                | 0            | 58                                                         |

#### 1.4.2.1.1.3. Yerel İkili Örüntüler Histogramı

Bir yüz görüntüsü YİÖ ile tanımlanan mikro örüntülerin birleşimi olarak düşünülebilir. Tüm yüz görüntüsü için çıkarılan YİÖ histogramı, mikro örüntülerin konumlarını dikkate almaksızın sadece oluşumlarını kodlamaktadır. Bununla birlikte yüz görüntüsünün doku bilgisi yanında şekil bilgisini de değerlendirmek gerekir. Ahonen ve arkadaşları yüzün şekil bilgisini de dikkate alarak, yüz görüntüsünü m tane yerel bölgeye ayırıp, bu bölgelerin

histogramını çıkardıktan sonra elde edilen histogramları birleştirerek tek bir özellik histogramı çıkarmayı önermişlerdir [42]. Böylece YİÖ histogramı hem doku hem de şekil bilgisini kodlamış olur. YİÖ histogramı  $H(i)$ 'nin hesaplanışı eşitlik (1.5) ve (1.6)'da verilmektedir.

$$H(i) = \sum_{x,y} D(YİÖ_{P,R}^{u2}(x,y) = i) \quad i \in [0, (P-1) * P + 1] \quad (1.5)$$

$$D(t) = \begin{cases} t & \text{doğru ise} \\ 1 & \text{yanlış ise} \end{cases} \quad (1.6)$$

Histogram çıkarılırken düzgün örüntüler dikkate alındığı için  $i \in [0, 2^P-1]$  yerine  $i \in [0, (P-1)*P+1]$  aralığında alınmıştır. 8 komşuluk için  $i \in [0,57]$  arasındadır. Yüz görüntüsü  $B_1, B_2, \dots, B_m$  olmak üzere  $m$  bölgeye ayrıldıktan sonra her bir bölgenin bölgesel histogramı (1.5) ve (1.6) eşitlikleri kullanılarak çıkarılmaktadır. Ve üretilen bu bölgesel histogramlar birleştirilerek yüz görüntüsü için tek bir histogram elde edilmektedir.

Literatürde YİÖ'lerin merkez pikseline, komşuluklarına, düzgün örüntülerine, eşik değerine göre farklılık gösteren birçok çeşidi mevcuttur. İyileştirilmiş Yerel İkili Örüntüler, Merkezi Simetrik Yerel İkili Örüntüler ve Çok Bloklü Yerel İkili Örüntüler bunlar arasındadır.

#### 1.4.2.1.2. İyileştirilmiş Yerel İkili Örüntüler

Jim ve arkadaşları, YİÖ'nün bazı koşullar altında yerel yapı bilgisini göz ardı ettiğini göstermiştir [43]. Örneğin YİÖ(8,1) operatörü 511 ( $2^9-1$ ) örüntünün, merkez pikseli  $(x_c, y_c)$ 'i dâhil etmeyerek 256 tanesi alabilmektedir. Bütün bilgiyi değerlendirebilmek için, tüm pikselleri merkez pikselde dâhil olmak üzere piksellerin ortalamasıyla karşılaştıran İyileştirilmiş Yerel İkili Örüntüler (İYİÖ) önerilmiştir. YİÖ ile  $2^P$  tane farklı yerel yapı tanımlanabilirken, İYİÖ ile  $2^{P+1}-1$  tane yerel yapı tanımlanabilmektedir. İYİÖ kodunun hesaplanışı eşitlik (1.7) ve (1.8)'de verilmektedir.

$$\text{YIÖ}_{P,R} = \sum_{i=0}^{P-1} r(g_i - m) * 2^i + r(g_c - m) * 2^P \quad (1.7)$$

$$r(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad m = \frac{1}{P+1} \left( \sum_{i=0}^{P-1} g_i + g_c \right) \quad (1.8)$$

Burada m, merkez piksel ve P komşusunun ortalaması, x değeri piksel ile ortalama arasındaki farkı ifade etmektedir. Şekil 1.10’ da P=8 ve R=1 için İYİÖ(8,1) kodunun hesaplanışına örnek verilmektedir.

|    |    |     |                                                    |   |   |   |
|----|----|-----|----------------------------------------------------|---|---|---|
| 60 | 70 | 140 | Ortalamaya göre eşiklendirme<br><br>Ortalama = 101 | 0 | 0 | 1 |
| 96 | 95 | 159 |                                                    | 0 | 0 | 1 |
| 94 | 94 | 102 |                                                    | 0 | 0 | 1 |

Şekil 1.10. İYİÖ(8,1) kodunun hesaplanışı

#### 1.4.2.1.3. Merkezi Simetrik Yerel İkili Örüntüler

Merkezi Simetrik Yerel İkili Örüntüler (MSYİÖ), YİÖ’ nün bir başka çeşididir. Nesne tanıma amaçlı Marko Heikkilä tarafından önerilmiştir [44]. Bu metotta YİÖ’ de olduğu gibi her bir pikselin merkez pikselle olan farkına bakılması yerine, merkez piksele göre simetrik olan piksel çiftleri farkına bakılmaktadır. YİÖ ile çıkarılan özellik boyutu oldukça büyüktür. MSYİÖ ‘de ise simetrik çiftler alınarak özellik boyutu YİÖ’ ye göre çok küçültülmüştür. Örneğin 8 komşuluk için YİÖ 256 ( $2^8$ ) farklı kod üretirken, MSYİÖ 16 ( $2^4$ ) farklı kod üretmektedir. Şekil 1.11’ de YİÖ ve MSYİÖ’ nün ikili kod oluşumları ve komşulukları gösterilmiştir.


MSYİÖ kodunun hesaplanışı eşitlik (1.9)’ da verilmektedir. Burada T eşik değeridir. YİÖ’ de eşik değeri merkez pikseldir.

$$MSY\ddot{O}_{P,R,T}(x_c, y_c) = \sum_{i=0}^{(P/2)-1} s(g_i - g_{i+\frac{P}{2}}) * 2^i, \quad s(x) = \begin{cases} 1 & x > T \\ 0 & \text{değilse} \end{cases} \quad (1.9)$$

### İkili Örüntü

| YİÖ =               | MSYİÖ =             |
|---------------------|---------------------|
| $s(g_0 - g_c)2^0 +$ | $s(g_0 - g_4)2^0 +$ |
| $s(g_1 - g_c)2^1 +$ | $s(g_1 - g_5)2^1 +$ |
| $s(g_2 - g_c)2^2 +$ | $s(g_2 - g_6)2^2 +$ |
| $s(g_3 - g_c)2^3 +$ | $s(g_3 - g_7)2^3 +$ |
| $s(g_4 - g_c)2^4 +$ |                     |
| $s(g_5 - g_c)2^5 +$ |                     |
| $s(g_6 - g_c)2^6 +$ |                     |
| $s(g_7 - g_c)2^7$   |                     |

### Komşuluklar




Şekil 1.11. YİÖ ve MSYİÖ' nün ikili kod oluşumları ve komşulukları

#### 1.4.2.1.4. Çok Bloklü Yerel İkili Örüntüler

Çok Bloklü Yerel İkili Örüntüler (ÇBYİÖ) operatörü Zhang, Chu, Xiang, Liao ve Li tarafından önerilen YİÖ' nün bir diğer çeşididir. ÇBYİÖ, YİÖ' den daha güçlü bir operatördür. Görüntüdeki örüntülerin sadece mikro yapılarını değil makro yapılarını da kodlamaktadır. Bazı uygulamalarda özellikle de yüz tanıma uygulamalarında ÇBYİÖ' nün diğer YİÖ algoritmalarından daha üstün olduğu gösterilmiştir [45].

ÇBYİÖ kodu hesaplanırken öncelikle görüntü eşit büyüklükteki alt bölgelere ayrılmaktadır. Bölgelerin kare olmasına gerek yoktur. YİÖ' de piksellerin gri seviyeleri karşılaştırılırken, ÇBYİÖ' de alt bölgeleri oluşturan piksellerin ortalamaları karşılaştırılır. Original YİÖ' de eşik değeri merkez piksel iken, ÇBYİÖ' de eşik, merkez bölgenin ortalaması olmaktadır. Bölgelerin ortalaması toplam-alan tablosu [46] ya da integral görüntüsünden [47]

hızlı bir şekilde kolayca hesaplanabilir. Bu nedenle özellik çıkarımı çok hızlıdır. Şekil 1.12’ de ÇBYİÖ kodunun hesaplanışına örnek verilmiştir.



Şekil 1.12. ÇBYİÖ kodunun hesaplanışı

ÇBYİÖ operatörü aslında original YİÖ operatörünün genişletilmiş halidir. 3\*3 lük bölgeyi temsil eden ÇBYİÖ, original YİÖ’ e karşılık gelmiş olur. Alt bölgelerin boyutu 3\*3, 9\*9, 15\*15 olarak genişletilebilir. Uygulama türüne göre en iyi performansı veren bölge boyutu seçilmektedir.

### 1.4.3. Hibrit Yaklaşımlar

Hibrit metotlar yüz tanıma için hem bölgesel hem de bütünsel özellikleri kullanmaktadırlar. Hibrit yaklaşımla ilgili en eski çalışmalardan birisi de Pentland’ın modüler Özyüz çalışmasıdır [34]. Bu çalışmada Özyüz yöntemi, özellik tanımlaması ve kodlamasıyla genişletilerek Özözellikler olan Özgözler, Özburunlar ve Özağızlar elde edilmiştir. Deneysel sonuçlar bazı çalışmalarda Özözelliklerden Özyüze göre daha iyi performans alındığını göstermiştir.

Aktif Şekil Modelleri (ASM) ve Aktif Görünüm Modelleri (AAM) de bu yaklaşımdaki diğer yöntemlerdir [35].

## 1.5. Temel Bileşen Analizi


### 1.5.1. Temel Bileşen Analizine Giriş

Bilgisayarla görme ve örüntü tanımda yaygın şekilde kullanılan Temel Bileşen Analizi, klasik öznelitik çıkartma ve veri temsili tekniğidir [48]. Ayrıca TBA, çok değişkenli veri kümelerinin yorumlanmasında ve boyut indirgemesinde de kullanılmaktadır [49]. Karhunen-Loeve dönüşümü olarak da bilinen Temel Bileşen analizinin ilk tanımlanan uygulaması sosyal bilimler alanında olmuştur. 1904 yılında Charles Spearman Amerikan psikoloji dergisinde “Nesnel olarak tespit edilen ve ölçülebilen genel zekâ” isimli bir yayınında insanın entelektüel yeteneğini matematik, yazım, eleştirel düşünme gibi çeşitli konularla ilgili olarak incelemiştir. TBA kullanarak yaptığı analizde konu ne olursa olsun entelektüel yetenek tarafından belirlenen temel bir zekâ faktörünün olduğunu göstermiştir. Bu faktör de yaygın olarak bilinen adıyla IQ’ dur.

Sirovich ve Kirby ise ilk defa TBA’ yı insan yüzlerinin etkin temsili için kullanmışlardır [50]. TBA ile yapılan çalışmaların sonucunda, TBA büyük veri kümelerinin analizinde temel bir istatistiksel yöntem olarak kabul edilmiştir.

TBA da asıl amaç boyut indirgemektir. TBA, verilen  $M \times N$ ’ lik veri kümesi içerisindeki  $N$  nesnenin  $M$  parametresi arasındaki ilişkiyi analiz etmektedir. TBA’ daki başlıca hedef bu veri kümesini, asıl değişkenlerin doğrusal birleşimi olan ve karşılıklı ortogonal yeni değişkenler ile tekrar tanımlamaktır. Bu yeni değişkenler, çok değişkenli uzayda verinin doğal sınıflandırılmasını sağlayacak bir koordinat eksenini tanımlar. Bu tanımlama ile boyut indirgemesi gerçekleşmiş olmaktadır.

Boyut indirgeme özelliği TBA’ yı güçlü ve çok yönlü bir analiz yöntemi yapmaktadır. TBA, çok boyutlu veri içerisinden istenilen temel bileşenleri çıkarmaya dayalı bir boyut indirgeme tekniğidir. Özellikle istatistiksel analizlerin birçoğunda birbirine bağımlı çok sayıda değişken incelenmektedir. Bu durum bir yandan hesapsal karmaşıklığa yol açarken diğer bir yandan analiz sonuçlarının değerlendirilmesini güçleştirmektedir. TBA’ nın da temel çıkış noktası burasıdır. Boyut indirgeme işlemini grafiksel olarak gözlemlemek için Şekil 1.13’ deki iki boyutlu  $(x,y)$  veri kümesi üzerinde TBA’ yı inceleyelim.



Şekil 1.13. TBA' nın belirlediği yeni eksenler [51].

Şekil 1.13' den de görüldüğü üzere TBA verileri “x” ve “y” eksenleri yerine, verinin dağılımının en büyük olduğu kırmızı eksenini ile ifade etmiştir. Bu şekilde iki boyutlu veri tek boyuta da indirgenmiş olmaktadır. Mavi ekseninde kırmızı eksenin sonra veri dağılımının en büyük olduğu eksenidir.

Temel Bileşen Analizinin yüz tanıma bilinen en etkili uygulaması Turk ve Pentland tarafından ortaya konulan Özyüz yöntemidir [52]. Bu bölümde öncelikle TBA yönteminin daha kolay anlaşılabilmesi adına bazı temel kavramlar verilecek, daha sonra TBA nın amacı ve Temel bileşenlerin seçilmesine değinilecek ve ardından Özyüz yöntemine ait detaylı bilgi verilerek yöntemin nasıl uygulandığı anlatılacaktır.

#### 1.5.1.1. Varyans

Olasılık kuramı ve istatistik bilim dallarında varyans bir rassal değişken, bir olasılık dağılımı veya örneklem için istatistiksel yayılımın mümkün bütün değerlerin beklenen değer veya ortalamadan uzaklıklarının karelerinin ortalaması şeklinde bulunan bir dağılım ölçüsüdür [53]. Ortalama bir dağılımın merkezsel konum noktasını bulmaya çalışırken, varyans değerlerin ne ölçekte veya ne derecede yaygın olduklarını tanımlamayı hedef almaktadır. Varyans için ölçülme birimi orijinal değişkenin biriminin karesidir. Varyansın kare kökü

standart sapma olarak adlandırılır ve ölçme birimi orijinal değişkenle aynı birimde olup daha kolay yorumlanabilmektedir. Varyansın hesaplanışı eşitlik (1.10)' da verilmektedir.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (1.10)$$

Burada  $\sigma$  standart sapmayı yani varyansın karekökünü,  $N$  veri sayısını,  $\mu$   $N$  adet verinin ortalamasını,  $x_i$  i. verinin değerini göstermektedir.

### 1.5.1.2. Kovaryans

Olasılık teorisi ve istatistikte, kovaryans iki değişkenin birbirlerine göre değişimlerinin ölçüsüdür. Standart sapma ve varyans diğer boyutlardan bağımsız olarak yalnızca bir boyuttaki verinin ortalama değere göre dağılımı hakkında bilgi verirken, kovaryans bir boyutun diğer boyutlara bağlı olarak nasıl bir değişim gösterdiği hakkında bilgi veren bir ölçümdür. Kovaryans daima 2 boyut arasında hesaplanmaktadır. Değişkenlerden birinin değeri artarken diğerinin değeri artıyor ya da biri azalırken diğeri de azalıyorsa iki değişken arasındaki kovaryans değeri pozitif olacaktır. Değişkenlerden birinin değeri artarken diğerinin değeri azalıyor ya da birinin değeri azalırken diğerinin değeri artıyorsa kovaryans değeri negatif çıkacaktır. Eğer değişkenler arasında belirgin bir ilişki yoksa, kovaryans sıfıra yakın bir değer olmaktadır [54]. Kovaryans (1.11) eşitliğine göre hesaplanmaktadır.

$$\text{kov}(X, Y) = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{N - 1} \quad (1.11)$$

Burada  $X_i$  ve  $Y_i$  veri kümesindeki her bir verinin iki boyuttaki veri değerlerini,  $\bar{X}$  ve  $\bar{Y}$  verilerin ilgili boyutlardaki ortalamasını ifade etmektedir. Kovaryans matrisi 2 boyut arasında hesaplandığından, daha yüksek boyutlardaki veri setlerinde verilerin ikiyeşli kovaryans değeri hesaplanmaktadır. Örneğin üç boyutlu bir veri seti için  $\text{kov}(X_1, X_2)$ ,  $\text{kov}(X_1, X_3)$  ve  $\text{kov}(X_2, X_3)$  değerleri hesaplanarak kovaryans matrisi oluşturulmaktadır. Genelleştirirsek  $n$  boyutlu bir

veri seti için  $n!/(n-2)!*2$  farklı kovaryans değeri hesaplanmaktadır [55]. Kovaryans matrisi C (1.12)' de verilmektedir.

$$C^{3 \times 3} = \begin{bmatrix} \text{kov}(X1, X1) & \text{kov}(X1, X2) & \text{kov}(X1, X3) \\ \text{kov}(X2, X1) & \text{kov}(X2, X2) & \text{kov}(X2, X3) \\ \text{kov}(X3, X1) & \text{kov}(X3, X2) & \text{kov}(X3, X3) \end{bmatrix} \quad (1.12)$$

Burada köşegen üzerinde bulunan katsayılar varyans, diğerleri kovaryans katsayılarıdır.

### 1.5.2. Temel Bileşen Analizinin Amacı

TBA, orijinal (görüntü) uzayı güçlü bir şekilde indirgeyerek bir alt öz nitelik uzayı tanımlamaktadır. Bu yeni alt uzay, veri kümesi içerisindeki gereksiz bilgiyi eleyecek ve gizli yapıyı ortaya çıkaracak özelliktedir. Daha sonra orijinal uzaydaki veriler bu alt uzaya izdüşürülmektedir. Aşağıda örnek bir veri kümesinin TBA ile hedeflenen yönde dönüşümü anlatılmaktadır.

Veri kümesi X,  $m*n$  boyutlu bir matris olarak kabul edilsin. X matrisinin her bir sütunu kümeye ait örnek vektör olarak alınırsa, herbir vektör  $m$  boyutlu ve ortonormal tabanlı bir vektör uzayında olmuş olur. Ve bu vektörler birim uzunluklu taban vektörlerinin lineer kombinasyonlarını oluştururlar.

Orijinal X veri kümesi, D doğrusal dönüşümü ile  $m*n$  boyutlu Y matrisi ile temsil edilir. Bu dönüşüm işlemi  $DX=Y$  eşitliği ile ifade edilebilir. Eşitlik bir matris çarpımı olduğuna göre Y 'nin her bir sütunu  $y_i$ , X in her bir sütunu  $x_i$  ile D'nin ilgili satırının nokta çarpımı ile elde edilir ( $y_i = [d1. x_i ; \dots ; dm. x_i]$ ). Yani D matrisinin satırları  $\{d1, d2, \dots, dm\}$ , X in sütunlarını ifade etmek için kullanılan yeni taban vektörleri olmuştur ve  $y_i$ ,  $\{d1, d2, \dots, dm\}$  tabanına iz düşümdür. Dönüşümdeki  $\{d1, d2, \dots, dm\}$  satır vektörleri X' in temel bileşenleridir ve Y'nin sergileyeceği özellikleri belirlemektedirler. (1.13), (1.14) ve (1.15) eşitliklerinde anlatılan matrisler verilmektedir.

$$DX = \begin{bmatrix} d_1 \\ \vdots \\ d_m \end{bmatrix} [x_1 \quad \cdots \quad x_n] \quad (1.13)$$

$$Y = \begin{bmatrix} d_1 \cdot x_1 & \cdots & d_1 \cdot x_n \\ \vdots & \ddots & \vdots \\ d_m \cdot x_1 & \cdots & d_m \cdot x_n \end{bmatrix} \quad (1.14)$$

$$y_i = \begin{bmatrix} d_1 \cdot x_i \\ \vdots \\ d_m \cdot x_i \end{bmatrix} \quad (1.15)$$

TBA' nın amacı orjinal veri kümesi  $X'$  deki fazla gereksiz bilgiyi kaldırmak yani örnekdeki her bir bileşeni birbirinden bağımsız yapmaktır. Bileşenlerin birbirinden bağımsız olması için  $X'$  in kovaryans matrisi,  $\text{kov}(X)$ , köşegen (diagonal) hale getirilmelidir. Dolayısıyla, yeni bileşenlerin ( $Y$ ) kovaryans matrisi köşegen olmalıdır.

Kovaryans matrisinin köşegen olması, bir bileşenin kendisi ile hesaplanan varyansının en büyük değeri, diğer bileşenlerle hesaplanan kovaryansının sıfır değeri (ilişki yoksa kovaryans değeri sıfırdır) alacağı anlamına gelir [55]. Yani  $X'$  in dönüştürülmüş hali olan  $Y$ 'nin kovaryans matrisinin,  $\text{kov}(Y)$ , (1.16) eşitliğinde görüldüğü gibi köşegen halde olması amaçlanmaktadır.

$$\text{kov}(Y) = Y * Y^T = \begin{bmatrix} \sigma_{11} & 0 & \cdots & 0 \\ 0 & \sigma_{22} & \cdots & 0 \\ \cdots & \cdots & \cdots & \cdots \\ 0 & 0 & \cdots & \sigma_{mm} \end{bmatrix} \quad (1.16)$$

Burada  $\sigma$  i. ve j. bileşen arasındaki kovaryans değerini verir.

Matrisi köşegen hale getirmek için birçok yöntem mevcuttur. TBA geniş bir uygulama alanına sahip olmak için en basit yöntemi seçer. Bu yöntem aşağıda verilmektedir [55].

$Y$ 'nin kovaryans matrisi (1.17) bağıntısında verilmektedir.

$$\text{kov}(Y) = \frac{1}{N-1} Y Y^T \quad (1.17)$$

TBA'nın amacı  $Y=DX$  eşitliğindeki ortogonal  $D$  matrisini bulmaktır. Çünkü  $D'$ 'nin satırları  $X'$ 'in temel bileşenlerine karşılık gelmektedir. Buna göre (1.18) eşitliğinde  $Y$  yerine  $DX$  konulduğunda elde edilen eşitlik aşağıda verilmektedir.

$$\text{kov}(Y) = \frac{1}{N-1} (DX)(DX)^T \quad (1.18)$$

$$\text{kov}(Y) = \frac{1}{N-1} DXX^T D^T \quad (1.19)$$

$$\text{kov}(Y) = \frac{1}{N-1} D(XX^T) D^T \quad (1.20)$$

$$\text{kov}(Y) = \frac{1}{N-1} DAD^T \quad (1.21)$$

(1.20) bağıntısında simetrik bir matris olan  $A = XX^T$  tanımlanmıştır. Bu simetrik matris özvektörlerinden oluşan ortogonal matris ile köşegenleştirilmektedir.

$$A = EKE^T \quad (1.22)$$

(1.22) bağıntısında  $K$  köşegen matris,  $E$  ise  $A$ 'nın öz vektörlerinin sütunlara yerleştirilmesi ile elde edilen matristir.  $D$  dönüşüm matrisinin her bir satırı  $d_i$ ,  $A$ 'nın öz vektörü seçildiğinde,  $D = E^T$  ve  $A = D^T K D$  eşitliği elde edilmektedir.  $D$  matrisi ortogonal olduğu için tersi transpozuna eşittir,  $D^{-1} = D^T$ . Bu elde edilen eşitlikler  $\text{kov}(Y)$ 'de yerine koyulduğunda (1.23) bağıntısı elde edilmektedir.

$$\begin{aligned} \text{kov}(Y) &= \left( \frac{1}{N-1} \right) * DAD^T = \left( \frac{1}{N-1} \right) * D(D^T K D) D^T \\ \text{kov}(Y) &= \left( \frac{1}{N-1} \right) * D D^T K D D^T = \left( \frac{1}{N-1} \right) * D D^{-1} K D D^{-1} \\ \text{kov}(Y) &= \left( \frac{1}{N-1} \right) * K \end{aligned} \quad (1.23)$$

Görüldüğü üzere,  $K$  köşegen matris olduğundan  $K'$  nin skalerle çarpımı olan  $\text{kov}(Y)$ ' de köşegen matris olmaktadır.  $D$  dönüşüm matrisinin seçimi ile kovaryans matrisi köşegenleştirilmiştir. Dolayısıyla  $D, A = XX^T$  matrisinin özvektörlerini satırlarında içeren matris olarak alındığında; veri kümesini içeren  $X$  matrisinin dönüştüğü  $Y$  matrisinin kovaryansı hedeflendiği gibi köşegen özelliğe sahip olmaktadır.

Sonuç olarak; veri kümesi  $X$ ,  $D$  dönüşüm matrisi ile yeni bir alt uzaya iz düşürülmüştür. Bu  $X'$  in dönüştürülmüş hali olan  $Y$ 'nin kovaryans matrisinin köşegen özellikte olması ile sağlanmıştır.  $D'$  deki vektörler alt uzayın eksenlerine karşılık gelmektedir.

Orijinal veri kümesini alt uzaya izdüşürürken, izdüşümden kaynaklanan hatanın minimum olması için, verinin dağılımını en çok kapsayan eksenleri yani en büyük varyansı veren özvektörlerin temsil ettiği eksenleri, temel bileşenleri, seçmek gerekmektedir. TBA' da bu doğrultu varyansın en fazla olduğu doğrultu olan  $X$  veri kümesinin kovaryans matrisinin en büyük özdeğerine ilişkin olan özvektördür.

### 1.5.3. Temel Bileşenlerin Seçilmesi

Temel Bileşenler Analizi,  $n$  sayıdaki birbiri ile ilişkili değişkeni  $k < n$  olmak üzere  $k$  sayıdaki birbirinden bağımsız değişken ile temsil ederek boyut indirgemesi sağlamaktadır. Ancak TBA' dan elde edilen temel bileşenlerin sayısı veri kümesindeki değişkenlerin sayısı ile aynı olacaktır. Bunun için  $n$  bileşen arasından seçilen  $k$  bileşenin en az veri kaybıyla, veriyi en iyi temsil edecek olan bileşenler olması gerekmektedir.

Toplam varyansın ne kadarının veriyi temsil etmede yeterli kabul edilebileceği konusunda çeşitli görüşler mevcuttur. Bazı araştırmacılar tarafından ilk 5 veya 6 bileşenin toplam varyansın % 70 ile 80' ini kapsamasının yeterli olduğunu savunurken diğerleri % 80-90' ın uygun olduğunu belirtmektedirler [56]. Birçok bilgisayar yazılımında ise toplam varyansın % 95' inin temsil edildiği bileşen sayısı ölçüt olarak kabul edilmektedir [57]. Hesaplanan temel bileşenler içerisinde optimal sayıdaki temel bileşen sayısı, ortalama kök, %95 testi, döküntü grafiği yöntemleri ile değerlendirilmektedir.

Ortalama kök yöntemi; Öz değerlerin ortalamasından daha düşük değere sahip olan bileşenlerin alınmamasına dayanmaktadır [57]. Bunun için kovaryans matrisinin özdeğerlerinin ortalamaları hesaplanmaktadır.

$$\bar{\lambda} = \frac{\sum_{i=1}^N \lambda_i}{N} \quad (1.24)$$


Burada N bileşen sayısını,  $\lambda_i$  kov(X) in i. bileşenine ait özdeğeri,  $\bar{\lambda}$  ortalama özdeğeri ifade etmektedir. Optimal temel bileşenlerin sayısı, hesaplanan ortalama öz değerden daha yüksek özdeğere sahip olan temel bileşenlerin sayısı olarak alınmaktadır.

% 95 testi yöntemi; her bir temel bileşenin toplam varyansın yüzde kaçını kapsadığı (1.25) eşitliğine göre hesaplanmaktadır.

$$V = \frac{\lambda_i}{\sum_{i=1}^N \lambda_i} * 100 \quad (1.25)$$

Her bir öz değer için hesaplanan V değerlerinin kümülatif toplamı değerlendirilerek %95 ve üstü değere denk gelen temel bileşen sayısı optimal temel bileşen sayısı olarak alınmaktadır.

Döküntü grafiği yöntemi; temel bileşenlere bağlı olarak özdeğerlerin davranışı gösteren, yatay eksenle bileşen sayısı ve dikey eksenle özdeğerler olacak şekilde bir grafikten yararlanılır. Şekil 1.14 'te temel bileşenlere bağlı olarak özdeğerlerin davranışı gösteren örnek bir grafik verilmektedir.



Şekil 1.14. Temel Bileşenlere bağlı olarak özdeğerlerin davranışı

Grafikten de görüldüğü üzere genellikle özdeğerler bir eğri davranışı göstermektedirler. Bu yöntemde eğrideki büküm noktasına denk gelen bileşen sayısı, bileşen seçiminde ölçüt olarak kullanılmaktadır.

Bir başka yöntem olarak da temel bileşenin taşıdığı bilgi miktarının özdeğeri ile ölçülmekte olduğuna düşüncesiyle, özvektörler özdeğerlerine göre azalan sırada sıralanarak ve sondaki bazı vektörler işleme dâhil edilmemektedir [58]. Alt uzaydaki boyut sayısını düşürmede fazla veri kaybı olmadan, kullanılacak özdeğer sayısını belirlerken en büyük değerlilerin yanında küçük değerlilerin gözardı edilmesi aşağıdaki şartla sağlanabilmektedir.

$$\frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^N \lambda_i} > K \quad (1.26)$$


Burada N tane öz değer içerisinde toplamalarının tüm özdeğerler toplamına oranı K'dan büyük olan en büyük k tane özdeğer seçilecektir. K değeri performansa göre belirlenmektedir.

Optimal bileşen sayısını belirlemede kullanılan yöntemlerin karşılaştırılması amacıyla birçok araştırma gerçekleştirilmiş olmasına karşın, her bir çalışmadaki deney verisinin farklı özellikler içermesi sebebiyle kabul gören sonuçlara ulaşılamamıştır [57].

#### 1.5.4. Özyüz Yöntemi

Yüz görüntülerinin düşük boyutlu uzayda temsili ilk olarak Kirby ve Sirovich tarafından Brown Üniversitesinde 1987 yılında ortaya atılmıştır [49]. Daha sonraları Pentland, Turk, Moghaddam bu düşünceden hareketle 1994 yılında yüz tanıma amaçlı Özyüz dönüşümü adı altında bir yöntem geliştirmiştir [59].

Özyüz yöntemi, yüz olmayan görüntülerin dağılımını dikkate almayarak, yüz görüntülerin temsili için daha düşük boyutlu bir alt uzay bulmayı amaçlamaktadır. Özyüz yönteminde odaklanılan kısım yüz görüntüleri arasında oluşan varyasyondur. Şekil 1.15’ te bu durum görsel olarak verilmektedir.



Şekil 1.15. Yüz görüntüleri arasındaki varyasyon

Bir görüntü uzayı, görüntüyü oluşturan bütün piksellerin sayısı kadar boyutta ve piksel değerleri aralığında değerlere sahip bir uzay olarak düşünülebilir. Öyleyse  $N_x \times N_y$  boyutlu gri ölçekli bir görüntünün, görüntü uzayını  $P$  olarak alırsak,  $P$ 'nin boyutu  $N_x \times N_y$  olmaktadır. Ve görüntü gri ölçekli olduğu için her bir boyut 0 ile 255 arasında bir değer alır.

Bir görüntü satırları birbiri ardına eklenerek oluşturulmuş bir sütun vektörüne dönüştürüldüğünde, görüntü uzayında bir nokta olarak temsil edilebilir.

Bu şekilde bütün yüz görüntüleri vektörlere dönüştürüldüğünde, görüntü uzayında belirli bir bölgede gruplaşma olacaktır. Çünkü her yüzdeki yapı; gözler, ağız, burun benzerdir ve bunların yüz üzerindeki yerleri birbirleriyle bağlantılıdır. Bu durumdan hareketle görüntü uzayının tamamını kullanmak yerine yüzleri daha iyi tanımlayabilen bir alt uzay kullanmak daha uygun olacaktır. Bu alt uzay, yüz uzayı ve yüz uzayının sahip olduğu başlıca vektörler temel bileşenler olarak nitelendirilir. Özyüz analizi ile görüntü uzayının yüz uzayına izdüşümü gerçekleştirilmektedir.


#### 1.5.4.1. Özyüzlerin Hesaplanması

Özyüz yönteminde amaç yüzlerin oluşturduğu dağılımın temel bileşenlerini bulmak yani matematiksel olarak değerlendirilirse yüz görüntülerinden oluşan kovaryans matrisinin öz vektörlerini bulabilmektir. Bu özvektörler yüz uzayının eksenleri olup, yüz görüntüleri arasındaki dağılımı karakterize eden bir özellikler kümesidir. Özyüz yönteminin adımları aşağıda verilmektedir.

Adım 1: Genişliği  $N_x$ , yüksekliği  $N_y$  olan  $I$ , bir görüntü matrisi olsun.

$$I : N_x * N_y \text{ piksel} \quad (1.27)$$

$N_x * N_y$  boyutundaki görüntü matrisi satırları art arda getirilerek  $P * 1$  boyutundaki  $x$  sütun vektörüne dönüştürülür ( $P = N_x * N_y$ ). Böylece oluşan her bir vektör bir yüz görüntüsünü göstermektedir. Görüntünün vektör şeklinde temsili Şekil 1.16' da gösterilmektedir.



Şekil 1.16. Yüz görüntüsünden yüz vektörü oluşturma

Adım 2: Her bir görüntü matrisi sütun vektörüne dönüştürülerek eğitim matrisi oluşturulur. (1.28) eşitliğinde, M eğitim setindeki görüntü sayısını, X eğitim seti matrisini göstermektedir. Eğitim seti matrisinin boyutu P\*M olmaktadır.

$$X=[x_1 x_2 \dots x_M]$$

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^M \\ x_2^1 & x_2^2 & \dots & x_2^M \\ \vdots & \vdots & \ddots & \vdots \\ x_p^1 & x_p^2 & \dots & x_p^M \end{bmatrix} \quad (1.28)$$

Adım 3: Eğitim vektörlerinin ortalaması hesaplanır. Hesaplanan ortalama vektörü, her bir eğitim vektöründen çıkarılarak sıfır ortalamalı yeni eğitim veri matrisi elde edilir.

$$\mu = \frac{1}{M} \sum_{i=1}^M x_i = \begin{bmatrix} m_1 \\ m_2 \\ \vdots \\ m_p \end{bmatrix} = \mu \quad (1.29)$$

(1.29) bağıntısında  $\mu$  ortalama vektörü olup ortalama yüz olarak da adlandırılır. Ortalama yüz matrisinin boyutu P\*1' dir. Ortalama yüz hesaplandıktan sonra yeni sıfır ortalamalı eğitim seti matrisi A oluşturulur. A' nın hesaplanması (1.30), (1.31), (1.32) eşitliklerinde gösterilmektedir.

$$r_i = x_i - \mu \quad (1.30)$$

$$A=[r_1 r_2 \dots r_M] \quad (1.31)$$

$$A = \begin{bmatrix} x_1^1 - m_1 & x_1^2 - m_1 & \cdot & x_1^M - m_1 \\ x_2^1 - m_2 & x_2^2 - m_2 & \cdot & x_2^M - m_2 \\ \cdot & \cdot & \cdot & \vdots \\ x_P^1 - m_P & x_P^2 - m_P & \cdot & x_P^M - m_P \end{bmatrix} \quad (1.32)$$

A matrisinin boyutu da  $P \times M$  olmaktadır.

Adım 4: A matrisinin kovaryans matrisi (1.33) eşitliği kullanılarak hesaplanır ve kovaryans matrisinin özdeğerleri ve onlara karşılık gelen özvektörleri bulunur.

$$C = A * A^T = \frac{1}{M-1} \sum_{i=1}^M (x_i - \mu) * (x_i - \mu)^T \quad (1.33)$$

$$\begin{bmatrix} (x_1^1 - m_1)^2 & (x_1^2 - m_1)(x_1^1 - m_2) & \cdot & (x_1^M - m_1)(x_1^1 - m_N) \\ (x_2^1 - m_2)(x_1^2 - m_1) & (x_2^2 - m_2)^2 & \cdot & (x_2^M - m_2)(x_2^1 - m_N) \\ \cdot & \cdot & \cdot & \cdot \\ (x_N^1 - m_N)(x_1^M - m_1) & (x_N^2 - m_N)(x_2^M - m_2) & \cdots & (x_N^M - m_N)^2 \end{bmatrix} \quad (1.34)$$

(1.34)' deki matrisin köşegeni üzerinde bulunan matris elemanları varyans, geri kalan elemanlar ise kovaryans katsayılarıdır.

C matrisinin boyutu  $P \times P$  olmaktadır. P 'nin de  $N_x \times N_y$  boyutunda olduğu göz önünde bulundurulursa kovaryans matrisinin boyutu işlem yapma açısından oldukça büyüktür. Örneğin eğitim setindeki görüntülerin boyutu  $256 \times 256$  alındığı düşünülürse kovaryans matrisinin boyutu  $65.536 \times 65.536$  olacak ve 65.536 özvektör yani özyüz çıkarılacaktır. Bu probleme çözüm olarak Özyüz yönteminde  $P \times P$  boyutundaki kovaryans matrisinin özvektörlerini hesaplamak yerine  $M \times M$  büyüklüğündeki matrisin özvektörleri hesaplanır. Çünkü  $M \times M$  boyutundaki matrisinin öz vektörleri  $P \times P$  boyutundaki matrisin özvektörlerine denk gelmektedir. Şöyle ki;

C matrisi yerine Y matrisi (1.35) eşitliğindeki gibi tanımlansın.

$$Y = A^T * A = \frac{1}{M-1} \sum_{i=1}^M (x_i - \mu)^T * (x_i - \mu) \quad (1.35)$$

Bu şekilde Y matrisinin boyutu  $M \times M$  olacaktır.

Y' nin özvektörleri  $v_i$ , özdeğerleri  $\alpha_i$  olsun.

$$Y * v_i = \alpha_i * v_i \quad (1.36)$$

$Y'$  nin deęerini bu baęıntıda yerine koyarsak (1.37) eřitlięi elde edilir.

$$A^T * A * v_i = \alpha_i * v_i \quad (1.37)$$


Eřitlięin her iki tarafını  $A$  ile arpılsın.

$$A * A^T * A * v_i = A * \alpha_i * v_i \quad (1.38)$$

$\alpha_i$  skaler bir sayı ve de  $C=A * A^T$  olduęundan bu baęıntı dzenlendięinde eřitlik (1.39) elde edilmektedir.

$$C * A * v_i = \alpha_i * A * v_i \quad (1.39)$$

(1.39)' da grldę zere  $C$  matrisinin zvektr  $u_i = A * v_i$  olmaktadır.  $C$  matrisinin zvektrlerine zyz adı verilmektedir. zyzler, yz gibi grnme sahip oldukları iin bu adı almıřlardır. řekil 1.17' de rnek zyzler verilmiřtir.



řekil 1.17. Kovaryans matrisinin zvektrlerine karřılık gelen zyzler

Adım 5: Hesaplanan zdeęerler bykten kęe doęru sıralanır. Bu sıralı zdeęerlere karřılık gelen sıralı vektrlerden ilk  $k$  tanesi kullanılarak  $G$  iz dřm matrisi oluřturulur. Seilen zvektrler matrisin satırlarını oluřturacak řekilde 1.40' daki eřitlik elde edilir.

$$G^T = \begin{bmatrix} g_1 \\ g_2 \\ \vdots \\ g_k \end{bmatrix} \quad (1.40)$$

Bulunan  $k$  tane Özyüz (özvektör)  $P$  boyutlu yüz uzayını tanımlar. (1.41) eşitliği ile eğitim seti matrisinin  $G$  matrisi üzerinde izdüşümü alınır.

$$W = G^T A = G^T (X - \mu) \quad (1.41)$$

Burada  $W$ , eğitim seti matrisinin Özyüz uzayına izdüşürülmüş şeklidir.  $W$  matrisinin her bir sütunu ise eğitim setindeki görüntülerin özuzaya izdüşürülmüş şekli olmaktadır.

Özyüz yöntemindeki en önemli nokta, görüntü uzayında  $N_x \times N_y$  boyutunda olan bir görüntünün, özyüz uzayında  $k \times 1$  boyutunda bir vektör olarak temsil edilebilmesidir.

Böylece eğitim aşaması tamamlanmış bulunmaktadır. Bir sonraki adım, bir test görüntüsü geldiğinde, eğitim aşamasındaki öznitelikler kullanılarak test vektörünü sınıflandırabilmektir. Aşağıda test görüntünün Özyüz uzayına izdüşümü ve sınıflandırılması verilmektedir.

Test görüntüsü vektörü  $X_t$  olsun. Test görüntü vektörünün boyutu, eğitim görüntü vektörlerinin boyutları ile aynı olup  $P \times 1$ ’ dir.

Öncelikli olarak test görüntü vektöründen ortalama vektörü çıkarılmaktadır.

$$r_t = X_t - \mu \quad (1.42)$$


Daha sonra test görüntüsü eğitim aşamasında elde edilen izdüşüm matrisi ile öz uzaya izdüşürülür. Test görüntüsü için izdüşürme işlemi (1.43) eşitliğinde verilmektedir.

$$W_t = G^T r_t = G^T (X_t - \mu) \quad (1.43)$$

### 1.6. Doğrusal Ayırıştırma Analizi

Fisher Ayırıştırma Analizi olarak da adlandırılan Doğrusal Ayırıştırma Analizi daha küçük boyutta yeni bir alt uzay oluştururken, verileri gruplayarak, aynı türdeki veri noktalarını bir araya getiren ve farklı türdeki veri noktalarını birbirinden ayıran doğruları bulmayı amaçlamaktadır [58]. Fisher' ın Doğrusal Ayırıştırıcısı [60] (FDA) R. A. Fisher tarafından 1930'larda geliştirilmesine rağmen Fisher Ayırıştırıcıları ancak son yıllarda obje tanımda kullanılmaya başlanmıştır. FDA, 1996 yılında Swets ve Weng tarafından kimliklendirme amaçlı resimleri kümelemede kullanılmıştır [61]. Belhumeur, Hespanha ve Kriegman ise FDA' yı eğitim ve farklı ışıklandırmalar altındaki bir kaç yüz ile test ederek yüz belirleme alanında kullanmışlardır [62].

DAA, P (görüntüdeki piksel sayısı) boyutlu uzaydaki görüntüleri C-1 (C sınıf sayısı) boyutlu uzaya izdüşürmektedir. TBA ile DAA karşılaştırıldığında, iki yöntemde boyut indirgeme amacı ile kullanılmaktadır. TBA özellik sınıflandırırken, DAA veri sınıflandırmaktadır. TBA varyansın maksimum olduğu doğrultuya izdüşüm yaparken, DAA sınıflar arası varyansın, sınıf içi varyansına oranının maksimum olduğu doğrultuya izdüşüm yapmaktadır. Şekil 1.18' de TBA ve DAA' nın iki ayrı türden veri üzerindeki izdüşüm doğrultuları verilmektedir.



Şekil 1.18. Alt uzaya yansıma [58].

Şekil 1.18'den de görüldüğü üzere TBA' da varyansın maksimum olduğu doğrultu üzerinde izdüşüm yapılmıştır ancak bu doğrultu verinin sınıflandırılması için uygun bir doğrultu olmamaktadır. Bununla birlikte DAA kullanılarak izdüşüm yapılan doğrultu ise veri sınıflandırması için en uygun doğrultudur. Ayrıca TBA' da örneklerin hangi sınıftan geldiği bilinmezken ve önemsenmezken, DAA' da örneklerin hangi sınıftan geldiği bilinmekte ve kullanılmaktadır.

Fisheryüz ile Özyüz yöntemi benzerdir. İki yöntemde de görüntü uzayı yeni bir alt uzaya izdüşürülmektedir. Aralarındaki tek fark alt uzayın hesaplanış şeklidir.

### 1.6.1. Fisheryüzlerin Hesaplanması

DAA, yüz görüntülerini en iyi temsil edecek özellikleri çıkartan TBA' nın aksine farklı yüz sınıflarını en iyi ayıracak bir altuzay bulmaya çalışmaktadır. Bu, izdüşürülecek uzayda sınıflar arası saçılım matrisi  $S_B$ 'yi maksimum, sınıf içi saçılım matrisi  $S_W$ ' yu minumum yapmakla gerçekleştirilmektedir.

Adım 1: Genişliği  $N_x$ , uzunluğu  $N_y$  olan  $I$ , bir görüntü matrisi olsun.

$$\text{Görüntü} \rightarrow I: N_x \times N_y \text{ piksel} \quad (1.44)$$

$N_x \times N_y$  boyutundaki görüntü matrisi TBA' da olduğu gibi satırları art arda getirilerek  $P \times 1$  boyutundaki  $x$  sütun vektörüne dönüştürülür ( $P = N_x \times N_y$ ). Böylece oluşan her bir vektör bir yüz görüntüsünü göstermektedir.

Adım 2: Her bir görüntü matrisi sütun vektörüne dönüştürülerek eğitim matrisi oluşturulur. (1.45) eşitliğinde,  $M$  eğitim setindeki görüntü sayısını  $X$  eğitim seti matrisini göstermektedir. Eğitim seti matrisinin boyutu  $P \times M$  olmaktadır.

$$\text{Eğitim seti} \rightarrow X = [x_1 x_2 \dots x_M] \quad (1.45)$$

Adım 3: Sınıf içi saçılım matrisi  $S_W$  hesaplanır.  $S_W$ , aynı sınıftaki veriler arasındaki saçılım miktarını ölçmektedir. DAA her bir sınıftaki eğitim görüntülerini tek başına

değerlendirmez. Bu durumda  $S_W$  bir benzerlik matrisi haline gelir. Standart Özyüz yönteminde de  $S_W$  kovaryans matrisi olarak alınır [63].

Her bir sınıfın sınıf içi saçılım matrisi, o sınıftaki sıfır ortalamalı görüntülerin kovaryans matrislerine denk gelmektedir. (1.46) eşitliğinde i. nci sınıfın, sınıf içi saçılım matrisi  $S_i$ 'nin hesaplanması verilmektedir.

$$S_i = \sum_{x \in X_i} (x - m_i)(x - m_i)^T \quad (1.46)$$

$$m_i = \frac{1}{n_i} \sum_{k=1}^{n_i} x_k \quad (1.47)$$

Burada  $m_i$  i. nci sınıftaki görüntülerin ortalamasıdır. Burada  $i=1, 2, \dots, C$  (sınıf sayısı)'ye kadar değer almaktadır. Her bir sınıf için hesaplanan ortalama yüz vektörü  $P \times 1$  boyutunda olmaktadır.

$S_W$ , tüm sınıfların sınıf içi saçılım matrisinin toplamıdır (1.48).

$$S_W = \sum_{i=1}^C S_i \quad (1.48)$$

Burada  $C$  sınıf sayısıdır.

Adım 4: Sınıflar arası saçılım matrisi  $S_B$  hesaplanır.  $S_B$  sınıflar arasındaki saçılımın miktarını ölçmektedir.  $S_B$ 'nin hesaplanması (1.49)'de verilmektedir.

$$S_B = \sum_{i=1}^C n_i (m_i - m)(m_i - m)^T \quad (1.49)$$

Burada  $m$  tüm eğitim görüntülerinin ortalaması,  $n_i$  sınıftaki görüntü sayısını ifade etmektedir.

Adım 5: Alt uzaya izdüşüm yapacak en iyi  $D$  izdüşüm doğrultusunu bulmak için (1.50) eşitliğindeki genelleştirilmiş özdeğer problemi çözülür.

$$S_B D = S_W D \lambda_W \quad (1.50)$$

(1.50) eşitliğinin her iki tarafı  $S_W^{-1}$  ile çarpılırsa;

$$S_W^{-1} * S_B * D = D * \lambda_W \quad (1.51)$$

elde edilir.  $D$ ,  $S_W^{-1} * S_B$  matrisinin özvektörlerine,  $\lambda_W$  özdeğerlerine karşılık gelmektedir.

$S_W^{-1} * S_B$  matrisinin en fazla  $C-1$  tane sıfır olmayan özvektörü vardır. Böylece verilen en yüksek boyutlu görüntü bile  $C-1$  boyutlu uzaya izdüşürülmüş olur.  $S_W$  'nin tekil olmamasını garantilemek için ise en azından eğitim setinde  $P+C$  tane örnek olması gerekmektedir. Yüz tanıma uygulamalarında, çoğunlukla örnek uzayının boyutu, eğitim setindeki görüntü sayısından büyük olmakta ve dolayısıyla sınıf içi saçılım matrisi  $S_W$  tekil olup ve tersi alınamamaktadır. Bu problem az sayıdaki örneklerin boyut problemi (small sample size problem) olarak bilinmektedir [64]. Literatürde  $S_W$  'nin tersi alınabilmesi için önerilen birçok yöntem mevcuttur:

- Düzenleştirme: Bu yöntemde  $S_W$  matrisi köşegen elemanları kullanılarak düzenlenir.  $S_W$  matrisinin düzenlenmiş hali  $S_W'$  (1.52) eşitliğinde verilmektedir.

$$S_W' = S_W + \beta I \quad (1.52)$$

Burada  $\beta$  oldukça küçük seçilmesi gereken bir parametredir. Pratikte  $\beta$ ,  $S_W$  matrisinin küçük bir  $k$  sabiti ile çarpımından elde edilen matrisin köşegen elemanlarının ortalaması olarak alınır [65, 66].

- Altuzay: Alt uzay yönteminde, TBA ile veri boyutları indirgenmekte ve böylece  $S_W$  'nin de tekil olmaması garantilenmiş olmaktadır.

Adım 6:  $S_W$  tekil olmaması garantilendikten sonra, özvektörler özdeğerlerine göre azalan sırada sıralanarak ilk  $C-1$  özvektör alınır. Bu özvektörler Fisher'ın temel vektörlerini (Fisheryüz) oluşturmaktadırlar.

Adım 7: Hesaplanan özvektörlerle orjinal yüz görüntüleri (sıfır ortalamalı olmayan), TBA' da olduğu gibi Fisheryüz uzayına izdüşürülür.

### 1.7. Alt Uzay Doğrusal Ayrıştırıcı Analizi

Alt Uzay Doğrusal Ayrıştırıcı Analizinde, veri öncelikle TBA ile Özyüz uzayına izdüşürüldükten sonra DAA ile Özyüz uzayındaki veri sınıflandırılmaktadır.

#### 1.7.1. Alt uzay DAA' nın Uygulanması

Adım 1: Tüm eğitim görüntüleri için önceki bölümde bahsedilen Özyüz yöntemi uygulanır. Özyüz yöntemi ile  $P$  boyutlu uzaydan  $k'$  boyutlu özuzaya izdüşüm yapılmaktadır. Özyüz uzayındaki görüntüler  $k' * 1$  boyutludur. Bu aşama sonucunda verilerin boyutu indirgenmiş, birnevi veri özelliği çıkarılmıştır.

Adım 2: Boyut indirgemesinden sonra tüm görüntüler Fisheryüz uzayına izdüşürülür. Ancak görüntülerin piksel değerleri yerine Özyüz uzayına izdüşürülmüş bileşenleri alınır. Böylece eğitim aşaması tamamlanmış olmaktadır.

Adım 3: Test aşamasında da öncelikle test görüntüsü Özyüz uzayına izdüşürüldükten sonra Fisheryüz uzayına izdüşürülmektedir.

### 1.8. Sınıflandırma

Sınıflandırma aşamasının amacı, test olarak verilen görüntünün özellikleri ile eğitim görüntülerinin özelliklerinin karşılaştırılarak birtakım benzerlik ölçütlerine göre test görüntüsü ile eğitim görüntülerinin ne kadar eşleştiğini belirlemektir. Çok sınıflı yüz tanıma uygulamalarında daha çok En yakın komşu ve En yakın ortalama sınıflandırıcıları kullanılmaktadır. Bu sınıflandırıcıların tasarımında en önemli nokta benzerliğin nasıl ölçüleceğidir. Benzerlik ölçümünde test ve eğitim özellikleri arasındaki uzaklığa bakılmaktadır. Uzaklık hesabında çeşitli uzaklık ölçütleri kullanılmaktadır: Manhattan, Chi karesi, Chebyshev uzaklıkları, Kosinüs benzerliği ve en sık kullanılan Öklit uzaklığı gibi farklı metotlar vardır. Bu uzaklık ölçütleriyle  $P = (p_1; p_2; \dots; p_n)$  ve  $Q = (q_1; q_2; \dots; q_n)$  noktaları arasındaki uzaklığın hesaplanışı aşağıdaki eşitliklerde verilmektedir.

$$D_{\text{Manhattan}} = \sum_{i=1}^n |p_i - q_i| \quad (1.53)$$

$$D_{\text{Chebyshev}} = \max_i (|p_i - q_i|) \quad (1.54)$$

$$D_{\text{Öklid}} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (1.55)$$

$$D_{\text{Chi Karesi}} = \sum_{i,j} w_{i,j} \frac{(p_{i,j} - q_{i,j})^2}{p_{i,j} + q_{i,j}} \quad (1.56)$$

$$D_{\text{Kosinüs}} = \frac{P \cdot Q}{\|P\| \|Q\|} = \frac{\sum_{i=1}^n p_i \times q_i}{\sqrt{\sum_{i=1}^n (p_i)^2} \times \sqrt{\sum_{i=1}^n (q_i)^2}} \quad (1.57)$$

(1.56) eşitliğinde  $i$  ve  $j$  indeksleri,  $j$ .yerel bölgeye karşılık gelen histogramın  $i$ . bölmesini,  $w_{i,j}$  ise  $j$ . bölgenin ağırlığını ifade etmektedir.

En yakın komşu; Bu yöntemde test ile eğitim görüntüleri arasındaki uzaklık verilen uzaklık ölçütlerine göre hesaplanmaktadır. Hesaplama sonucunda, test görüntüsü en yakın olduğu eğitim görüntüsünün sınıfa dahil edilmektedir.

En yakın ortalama; En yakın komşu sınıflandırıcısı ile benzer sınıflandırıcılardır. Bu yöntemde özellik çıkarımı sonucunda her bir sınıfın özelliklerinin ortalaması alınarak her sınıf için tek bir özellik vektörü elde edilmektedir. Test ile sınıf özellik vektörleri arasındaki uzaklık verilen ölçütlere göre hesaplanmakta ve test görüntüsü en yakın olduğu sınıfa dahil edilmektedir.

## 1.9. Sınıflandırma Performansının Değerlendirilmesi

### 1.9.1. Tanısal Meta-Analiz

Meta-analiz, aynı konudaki farklı yer ve zamanlarda yapılmış olan araştırma sonuçlarının niteliksel ve niceliksel olarak uygun istatistiksel yöntemlerle birleştirilmesidir [67, 68].

Meta-analizin temel ortaya çıkış nedeni, karmaşık ve çelişkili görülen sonuçlardan anlamlı ve uygulanabilir sonuçlar çıkartmaktır [69]. Tanısal meta-analizler ise meta-analizlerin yöntemsel olarak alt grubu olup, tanısal testlerin doğruluğunu ve performansını sistematik olarak değerlendirmektedirler.

Hasta ve sağlıklı bireylerin oluşturduğu heterojen bir toplulukta bireylerin hastalık durumunu belirlemek amacıyla kullanılan tanı testlerini, genel olarak hastalıkların tanısında kullanılan istatistik yöntemler değerlendirmektedir. Doğruluğu kesin olarak kanıtlanmış referans testler (kesin test, altın standart test) ile bireylere kesin hasta ya da kesin sağlıklı tanısı konulabilmektedir. Fakat bu testlerin uygulamalarının zor, maliyetlerinin yüksek ve bazı hastalıklarda girişimsel olmaları nedeniyle her şüpheli durumda kullanılmaları mümkün olmamaktadır [70].

Bu sebeple birçok bilim dalında referans testlere alternatif olacak tanı testleri geliştirilmeye çalışılmaktadır. Referans testlerle gerçek durumu (hasta sağlıklı) belirlenmiş bireylere, ilgili tanı testi uygulanarak, testin ayrıcalıklı gücünü gösteren “doğruluk ölçütleri” elde edilmektedir. İki sonuçlu tanı testlerinin gücü “özgün oranlar”, sıralı ya da sürekli sonuçlu tanı testinin gücü ise “ROC eğrisi” altında kalan alan yardımıyla değerlendirilir [71].

Sağlık bilimlerinde, tanı testinin ayırt etme gücünün belirlenmesinde, çeşitli testlerin etkinliklerinin kıyaslanmasında, optimal pozitiflik eşiğinin belirlenmesinde, laboratuvar sonuçlarının kalitesinin izlenmesinde, uygulayıcıların gelişiminin izlenmesi ve farklı uygulayıcıların etkinliklerinin kıyaslanmasında ROC eğrisi yöntemi kullanılmaktadır [72].

Tanı testi sonuçlarının değerlendirilebilmeleri için, testin üzerinde uygulandığı olguların “gerçek tanı sonuçları” bilinmesi gerekmektedir. . Gerçek tanı için, aynı hastalığı belirlemede kesin doğru sonuçlar verdiği kabul edilen “altın standart yöntem” kullanılmaktadır. Altın standart; klinik süreç, cerrahi doğrulama, otopsi ve bazı olgularda bir uzmanın danışmanlığı

görevini yerine getirmektedir. Tanı testlerinin doğruluğunu test etmek için birçok yöntem mevcuttur.

Çalışmada ikili sonuç üreten tanısal testler kullanılmıştır. İkili sonuç üreten tanısal testlerde, gerçekte hastalığın var olup olmadığını belirten H ikili değişkeni tanımlanır. H için;

$$H = \begin{cases} 1 & \text{gerçekte hasta} \\ 0 & \text{gerçekte sağlam} \end{cases} \quad (1.58)$$

Tanımlanan S değişkeni ise tanısal test sonucunu tutan değişkendir. S'nin büyük değerleri hastalık işareti olarak düşünülmektedir [73].


$$S = \begin{cases} 1 & \text{pozitif test sonucu (Tanı testinin sonucuna göre hasta olanlar)} \\ 0 & \text{negatif test sonucu (Tanı testinin sonucuna göre sağlam olanlar)} \end{cases} \quad (1.59)$$

Bir ikili tanı testi sonucunda dört durum mevcuttur; gerçekte hasta olup, tanı testi sonucuna göre de hasta olarak çıkan durum Doğru Pozitif (TP), gerçekte sağlam oldukları halde testin hatalı olarak hasta belirlediği durum Yanlış Pozitif (FP), gerçekte hasta olup, tanı testi sonucuna göre sağlam olarak belirlenen durum Yanlış Negatif (FN), gerçek tanı sonucuna uygun olarak testinde sağlam dediği Doğru Negatif (TN) durumlarıdır. Bu durumlar Tablo 1.3' de düzenlenmiştir.

Tablo 1.3. İkili tanı testi durumları

| Tanı Testi Sonucu | Gerçek Durum(Altın Standart Tanısı) |                   |         |
|-------------------|-------------------------------------|-------------------|---------|
|                   | H=1                                 | H=0               |         |
| S=1               | A(Doğru pozitif)                    | B(Yanlış pozitif) | A+B     |
| S=0               | C(Yanlış negatif)                   | D(Doğru negatif)  | C+D     |
| Toplam            | A+C                                 | B+D               | A+B+C+D |

İkili tanı testi durumlarının grafiksel dağılımı aşağıda gösterilmektedir.



Şekil 1.19. İkili tanı testi grafiği

Tablodaki değerler kullanılarak çeşitli oranlar hesaplanmaktadır.

**Duyarlılık (Sensitivity) :** Gerçekten hasta olan ( $H=1$ ) bireylerin test tarafından ne kadar doğrulukta bulunabildiğini belirten bir orandır. Testin gerçek hastaları ayırt etmede ne oranda duyarlı olduğunu göstermektedir.

$$\text{Duyarlılık} = A / (A + C) = TP / (TP + FN) \quad (1.60)$$

**Özgüllük (Specificity) :** Bir testin gerçekte hasta olmayanlar arasından hasta olmayanları ( $H=0$ ) ayırabilme yeteneğini belirten orandır. Bir birey değerlendirilen hastalığa yakalanmamış ise test bunu kesin olarak ayırabilme gücüne sahip olmalıdır.

$$\text{Özgüllük} = D / (B + D) = TN / (FP + TN) \quad (1.61)$$

**Doğruluk (Accuracy):** Gerçekte testin hasta ve sağlam olarak toplam doğru tanının tüm tanı sonuçlarına oranına “doğruluk” denir.

$$\text{Doğruluk} = (A + D) / (A + B + C + D) = (TP + TN) / (TP + FP + TN + FN) \quad (1.62)$$

İkili tanı testi sonucunda oluşan hatalar yanlış pozitif ve yanlış negatif hatalar olmak üzere iki tiptir. İdeal bir test ne yanlış pozitif ne de yanlış negatif hatasına sahip değildir. Duyarlılık olarak adlandırılan doğru pozitif oranı (TPF), hasta olanlar arasından test sonucu pozitif çıkanların toplam hasta sayısına oranıdır. Testin, hasta olanlar arasından hastalığı saptama kapasitesidir. Gerçek pozitif hızı olarak da adlandırılır. Özgüllük olarak adlandırılan 1-yanlış pozitif oranı (FPF) ise hasta olmayanlar arasından test sonucu negatif çıkanların toplam hasta olmayan sayısına oranıdır. Gerçek negatif hızı olarak da adlandırılır. İdeal bir testte  $FPF=0$  ve  $TPF=1$  dir. İdeal olmayan yararsız bir testte ise  $TPF=FPF'$  dir. Bu değerlendirmelerin yanında test sonucunda sadece hastalıklı durumun doğruluğunu ölçmek için Pozitif Tahmin Değeri (PPV) ve Negatif Tahmin Değeri (NPV) kullanılmaktadır. Mükemmel bir test hastalık durumunu %100 bulabilmelidir. Bu da  $PPV=1$  olması ile mümkündür [73]. Aşağıdaki eşitliklerde bu değerlerin hesaplanması verilmektedir.

$$FPF = (1-\text{Özgüllük}) = B / (B+D) = FP / (FP+TN) \quad (1.63)$$

$$TPF=\text{Duyarlılık} = A / (A + C) = TP / (TP + FN) \quad (1.64)$$

$$PPV = A / (A+B) = TP / (TP + FP) \quad (1.65)$$


$$NPV = D / (D+C) = TN / (TN + FN) \quad (1.66)$$

Bir testin duyarlılık, özgüllük ve doğruluk değeri hastalığın türüne ve kitledeki gözlenme sıklığına göre yorumlanmakta ve büyük önem taşımaktadır. Eğer yanlış hastalık teşhisi daha ileri tekniklerle düzeltilemiyorsa testin özgüllük oranının yüksek olması, eğer test tarama amacı ile kullanılıyorsa duyarlılık oranının yüksek olması istenmektedir. Doğruluk oranı yüksek testler hem klinikte tanı amacıyla hem de taramalarda güvenle kullanılabilmektedirler [74].

## **2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME**

### **2.1. Sistemin Yapısı ve Aşamaları**


Çalışmada yüzden hastalık teşhisi yapan, otomatik ön tanı sistemi gerçekleştirilmiştir. Bunun için öncelikle eğitim ve test veri tabanı oluşturulmuştur. Veri tabanında kullanılan yüz görüntüleri internetteki açık kaynaklardan temin edilmiştir. Eğitim veri tabanı, Akromegali, Lupus, Down sendromu, sağlam ve bu sınıflardan hiçbirine dahil olmayan görüntüleri içeren bir diğer sınıf olmak üzere beş sınıftan oluşmaktadır. Eğitimde her bir sınıfta kullanılan 20 örnek ve testte kullanılan 41 yüz görüntüsü ile birlikte çalışmada toplam 141 yüz görüntüsü kullanılmıştır. Görüntüler sisteme giriş olarak verilmeden önce sistem performansını artırma amaçlı çeşitli ön işlem aşamalarından geçirilmiştir. Ön işlem olarak öncelikle, görüntü gri seviyeye çevrilmekte, ardından yüz görüntüsü ön yüz değilse, gözlerin konumuna göre döndürülmektedir. Daha sonra görüntüye kesme ve histogram eşitleme uygulanarak tüm görüntüler normalize edilmektedir. Ön işlem aşaması tamamlandıktan sonra, eğitim setindeki görüntüleri en iyi şekilde temsil ederek, ayırt edilebilmesini sağlayacak özelliklerin elde edilmesi için öznitelik çıkartım yöntemleri uygulanmaktadır. Öznitelik çıkartım yöntemlerinden Yerel İkili Örüntüler, İyileştirilmiş Yerel İkili Örüntüler ve Merkezi Simetrik Yerel İkili Örüntüler kullanılarak yüze ait çok küçük önemli örnekler tanımlanmakta, Temel Bileşen Analizi, Doğrusal Ayırıştırıcı Analizi ve Alt uzay Doğrusal Ayırıştırıcı Analizi kullanılarak ise, verilerin izdüştürüldüğü uzayda, sınıfların birbirinden olduğunca uzak yerleşmesi sağlanmaktadır. Elde edilen öznitelik vektörlerine göre giriş görüntüsü, En yakın komşu ve En yakın ortalama sınıflandırıcıları ile sınıflandırılmaktadır. Kullanılan özellik çıkarım yöntemlerinin her biri için ikili tanı testine göre sınıflandırıcıların performansları değerlendirilmektedir. En son olarak ise sınıflandırıcı sonuçlarına Borda Sayısı yöntemi uygulanmakta ve ön tanı performansı arttırılmaktadır. Şekil 2.1' de sistemin temel işlem adımları verilmektedir.



Şekil 2.1. Sistemin temel işlem adımları

### 2.1.1. Ön İşlemler

Veri tabanındaki yüz görüntülerine, sistemin tanıma performansını arttırmak amacıyla çeşitli görüntü işleme teknikleri uygulanmıştır. Çalışmada ön işlemler olarak uygulanan, Gri seviyeye dönüştürme, Görüntü döndürme, Kesme ve Histogram Eşitleme yöntemleri bu bölümde verilecektir. Şekil 2.2’ de uygulanan ön işlem aşamaları verilmektedir.




Şekil 2.2. Ön işlem aşamaları

#### 2.1.1.1. Gri Seviyeye Dönüştürme

Çalışmada görüntülerin gri seviye değerleri kullanılmıştır. Gri seviye değerleri renklerin siyahtan beyaza doğru değiştiği bir renk skalasıdır. Bu skaladaki renkler, 0 ile beyaz renk, 255 ile siyah renk temsil edilmek üzere 0-255 arasındaki toplam 256 renk kodu ile gösterilir. Görüntünün gri seviye değerini bulmak için kullanılan en genel yöntem, gri seviye piksel değerine, pikselin kırmızı, yeşil ve mavi bileşenlerinin ortalamasının atandığı yöntemdir. Bununla birlikte, pikselin bu üç bileşeninin ağırlıklandırılmış toplamı alınarak gri seviye değeri oluşturulan yöntem, insan gözünün temel renklere olan farklı hassasiyeti açısından daha uygundur [75]. Bir pikselin insan gözüyle algılanan parlaklığı  $0.30*R+0.59*G+0.11*B$  şeklinde hesaplanmaktadır.

#### 2.1.1.2. Görüntü Döndürme


Herhangi bir yüz görüntüsünde gözler, burun ve ağızın konumu bilindiğinde, yüz görüntüsü bu konumlara göre döndürülebilir. Çalışmada yüzler, gözlerin konumuna göre döndürülerek veri tabanındaki tüm yüz görüntüleri ön yüz haline getirilmiştir. Bunun için yüz görüntüsünde sağ ve sol gözün orta noktaları  $(X1,Y1)$  ve  $(X2,Y2)$  belirlenmektedir. Ardından bu noktaları birleştiren  $d1$  doğrusu ile dönme sonucunda oluşacak yüz görüntüsündeki sağ ve sol gözün orta noktalarını birleştiren  $d2$  doğrusu arasındaki açının ters tanjantı  $\alpha$  hesaplanmaktadır.  $\alpha$  açısı ile yüz görüntüsü döndürülmektedir. Şekil 2.3' te bu döndürme işleminin uygulanışı ve  $\alpha$  açısının hesaplanması gösterilmektedir.



Şekil 2.3. Görüntüyü döndürme

### 2.1.1.3. Görüntü Kesme

Sistem yüz bölgesine göre hastalık tespiti yaptığı için görüntülerdeki yüz kısmı kesilmekte ve sadece yüz bölgesi sisteme verilmektedir. Görüntüde yüz bölgesi kesilirken, kesim sınırları gözlerin ve ağzın konumlarına göre belirlenmektedir. Sol ve sağ kesim sınırlarının belirlenmesinde, sağ ve sol gözün x bileşenleri arasındaki uzaklık hesaplanır. Ve gözlerin x bileşenleri bu uzaklığın yarısı kadar ötelenir. Alt ve üst kesim sınırında ise bu sefer sol gözün ve ağzın y bileşenleri arasındaki uzaklık hesaplanır. Bu uzaklığın yarısı kadar ağız ve gözlerin y bileşenleri ötelenir. Bu kesme işlemi Şekil 2.4' te gösterilmektedir.




Şekil 2.4. Görüntü kesme

Veri tabanındaki görüntülerin yüz kısımları kesildikten sonra hepsi aynı boyuta getirilerek yeniden boyutlandırılmışlardır.


#### 2.1.1.4. Histogram Eşitleme

Histogram eşitleme, bir görüntüdeki renk değerlerinin belli bir yerde kümelenmiş olmasından kaynaklanan, renk dağılımı bozukluğunu gidermek için kullanılan bir görüntü işleme tekniğidir. Çalışmada veri tabanındaki tüm yüz görüntülerinde histogram eşitlemesi yapılarak görüntülerin kontrastları ayarlanmıştır. Şekil 2.5’ te Akromegali sınıfına ait bir görüntünün histogram eşitlemeden önceki ve sonraki histogramları verilmiştir.



Şekil 2.5. (a) Akromegali görüntüsü (b) Görüntü histogramı (c) Histogram eşitlemeden sonraki görüntü histogramı

Şekil 2.6’ da Down sendromlu görüntüler üzerinde ön işlem adımlarının sonucu verilmektedir.




Şekil 2.6. Down sendromlu örnekler üzerinde ön işlem adımları

### 2.1.2 Öznitelik Çıkarımı

Çalışmada öznitelik çıkarımı aşamasında Yerel İkili Örüntüler, İyileştirilmiş Yerel İkili Örüntüler, Merkezi Simetrik Yerel İkili Örüntüler, Temel Bileşen Analizi, Doğrusal Ayrıştırıcı Analizi ve Alt uzay Doğrusal Ayrıştırıcı Analizi yöntemleri kullanılmıştır.


#### 2.1.2.1 Yerel İkili Örüntüler

Özellik çıkarımı kısmında anlatılan Yerel ikili Örüntüler yönteminin akış diyagramı Şekil 2.7' de verilmektedir.



Şekil 2.7. YİÖ 'le özellik çıkarımı


Öncelikle tüm eğitim görüntülerinin YİÖ ikili kodu üretilmektedir. YİÖ kodu üretiminde YİÖ(8,1), YİÖ(8,2) ve YİÖ(16,2) operatörleri kullanılmıştır. Şekil 2.8' de her bir eğitim sınıfından alınan görüntülerin YİÖ(8,1) ve YİÖ(8,2) operatörleri ile elde edilen YİÖ kodlarının görüntüleri verilmektedir.



Şekil 2.8. Görüntülerin YİÖ kodları

YİÖ(8,1) ve YİÖ(8,2) operatörleri ile  $2^8$  farklı YİÖ kodu elde edilmektedir. YİÖ(16, 2) operatörü ile elde edilen kodda ise etiket değerleri 0 ile  $2^{16}$  arasında olduğu için gri seviye görüntüsü oluşturulamamaktadır. Bununla birlikte özellik vektörü olarak kabul edilen histogram boyutu da seçilen operatöre göre  $2^8$  veya  $2^{16}$  olmaktadır. Özellik vektörünün boyutunu indirmek amacıyla elde edilen görüntülerin hepsinin alınması yerine 0-1 yada 1-0 geçiş sayısı en fazla iki olan görüntüler alınmaktadır. YİÖ(8,1) ve YİÖ(8,2) operatörleri için, 256 görüntü içerisinde bit geçişi sayısı en fazla 2 olan 58 görüntü elde edilmekte ve diğer görüntülerde tek bir görüntüymüş gibi kabul edilmektedir. Böylece özellik vektörünün boyutu

256' dan 59' a, YİÖ(16,2) operatörü için ise 65536' dan 243' e düşmektedir. Şekil 2.9'da eğitim görüntülerinin düzenli YİÖ histogramları verilmektedir.




Şekil 2.9. Görüntülerin düzenli YİÖ histogramları

Bütün eğitim görüntüleri için düzenli YİÖ(8,1), (8,2) ve (16,2) kodu hesaplandıktan sonra, görüntüler 10x10 luk alt bölgelere ayrılmaktadır. Bu şekilde, her bir görüntü 100x100 boyutunda olduğundan, 10x10 piksellik 100 bölgeye ( $B_1, B_2, \dots, B_{100}$ ) ayrılmış olmaktadır. Şekil 2.10' da 10x10' luk alt bölgelere ayrılmış örnek bir görüntü verilmektedir.



Şekil 2.10. 10x10' luk alt bölgeye ayrılmış görüntü

Görüntüler alt bölgelere ayrıldıktan sonra her bir bölgenin düzenli YİÖ histogramı çıkarılmaktadır. Böylece toplamda 100 düzenli YİÖ histogramı elde edilmiş olur. Daha sonrasında bu bölgesel histogramlar birleştirilerek tek bir histogram elde edilmekte ve bu histogram her bir görüntü için özellik vektörü olarak kabul edilmektedir. Herbir görüntünün özellik vektörü 100x59 boyutunda olmaktadır. Şekil 2.11' de her bir alt bölgenin histogramın çıkarılması ve sonrasında birleştirilmesi gösterilmektedir.



Şekil 2.11. Bölgesel YİÖ histogramlarının çıkarılması ve birleştirilmesi

Görüntünün YİÖ kodunun histogramı çıkarılırken, özellik vektörü olarak tüm görüntünün histogramı yerine görüntünün bölgesel histogramlarının birleşimi alınmaktadır. Bölgesel histogramların birleşiminden oluşan bu histogram, bölgesel dokuların dağılımı hakkında da bilgi içermektedir.

#### **2.1.2.1.1. İyileştirilmiş Yerel İkili Örüntüler**

İYİÖ, YİÖ' den farklı olarak bütün bilgiyi değerlendirebilmek için, tüm pikselleri merkez pikselde dâhil olmak üzere piksellerin ortalamasıyla karşılaştırmaktadır. YİÖ ile  $2^P$  tane farklı yerel yapı tanımlanabilirken, İYİÖ ile  $2^{P+1}-1$  tane yerel yapı tanımlanabilmektedir. Örneğin  $P=8$  komşuluk için, YİÖ' de 256 farklı YİÖ kodu elde edilirken, İYİÖ' de 511 farklı İYİÖ kodu elde edilmektedir.

İYİÖ kodu elde edildikten sonra, görüntünün özellik vektörünü elde etmek için YİÖ algoritmasındaki adımlar takip edilmektedir.

#### **2.1.2.1.2. Merkezi Simetrik Yerel İkili Örüntüler**

Bu metotta YİÖ' de olduğu gibi her bir pikselin merkez pikselle olan farkına bakılması yerine, merkez piksele göre simetrik olan piksel çiftleri farkına bakılmaktadır. Bu şekilde MSYİÖ' le çıkarılan özellik boyutu, YİÖ 'le çıkarılan özellik boyutuna göre oldukça küçük olmaktadır. Örneğin 8 komşuluk için YİÖ, 256 ( $2^8$ ) farklı kod üretirken, MSYİÖ 16 ( $2^4$ ) farklı kod üretmektedir.


Kod üretiminde diğer bir farklılıkta kullanılan eşik değeridir. YİÖ' lerde eşik değeri merkez pikselin gri seviye değeri olarak alınırken, MSYİÖ' lerde performansa göre sabit bir değer alınmaktadır. MSYİÖ yöntemi özellik boyutunu küçültmesi açısından bir avantaj, eşik değerinin seçilmesi açısından bir dezavantaj oluşturmaktadır. Çalışmada görüntülerin piksel değerleri 0-1 arasına normalize edildikten sonra MSYİÖ(8,1) için eşik değeri  $T=0.07$ , MSYİÖ(8,2) için ise  $T=0.09$  alınmıştır. MSYİÖ kodu elde ettikten sonra görüntünün özellik vektörünü elde etmek için YİÖ algoritmasındaki adımlar takip edilmektedir.

### 2.1.2.1.3. YİÖ ile Elde Edilen Özelliklerin Sınıflandırılması

Çalışmada her hastalık sınıfına ait eğitim görüntüleri oluşturulduktan sonra YİÖ ile bütün eğitim görüntülerinin özellik vektörleri elde edilmiştir. Sınıflardaki görüntülerin bölgesel YİÖ histogramlarının ortalaması alınarak her sınıf için tek bir özellik vektörü elde edilmiştir. Bu şekilde elde edilen ortalama bölgesel YİÖ histogramı o hastalığa ait özellik vektörünü oluşturmaktadır.

Test görüntüsünü sınıflandırmada ise Ağırlıklandırılmış Chi Karesi İstatistiği, Öklit, Manhattan ve Chebyshev uzaklık ölçütleri ile NM sınıflandırıcısı kullanılmaktadır.

YİÖ kodu hesaplanan görüntü alt bölgelere ayrıldığında bazı bölgelerin diğerlerine göre daha fazla ve önemli bilgi taşıdığı düşünülerek Chi Karesi İstatistiği için bir ağırlıklık matrisi tasarlanmıştır. Bu matris tasarımı Akromegalide burun ve ağız, Lupusda yanak bölgesi, Down sendromunda gözler ve gözler arasındaki bölgelere, diğer bölgelere oranla daha önemli oldukları için 3 ve 4 katsayıları, bu bölgelerden daha az önemli bölgelere 1 katsayısı ve yüz dışında kalan bölgelere 0 katsayısı verilmiştir. Şekil 2.12’ de alt bölgelere ayrılmış görüntü ve ağırlık matrisi verilmektedir.



Şekil 2.12. Alt bölgelere ayrılmış ve ağırlıklandırılmış görüntü

Chi Karesindeki W matrisi elde edildikten sonra test görüntüsü ile her sınıfın ortalama bölgesel YİÖ histogramı arasındaki Chi Karesi uzaklığına bakılarak test görüntüsü en yakın olduğu sınıfa dahil edilmektedir.

Öklit, Manhattan ve Chebyshev uzaklık ölçütlerinde de Chi Karesindeki gibi test görüntüsü ile her sınıfın ortalama bölgesel YİÖ histogramı arasındaki uzaklıklara bakılarak test görüntüsü en yakın olduğu sınıfa dahil edilmektedir. Şekil 2.13' de YİÖ(8,1) ile elde edilen özelliklerin sınıflandırılması sonucu ön tanı program çıktıları verilmektedir.

| 29         | CHI KARESİ | EUCLIDEAN | MANHATTAN | CHEBSHEV | Orjinal                                                                             | LBP                                                                                 |
|------------|------------|-----------|-----------|----------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
| AKROMEGALİ | 92         | 149       | 6519      | 22       |  |  |
| DİĞER      | 93         | 158       | 6667      | 30       |                                                                                     |                                                                                     |
| DOWN       | 93         | 153       | 6753      | 23       |                                                                                     |                                                                                     |
| LUPUS      | 86         | 136       | 5897      | 20       |                                                                                     |                                                                                     |
| NORMAL     | 95         | 160       | 6803      | 21       |                                                                                     |                                                                                     |
|            |            |           |           |          | ORİJİNAL:                                                                           | LUPUS                                                                               |
|            |            |           |           |          | SONUÇ:                                                                              | LUPUS                                                                               |

| 40         | CHI KARESİ | EUCLIDEAN | MANHATTAN | CHEBSHEV | Orjinal                                                                               | LBP                                                                                   |
|------------|------------|-----------|-----------|----------|---------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------|
| AKROMEGALİ | 95         | 211       | 7424      | 32       |  |  |
| DİĞER      | 101        | 225       | 7822      | 34       |                                                                                       |                                                                                       |
| DOWN       | 96         | 210       | 7380      | 31       |                                                                                       |                                                                                       |
| LUPUS      | 99         | 222       | 7714      | 32       |                                                                                       |                                                                                       |
| NORMAL     | 91         | 197       | 6926      | 29       |                                                                                       |                                                                                       |
|            |            |           |           |          | ORİJİNAL:                                                                             | NORMAL                                                                                |
|            |            |           |           |          | SONUÇ:                                                                                | NORMAL                                                                                |


  

| 21         | CHI KARESİ | EUCLIDEAN | MANHATTAN | CHEBSHEV | Orjinal                                                                               | LBP                                                                                   |
|------------|------------|-----------|-----------|----------|---------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------|
| AKROMEGALİ | 103        | 213       | 7985      | 34       |  |  |
| DİĞER      | 105        | 214       | 7973      | 34       |                                                                                       |                                                                                       |
| DOWN       | 91         | 193       | 7131      | 29       |                                                                                       |                                                                                       |
| LUPUS      | 102        | 215       | 7995      | 35       |                                                                                       |                                                                                       |
| NORMAL     | 104        | 220       | 8033      | 36       |                                                                                       |                                                                                       |
|            |            |           |           |          | ORİJİNAL:                                                                             | DOWN                                                                                  |
|            |            |           |           |          | SONUÇ:                                                                                | DOWN                                                                                  |

Şekil 2.13. Sınıflandırma sonuçları


#### 2.1.2.2. Temel Bileşen Analizi

TBA algoritmasının yüz görüntülerine uygulanışı eğitim ve test olarak iki aşamada verilecektir. Şekil 2.14' de algoritmanın eğitim kısmının akış diyagramı verilmektedir.



Şekil 2.14. TBA eğitim algoritması aşamaları

Akış diyagramından da görüldüğü üzere öncelikle eğitim görüntüleri eğitim matrisine dönüştürülür. Bunun için her bir eğitim görüntüsünün satırları birbiri ardına eklenerek bir sütun vektörüne dönüştürülmekte ve sütun vektörü haline dönüştürülmüş görüntüler birleştirilerek eğitim matrisi  $X$  elde edilmektedir. Çalışmada 5 sınıf için  $256 \times 256$  boyutunda 100 eğitim örneği kullanılmıştır. Dolayısıyla  $X$  eğitim matrisinin boyutu  $65536 \times 100$  olmaktadır. Şekil 2.15’ de TBA’ da eğitim görüntülerinden eğitim matrisinin oluşturulması gösterilmektedir.



Şekil 2.15. Eğitim matrisinin oluşturulması

Eğitim matrisi  $X$  oluşturulduktan sonra bu matrisin ortalaması  $\mu$  hesaplanır ve hesaplanan ortalama vektörü, her bir eğitim vektöründen çıkarılarak sıfır ortalamalı yeni eğitim veri matrisi  $A$  elde edilir.  $\mu$  matrisinin boyutu  $65536 \times 1$  olmaktadır. Şekil 2.16’ da çalışmada elde edilmiş ortalama yüz  $\mu$  verilirken, Şekil 2.17’ de eğitim görüntüsünden ortalama yüz çıkarılarak elde edilen örnek bir yüz görüntüsü verilmiştir.

$$\mu = \frac{1}{100} * X =$$



Şekil 2.16. Ortalama yüz



Şekil 2.17. Eğitim görüntüsünden ortalama yüzün çıkarılması

Şekil 2.17’ de olduğu gibi 100 eğitim görüntüsü için aynı işlem tekrarlanarak  $A$  matrisinin sütunları oluşturulmaktadır.

Bir sonraki aşama olarak  $A^T * A$  işlemi ile kovaryans matrisi  $C$  oluşturulmakta ve  $C$ ’ nin özdeğerleri ve onlara karşılık gelen özvektörleri hesaplanmaktadır.  $C$ ’ nin boyutu  $100 \times 100$  dür. Dolayısıyla  $C$ ’nin özvektör matrisi de özvektörleri sütunlarında taşıyan  $100 \times 100$  lük bir matris olacaktır. Dolayısıyla toplamda 100 Özyüz, temel bileşen elde edilmiştir. Şekil 2.18’ de çalışmada elde edilen Özyüzlerden ilk yirmi tanesi verilmektedir.




Şekil 2.18. Özyüzler

Elde edilen temel bileşenler seçilerek, hepsi izdüşümde kullanılmamaktadır. Temel bileşen seçiminde, temel bileşenin taşıdığı bilgi miktarının özdeğeri ile ilişkili olmasına dayanarak, öncelikle elde edilen özdeğerler azalan sırada sıralanmıştır. Her bir temel bileşenin özdeğeri için toplam varyansın yüzde kaçını kapsadığı hesaplanarak, toplamına bakıldığında %99 ve üstü değere denk gelen temel bileşen sayısı, optimal temel bileşen sayısı olarak alınmıştır. %99 değeri, %90-%100 arası değerler test edilerek en iyi tanıma performansı elde edilen değerdir. Çalışmada 100 temel bileşen arasından %99 ve üstü değere denk gelen temel bileşen sayısı 90 olarak elde edilmiştir.


Temel bileşenlerin seçiminde bu yöntem yanında döküntü grafiği, ortalama kök yöntemleri de kullanılmıştır. Ortalama kök yönteminde öz değerlerin ortalamasından daha yüksek değere sahip olan bileşenler alınmıştır. Çalışmada bu 100 temel bileşenden 21'ine karşılık gelmektedir.

Döküntü grafiği yönteminde ise x eksenini temel bileşenleri ve y eksenini özdeğerleri gösteren döküntü grafiği çizilmiştir. Grafiğin büküm noktası optimal temel bileşen sayısı olarak alınmıştır. Şekil 2.19' dan da görüldüğü üzere büküm noktası, azalan sıradaki ilk 10 temel bileşene karşılık gelmektedir.



Şekil 2.19. Döküntü grafiği

Çalışmada özdeğerlerine göre sıralanan ilk 90 temel bileşen (özvektör) ile G iz düşüm matrisi oluşturulmuştur. Seçilen özvektörler, matrisin satırlarını oluşturacak şekilde G izdüşüm matrisi oluşturulmaktadır. G'nin boyutu 65536x90 olmaktadır. Elde edilen azalan sıradaki ilk 90 temel bileşenden 10 tanesi Şekil 2.20' de verilmektedir.



Şekil 2.20. Kümülatif toplam ile seçilen özyüzler

Son aşama olarak  $G$  izdüşüm matrisinin transpozu ile görüntü vektörü çarpılarak  $W$  matrisi elde edilmekte ve tüm eğitim görüntüleri özyüz uzayına izdüşürülmüş olmaktadır. Şekil 2.21’ de örnek bir eğitim görüntüsünün izdüşümü gösterilmiştir. Özyüz uzayına izdüşürülmeden önce her bir görüntü 65536 ( $256 \times 256$ ) boyutlu uzayda bir nokta olarak temsil edilmekteydi. TBA kullanıldığında veri boyutu çok büyük bir oranda indirgenerek, görüntüler 90 boyutlu özyüz uzayında temsil edilmişlerdir.

$$G^T \times X = W(:,i)$$

|                   |
|-------------------|
| 1636.83912408854  |
| -2534.51703309259 |
| 2594.54818180808  |
| 587.969204533686  |
| -10038.8431421251 |
| 5433.53984164658  |
| -988.261216965219 |
| -2477.48379495990 |
| -4793.58429013337 |
| -1915.62746496239 |

Şekil 2.21. Görüntünün özyüz uzayına izdüşümü

Burada  $W(:,i)$ ,  $W'$ ’nin  $i$ . sütununu ifade etmektedir. Görüntülerin özuzaya izdüşürülmüş formlarını sütunlarında tutan  $W$  matrisi  $90 \times 100$  boyutunda bir matrisdir.  $W'$ ’nin elde edilmesi ile birlikte tüm eğitim görüntüleri özyüz uzayına izdüşürülmüş ve eğitim aşaması tamamlanmıştır.

Test aşamasında ise giriş olarak verilen test resminden öncelikle eğitim aşamasında hesaplanan ortalama yüz değeri çıkarılır. Ve yine eğitim aşamasında elde edilen  $G$  izdüşüm matrisiyle test görüntüsüne de özyüz uzayına izdüşürülür.

Özyüz uzayına taşınan görüntüler, dönüşüm işlemindeki adımların tersi uygulandığında çok küçük bir hata ile orjinal haline getirilmektedir. TBA bu özelliği ile görüntü sıkıştırma amaçlı da kullanılmaktadır. Özyüz uzayındaki görüntüden orjinal görüntüyü elde etmek için

tersden gidersek, dönüşüm işlemindeki en son aşama, yani  $W$  matrisinin elde edilmesinden başlanılmaktadır.  $W$  matrisinin elde edilmesine bakacak olursak;

$$W = G^T * A \quad (2.1)$$

Amaç  $W$  bilinyorken  $A'$  yı elde etmektir. Bunun için eşitliğin her iki tarafı  $(G^T)^{-1}$  çarparsak;

$$A = (G^T)^{-1} * W \quad (2.2)$$

elde edilir.  $G$  dönüşüm matrisi ortogonal olduğu için tersi transpozuna eşittir. Tersine yerine transpozunu alırsak  $A$  matrisinin son hali eşitlik (2.3) elde edilmektedir.

$$A = G * W \quad (2.3)$$

Şekil 2.22' de örnek olarak eğitim görüntülerinden birinde (2.3) eşitliğinin uygulanışı verilmektedir.

The diagram illustrates the transformation equation  $A = G * W$ . Matrix  $A$  is a single face image. Matrix  $G$  is a 9x10 grid of face images. Matrix  $W$  is a 90x1 column vector of numerical values. The diagram shows the multiplication of  $G$  and  $W$  to produce  $A$ .


Matrix  $W$  values (90x1):

|                   |
|-------------------|
| 14671.1555203398  |
| 1765.48743786250  |
| -5911.45825583894 |
| 273.506155187555  |
| -2035.61763083301 |
| -4590.28639490689 |
| 990.998146408844  |
| 2709.96384213879  |
| 861.056304460879  |
| -102.021000930073 |

Matrix dimensions:  $65536*90$  for  $G$ ,  $90*1$  for  $W$ .


Şekil 2.22. TBA' dan geri dönüşüm işlemi ile  $A'$  nın elde edilmesi

Eğitim görüntülerinden, ortalama yüz çıkartılarak sıfır ortalamalı eğitim matrisi A elde edilmişti. Dolayısıyla tekrar orjinal eğitim görüntülerini elde edebilmek için A matrisine ortalama yüz eklenir. Şekil 2.23' de, Şekil 2.22' de elde edilen A'ya ortalama yüzün eklenerek orjinal eğitim görüntüsünün elde edilmesi verilmektedir.



Şekil 2.23. Orjinal görüntünün elde edilmesi

Şekil 2.23' den görüldüğü üzere A matrisi ile ortalama yüzün toplamından elde edilen yüz ile orjinal yüz farklıdır. Bu farklılık, izdüşüm aşamasında temel bileşenlerin hepsinin kullanılmamasından ileri gelmektedir. Elde edilen temel bileşenlerin tamamının kullanılması durumunda oluşan görüntü orjinal görüntünün aynısı olacaktır. Şekil 2.24' de kullanılan temel bileşen sayısına göre elde edilen görüntüler verilmektedir.



Şekil 2.24. Farklı sayılardaki temel bileşenle oluşturulan görüntüler

Kullanılan sıralı temel bileşen sayısı arttıkça elde edilen görüntü orjinal görüntüye yaklaşımaktadır.

### 2.1.2.2.3. TBA ile Elde Edilen Özelliklerin Sınıflandırılması


Eğitim ve test görüntüleri TBA ile yeni bir altuzaya izdüşürüldükten sonra test görüntülerin hangi sınıfa ait olduğunu öğrenmek için Öklit, Manhattan uzaklıkları ve Kosinüs benzerliği ile birlikte NN sınıflandırıcısı kullanılmaktadır. Yalnız burada YİÖ' lerde olduğu gibi test görüntüsü ile sınıf ortalamaları arasındaki uzaklık yerine, test görüntüsü ile her bir eğitim görüntüsü arasındaki uzaklığa bakılmaktadır. Çünkü TBA' da sınıf bilgisi yoktur. Daha sonrada test görüntüsü, en yakın olduğu eğitim görüntüsünün sınıfına dahil edilmektedir. Şekil 2.25' de Öklit uzaklığı ile birlikte NN sınıflandırıcısı kullanılarak program sonucunda eşleşen test- eğitim görüntülerinin bir kısmı verilmiştir.



Şekil 2.25. Eşleşen test-eğitim görüntüleri


### 2.1.2.3. Doğrusal Ayırıcı Analizi

Giriş kısmında verilen DAA algoritmasının yüz görüntülerine uygulanışı verilecektir. Şekil 2.26' da DAA yönteminin eğitim aşamasının akış diyagramı verilmektedir.



Şekil 2.26. DAA eğitim algoritması aşamaları


Akış diyagramından da görüldüğü üzere DAA algoritmasında, TBA' da olduğu gibi öncelikli olarak eğitim matrisi oluşturulmaktadır. Yalnız DAA' da TBA'dan farklı olarak sınıf bilgisi mevcuttur. Yani eğitim matrisi oluşturulurken, TBA' da her bir eğitim görüntüsünün satırları birbiri ardına eklenerek bir sütun vektörüne dönüştürüldükten sonra sütun vektörü haline dönüştürülmüş görüntüler herhangi bir sıralama yapılmadan birleştirilerken, DAA' da sütun vektörüne dönüştürülmüş görüntüler sıralı birleştirilmektedir. Çalışmada eğitim matrisi X' in sütunlarının ilk 20' si Akromegali, 21 ile 40 arası Down sendromu, 41 ile 60 arası Lupus, 61 ile 80 arası sağlam, 81 ile 100 arası diğer sınıf olmak üzere 32x32 boyutunda yüz görüntülerinden oluşmaktadır. Şekil 2.27' de DAA'da eğitim görüntülerinden eğitim matrisinin elde edilişi verilmektedir.



Şekil 2.27. Eğitim matrisinin oluşturulması

Eğitim matrisi  $X$ 'in boyutu  $1024 \times 100$  olmaktadır.  $X$  oluşturulduktan sonra sınıf içi saçılım matrisi  $S_W$  oluşturulmaktadır.  $S_W$  oluşturulurken her bir sınıf için ortalama hesaplanarak, ortalama yüzler elde edilir. Ortalama yüzün hesaplanması (2.4) eşitliğinde, her sınıfın ortalama yüzü Şekil 2.28' de verilmektedir.

$$\mu_{ci} = \frac{1}{n_i} \sum_{k=1}^{n_i} x_k \quad (2.4)$$



Şekil 2.28. (a) Akromegali (b) Down sendromu (c) Lupus (d) Sağlam (e) Diğer sınıf ortalama yüzü  $\mu_{ci}$

Burada  $n_i$  her bir sınıftaki görüntü sayısı olup 20' ye eşittir ve ortalama yüz matrisi  $\mu_{ci}$ 'nin boyutu  $1024 \times 1$ ' dir. Elde edilen ortalama yüzler o sınıfa ait görüntülerden çıkarılarak sıfır ortalama eğitim matrisi elde edilmektedir. En son aşama olarak her sınıf için sıfır ortalama eğitim matrislerinin kovaryansı alınarak, toplanmasıyla  $S_W$  matrisi oluşturulur.  $S_W$  matrisinin hesaplanması eşitlik (2.5) ve (2.6)' de verilmektedir.


$$S_i = \sum_{x \in X_i} (x - \mu_{ci})(x - \mu_{ci})^T \quad (2.5)$$

$$S_w = \sum_{i=1}^C S_i \quad (2.6)$$

Burada C sınıf sayısı olup 5' e eşittir.  $S_i$  i. sınıfın sınıf içi saçılım matrisini ifade etmektedir. Sınıf içi saçılım matrisi  $S_w$ ' nin boyutu 1024x1024 olmaktadır. Sınıf içi saçılım matrisi hesaplandıktan sonra sınıflar arası saçılım matrisi  $S_B$  hesaplanmaktadır.  $S_B$ ' nin elde edilişi (2.7) eşitliğinde verilmektedir.

$$S_B = \sum_{i=1}^C n_i (\mu_{ci} - m)(\mu_{ci} - m)^T \quad (2.7)$$

Burada m tüm eğitim görüntülerinin ortalamasını ifade etmektedir. Şekil 2.29' da sınıf ortalama yüzlerinin, eğitim görüntülerinin ortalamasından çıkarımı verilmektedir.




Şekil 2.29. Ortalama yüzlerden ortalamanın çıkarılması

Şekil 2.29' deki gibi ortalama yüzlerden ortalamanın çıkarılması ile elde edilen matris ile transpozu ve sınıftaki görüntü sayısı çarpılırsa  $S_B$  matrisi elde edilmektedir.  $S_B$ ' nin boyutu  $1024 \times 1024$  olmaktadır.

Eğitim görüntülerini alt uzaya izdüşürecek izdüşüm matrisini bulmak için  $S_w^{-1} \times S_B$  matrisinin özvektörleri hesaplanmaktadır. Ancak görüntü uzayı boyutu 1024 iken eğitimde kullanılan görüntü sayısı 100 tanedir. Örnek uzayı boyutunun örnek sayısından çok büyük olması nedeniyle  $S_w$  matrisi tekil matris olmakta ve tersi alınamamaktadır. Tersinin alınabilmesi için  $S_w$  matrisi düzenlenilmektedir. Bunun için (2.8) eşitliği kullanılmaktadır.

$$S_W' = S_W + \beta I \quad (2.8)$$

Burada  $S_W'$ ,  $S_W'$  nin düzenleniştirilmiş halidir.  $\beta$  parametresi ise  $S_W$  matrisinin 0.01 sabiti ile çarpılmasıyla elde edilen matrisin köşegen elemanlarının ortalaması olarak alınmıştır. Bu yöntemle yeni sınıf içi saçılım matrisi  $S_W'$  tekil olmamakta ve tersi alınmaktadır.  $S_W^{-1} * S_B$  matrisinin özvektörleri fisheryüzlere karşılık gelmektedir. Şekil 2.30' da özdeğerlerine göre azalan sırada sıralanmış özvektörlerden (fisheryüzler) ilk 12 tanesi verilmektedir.



Şekil 2.30. Sıralı ilk 12 Fisheryüz

Şekil 2.30' dan da görüldüğü üzere ilk 4 özvektörden sonraki özvektörlerin taşıdığı bilgi miktarı azalmaktadır. Bu özvektörlerin yaklaşık sıfıra yakın değerleri vardır. Bu nedenle özvektörler, özdeğerlerine göre azalan sırada sıralandıktan sonra ilk 4 (C-1) tanesi alınmaktadır. Seçilen özvektörler matrisin satırlarını oluşturacak şekilde G izdüşüm matrisi oluşturulmakta ve matris boyutu 1024x4 olmaktadır.

TBA' da da olduğu gibi son aşama olarak elde edilen G izdüşüm matrisinin transpozu ile görüntü vektörü çarpılarak W matrisi elde edilmekte ve tüm eğitim görüntüleri fisheryüz uzayına izdüşürülmüş olmaktadır. Şekil 2.31' de örnek olarak eğitim görüntülerinin birinin izdüşümü gösterilmiştir.

$$G^T \times X = W(:, i)$$

The diagram shows a vertical stack of four grayscale face images labeled  $G^T$  on the left. In the center is a single grayscale face image labeled  $X$ . To the right of  $X$  is a circle containing a cross symbol  $\otimes$ . Further right is an equals sign  $=$ , followed by a vertical column vector labeled  $W(:, i)$  containing four numerical values:

$$\begin{bmatrix} 130.707722763820 \\ -139.264754649169 \\ -160.247982913056 \\ -138.306809473875 \end{bmatrix}$$

Şekil 2.31. Görüntünün Fisheryüz uzayına izdüşümü

Burada  $W(:,i)$ ,  $W'$  'nün  $i$ . sütununu ifade etmektedir. Görüntülerin fisheryüz uzayına izdüşürülmüş formlarını sütunlarında tutan  $W$  matrisi  $4 \times 100$  boyutundadır. Görüntülerin hepsinin fisheryüz uzayına izdüşürülmesiyle birlikte eğitim aşaması tamamlanmaktadır. Test aşamasında da verilen giriş görüntüsü  $G$  izdüşüm matrisiyle fisheryüz uzayına izdüşürülmektedir.

DAA uygulanmasıyla birlikte görüntüler 1024 ( $32 \times 32$ ) boyutlu uzaydan 4 boyutlu fisheryüz uzayına izdüşürülmüştür. Böylece veri boyutu çok büyük bir oranda indirgenerek güçlü bir veri ayrıştırması yapılmıştır.

#### 2.1.2.3.1. DAA ile Elde Edilen Özelliklerin Sınıflandırılması

YİÖ' llerde olduğu gibi DAA' da da eğitim görüntülerinin özellik vektörleri elde edildikten sonra, sınıflardaki görüntülerin özelliklerinin ortalaması alınarak her sınıf için tek bir özellik vektörü elde edilmiştir. Test görüntüsünün özellik vektörü ile sınıfların ortalama özellik vektörleri arasındaki Öklit, Manhattan uzaklıklarına ve Kosinüs benzerliğine bakılarak

test görüntüsü NM sınıflandırıcısına göre sınıflandırılmaktadır. Şekil 2.32’ de Öklit uzaklığı ile birlikte NM sınıflandırıcısı kullanılarak test görüntülerinin sınıflandırma sonuçları verilmektedir.

#### PROGRAM SONUCU- GERÇEK DURUM




Şekil 2.32. DAA ile sınıflandırma sonuçları

#### 2.1.2.4. Alt Uzak Doğrusal Ayrıştırıcı Analizi

Önceki bölümde DAA’ nın görüntülere uygulanışı verilmiştir. DAA’ da karşılaşılan en büyük problem örnek uzayı boyutunun örnek sayısından çok büyük olması nedeniyle sınıf içi saçılım matrisinin tersinin alınamamasıdır. Saçılım matrisinin tersinin alınabilmesi için düzenleme yöntemi uygulanmış ancak koşma zamanı ve görüntü boyutu açısından istenilen sonuca ulaşılamamıştır. Bunun için bir başka çözüm olarak Alt uzak Doğrusal Ayrıştırıcı Analizi yöntemi uygulanmıştır.

Alt uzak DAA yönteminin akış diyagramı Şekil 2.33’ de verilmektedir.



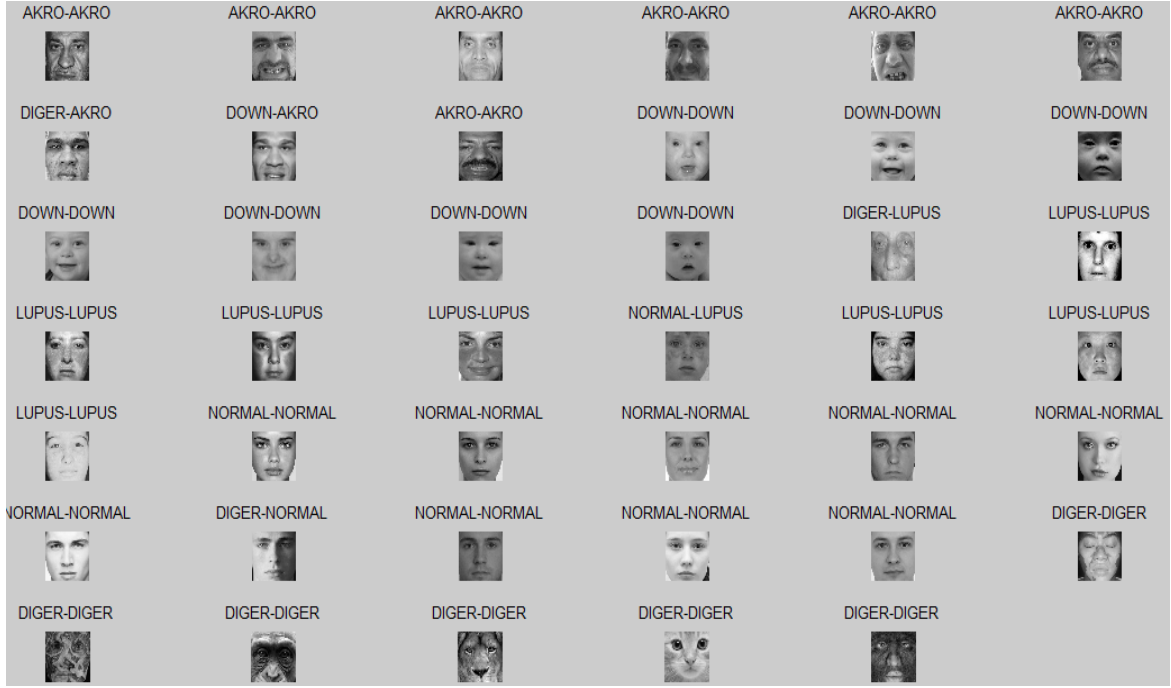
Şekil 2.33. Alt uzay Doğrusal Ayrıştırıcı Analizi

Bu yöntemde eğitim matrisi  $X$  oluşturulurken DAA’ da olduğu gibi sütun vektörüne dönüştürülmüş görüntüler sıralı birleştirilmektedir. Ancak eğitim görüntüleri DAA’dan farklı olarak  $256 \times 256$  boyutundadır. Dolayısıyla  $X$  matrisinin boyutu  $65536 \times 100$  olmaktadır. Eğitim matrisi oluşturulduktan sonra görüntülere öncelikle TBA yöntemi uygulanarak boyut indirgemesi yapılmaktadır. Önceki bölümde adım adım verilen TBA yönteminin uygulanması sonucunda  $65536 \times 100$  boyutlu eğitim matrisi  $X$ ,  $90 \times 100$  boyutlu bir matrise indirgenmiştir.

Verilerin TBA ile boyut indirgemesi ardından DAA yöntemi uygulanmaktadır. DAA yönteminde eğitim matrisi olarak TBA sonucunda indirgenen  $90 \times 100$  boyutundaki matris alınmaktadır. Böylece sınıf içi saçılım matrisi  $90 \times 90$  boyutunda bir matris olup tekil olmaması garantilenmektedir.

#### 2.1.2.4.1. Alt uzay DAA ile Elde Edilen Özelliklerin Sınıflandırılması

Alt uzay DAA ile çıkarılan özelliklerin sınıflandırmasında NM sınıflandırıcısı kullanılmıştır. Şekil 2.34’ de Öklit uzaklığı ile birlikte NM sınıflandırıcısı sonuçları verilmektedir.




Şekil 2.34. Alt uzay DAA ile sınıflandırma sonuçları

### 2.1.3. Test Aşaması Sonuçları ve Karşılaştırmalar

Yüzden hastalık teşhisi üzerine yapılan çalışmada çeşitli testler yapılmış ve karşılaştırmalı sonuçları aşağıda verilmiştir.


#### 2.1.3.1. Farklı YİÖ ve İYİÖ Operatörlerinin Kullanılması

Farklı YİÖ operatörlerinin karşılaştırıldığı testte, kullanılan sınıflandırıcılara göre sistemin 41 test görüntüsünü tanıma oranları verilmiştir. Bu testin karşılaştırmalı sonuçları Şekil 2.35’ de verilmektedir.



Şekil 2.35. Farklı YİÖ operatörlerin sınıflandırıcılara göre tanıma oranları

Sonuçlar incelendiğinde Chi karesi, Manhattan ve Chebyshev sınıflandırıcılarında YİÖ(8,1) operatörü YİÖ(8,2) ve YİÖ(16,2) operatörlerine göre daha iyi tanıma performansı verirken, Öklit sınıflandırıcısında YİÖ(8,1) ve YİÖ(8,2) operatörleri aynı tanıma oranı vermiştir. Aynı test İYİÖ'nün farklı operatörleri için de uygulanmıştır. Test sonuçları Şekil 2.36' de verilmektedir.




Şekil 2.36. Farklı İYİÖ operatörlerin sınıflandırıcılara göre tanıma oranları

Şekilden de görüldüğü üzere YİÖ' de olduğu gibi Chi karesi, Manhattan ve Chebyshev sınıflandırıcılarında İYİÖ(8,1) operatörü, İYİÖ(8,2) operatörüne göre daha yüksek tanıma oranı vermiştir. Öklit sınıflandırıcısında ise İYİÖ(8,2) operatöründen İYÖ(8,1)' e göre daha çok başarı elde edilmiştir.

### 2.1.3.2. MSYİÖ' de Eşik Değerinin Belirlenmesi


T. Mäenpää ve M. Pietikäinen, çeşitli performans testleri sonucunda MSYİÖ için en iyi eşik değerinin  $T=0.01$  olarak belirlemişlerdir [76]. Bununla birlikte bir başka çalışmada en iyi T değeri 0.02 bulunmuştur [77]. Bunun için 0.00 - 0.09 arasındaki T değerlerine bakılarak en yüksek doğruluk değeri veren T değeri, eşik değeri olarak alınmıştır. Şekil 2.37' de MSYİÖ(8,1) için seçilen T değerine göre sınıflandırıcıların doğruluk değerleri verilmektedir.



Şekil 2.37. MSYİÖ(8,1) için T değerine göre sınıflandırıcıların doğruluk değerleri

Şekil 2.37' e göre MSYİÖ(8,1) için en yüksek doğruluk değeri  $T=0.07$  alınarak Chi karesi sınıflandırıcısı ile elde edilmiştir. Diğer sınıflandırıcılar için en iyi eşik değeri ise Öklit

için  $T=0.08$ , Manhattan için  $T=0.06$  veya  $T=0.07$  ve Chebyshev için  $T=0.02$  belirlenmiştir. Aynı test MSYİÖ(8,2) için de tekrarlanmıştır. Test sonuçları Şekil 2.38’ de verilmektedir.




Şekil 2.38. MSYİÖ(8,2) için T değerine göre sınıflandırıcıların doğruluk değerleri

MSYİÖ(8,2) için sonuçlar incelendiğinde ise en yüksek doğruluk değeri  $T=0.09$  alınarak Manhattan sınıflandırıcısı ile elde edilmiştir. Diğer sınıflandırıcılar için belirlenen en iyi eşik değeri ise Öklit  $T=0.08$  veya  $T=0.09$ , Chi karesi  $T=0.09$  ve Chebyshev  $T=0.01$  dir.

### 2.1.3.3. Chi Karesinde Ağırlık Matrisinin Seçimi

Genel bilgiler kısmında da verildiği gibi görüntünün YİÖ kodunu çıkarıldıktan sonra, görüntü alt bölgelere ayrılıp her bir bölgenin histogramı çıkarılmaktadır. Elde edilen histogramlar birleştirildiğinde ise görüntü için özellik vektörü elde edilmektedir. Bu özellikler çıkarılırken Chi Karesinde, diğer sınıflandırıcılardan farklı olarak alt bölgelere ayrılmış görüntüde her bir bölgeye önem derecesine göre bir katsayı verilerek bir ağırlık matrisi (maske) oluşturulmaktadır. Her bir bölge için en iyi katsayıları belirleyebilmek adına öncelikle  $7 \times 7$ ’ lik alt bölge boyutunun T.Ahonen tarafından görüntü tanımda, en iyi boyut olarak


belirlenmesi [78] üzerine görüntüler önce 7x7' lik alt bölgelere ayrılmıştır. Ve literatürde yüz tanıma amaçlı kullanılan maskeler ve yüz bölgelerinin önem derecesine göre oluşturulan maske kombinasyonları denenerek hastalık tanımda en iyi performans veren maske oluşturulmuştur. Şekil 2.39' da kullanılan 7x7' lik maskeler verilmektedir.



Şekil 2.39. Kullanılan 7x7' lik maskeler

Sistem beş sınıf içermektedir. Mask1 bütün sınıflara uygulanırken, Mask2.1 Akromegali, Mask2.2 Lupus, Mask2.3 Down sendromu, Mask2.4 Sağlam ve Mask2.5 Diğer sınıfına uygulanmıştır. Mask2 oluşturulurken Akromegali sınıfında ağız ve burun, Lupus sınıfında yanak ve Down sendromu sınıfında gözler ve arasındaki bölgeler yüzün diğer

bölgelerine daha önemli oldukları için bu bölgelere daha yüksek katsayı verilmiştir. 7x7' lik maskelerin yanında 10x10' luk maske kombinasyonları da oluşturulmuştur. Şekil 2.40' de 10x10' luk maskeler verilmiştir.



Şekil 2.40. Kullanılan 10x10' luk maskeler

Şekil 2.39 ve Şekil 2.40' deki maskelerin kullanılması elde edilen sınıflandırıcı doğrulukları Tablo 2.1' de verilmektedir.

Tablo 2.1. Maskelere göre sınıflandırıcıların doğruluk değerleri

|           | Chi Karesi | Öklit | Manhattan | Chebyshev |
|-----------|------------|-------|-----------|-----------|
| Mask1[79] | 85         | 80    | 85        | 58        |
| Mask2     | 80         | 80    | 85        | 58        |
| Mask3     | 85         | 87    | 82        | 58        |
| Mask4     | 92         | 87    | 82        | 58        |


Öklit, Manhattan ve Chebyshev sınıflandırıcılarında ağırlık matrisi uygulanmamıştır. Yalnızca maske boyutuna göre alt bölge ayrımı yapılmıştır.

Sonuçlar incelendiğinde Mask4 ile Chi Karesinden en yüksek tanıma oranı elde edilmiştir. Öklit sınıflandırıcısı 10x10' luk alt bölge ayrımında 7x7'lik alt bölge ayrımına göre daha yüksek performans gösterirken, Manhattan sınıflandırıcısında tam tersi durum

görülmüştür. Chebyshev sınıflandırıcısında ise alt bölge sayısına bağlı olarak doğruluk değerinde herhangi bir değişiklik gözlenmemiştir.

#### 2.1.3.4. Farklı Sayıdaki Özvektörlerin Kullanımı

TBA ve TBA+DAA ile yapılan bu testte farklı sayıdaki özvektörlerin tanıma performansına etkisi incelenmiştir. Şeki 2.41’ de test sonuçları görülmektedir.



Şekil 2.41. Farklı sayıdaki özvektörlerin tanıma performansına etkisi

Şekil 2.41’ den de görüldüğü üzere Özyüz uzayı küçük olduğunda (1-4), TBA, TBA+DAA’ dan daha iyi performans gösterirken, Özyüz uzayı büyüdüğünde ise TBA+DAA, TBA’ dan daha iyi performans göstermektedir. Çünkü 1-4 arasındaki özvektörler 5 sınıfı doğrusal olarak ayıramamaktadır. Bu nedenle kullanılacak özvektörlerin sayısı, eğitimde kullanılan sınıfları ayırabilecek şekilde seçilmesi gerekmektedir.

### 2.1.3.5. TBA’ da Temel Bileşenlerin Seçilmesi

TBA ile yapılan bu testte Kümülatif Toplam, Ortalama Kök, Döküntü Grafiği yöntemleri kullanılarak elde edilen temel bileşen sayısına göre tanımadaki başarılar verilmiştir. Sınıflandırma yöntemi olarak Öklit sınıflandırıcısı kullanıldığı bu testin sonuçları Tablo 2.2’ de verilmektedir.

Tablo 2.2. Temel Bileşen seçimi yöntemlerinin tanıma yüzdesi

| Yöntem           | Temel Bileşen Sayısı | Seçilen Temel Bileşen Sayısı | Tanıma Yüzdesi |
|------------------|----------------------|------------------------------|----------------|
| Kümülatif Toplam | 100                  | 90                           | 73.1707        |
| Ortalama Kök     | 100                  | 21                           | 68.2927        |
| Döküntü Grafiği  | 100                  | 10                           | 70.7317        |

Tablo 2.2’ den de görüldüğü üzere özdeğerlerine göre azalan sırada sıralanmış 100 temel bileşenden ilk 90’ ı alındığında en yüksek tanıma yüzdesi elde edilmiştir.

### 2.1.3.6. Ön İşlemler

Eğitim ve test görüntülerine uygulanan ön işlemlerden histogram eşitlemenin tanıma performansını nasıl değiştirdiği gözlemlenmiştir. Bu test için TBA ve TBA + DAA yöntemi kullanılmıştır. Test sonuçları Tablo 2.3’ de verilmektedir.

Tablodaki 10 özvektör döküntü grafiği, 90 özvektör ise kümülatif toplam sonucunda elde edilmiştir.

Sonuçlar incelendiğinde histogram eşitleme sonucunda hem TBA hem de TBA + DAA da performans artışı gözlemlenmiştir. Bunun sonucunda TBA ve TBA+DAA için azalan sırada sıralanmış kümülatif toplam ile elde edilen 100 temel bileşenin 90’ ı alınmıştır. Bu sonucu Şekil 2.41’ de desteklemektedir.

YİÖ için ön işlem olarak histogram eşitleme yapılmamıştır. Çünkü YİÖ yöntemi ışık kaynağının şiddetindeki değişimlerden bağımsız bir yöntemdir.

Tablo 2.3. Histogram eşitlemenin başarı oranına etkisi

| <b>Yöntem</b>    | <b>Histogram Eşitleme</b> | <b>Kullanılan Özvektör</b> | <b>Tanım oranı</b> |
|------------------|---------------------------|----------------------------|--------------------|
| TBA              | Yok                       | 10                         | 43.9024            |
| TBA              | Var                       | 10                         | 70.7317            |
| <b>TBA</b>       | <b>Var</b>                | <b>90</b>                  | <b>73.1707</b>     |
| TBA              | Yok                       | 90                         | 43.9024            |
| TBA + DAA        | Yok                       | 10                         | 68.2927            |
| TBA + DAA        | Var                       | 10                         | 80.4878            |
| <b>TBA + DAA</b> | <b>Var</b>                | <b>90</b>                  | <b>87.8049</b>     |
| TBA + DAA        | Yok                       | 90                         | 80.4878            |

#### 2.1.3.7. Farklı Boyuttaki Görüntülere DAA Uygulanması

DAA' da görüntü boyutunun artmasına bağlı olarak sınıf içi saçılım matrisinin ( $S_w$ ) boyutu artmakta dolayısıyla tersinin alınabilmesi zorlaşmaktadır. Bunun için en ideal görüntü boyutu ve koşum zamanı için yapılan testin sonuçları Tablo 2.4' de verilmektedir.

Tablo 2.4. DAA için farklı görüntü boyutlarındaki tanıma oranı

| <b>Görüntü boyutu</b> | <b>Örnek uzayı boyutu</b> | <b>Koşum zamanı</b> | <b>Tanım oranı</b> |
|-----------------------|---------------------------|---------------------|--------------------|
| 64x64                 | 4096                      | 143.02 sn           | 78.0488            |
| 32x32                 | 1024                      | 16. 234 sn          | 80.4878            |
| 16x16                 | 256                       | 14.139 sn           | 65.8537            |

Tablo 2.4' den de görüldüğü üzere 32x32 boyutundaki görüntülerin kullanılması sonucunda kabul edilebilir bir koşum zamanı ile en yüksek tanıma oranı elde edilmiştir.

### 2.1.3.8. Hastalıkları Göre Sınıflandırıcı Performanslarının Değerlendirilmesi

Sistemde Akromegali, Down sendromu ve Lupus olmak üzere üç hastalık tanımlanmıştır. Ve bu hastalıkların teşhisinde kullanılan özellik çıkarım algoritmalarına göre sınıflandırıcıların duyarlılık (TPF), özgüllük (1-FPF), pozitif tahmin değeri (PPV) hesaplanmıştır. 41 test görüntüsü içerisinde 9 Akromegali, 6 diğer, 7 Down sendromu, 9 Lupus ve 10 Sağlam görüntü mevcuttur. Her bir hastalık için sınıflandırıcıların performansları hesaplanırken, hangi hastalık değerlendiriliyorsa o hastalık dışındaki görüntüler hasta olmayan görüntüler olarak nitelendirilmiştir. Aşağıdaki tablolarda sonuçlar görülmektedir.

Tablo 2.5. Akromegali teşhisinde YİÖ(8,1), YİÖ(8,2) ve YİÖ(16,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                   | YİÖ (8,1) |       |     | YİÖ (8,2) |       |     | YİÖ (16,2) |       |     |
|-------------------|-----------|-------|-----|-----------|-------|-----|------------|-------|-----|
|                   | TPF       | 1-FPF | PPV | TPF       | 1-FPF | PPV | TPF        | 1-FPF | PPV |
| <b>Chi Karesi</b> | 100       | 91    | 75  | 100       | 87    | 69  | 89         | 75    | 50  |
| <b>Öklit</b>      | 78        | 91    | 70  | 89        | 87    | 67  | 89         | 78    | 53  |
| <b>Manhattan</b>  | 56        | 91    | 62  | 55        | 81    | 45  | 22         | 59    | 13  |
| <b>Chebyshev</b>  | 56        | 60    | 30  | 55        | 50    | 24  | 56         | 47    | 23  |

Tablo 2.5 incelendiğinde özellik çıkarımında YİÖ(8,1) ve YİÖ(8,2) kullanıldığında Akromegali teşhisinde en iyi sınıflandırıcı Chi Karesi, YİÖ(16,2) kullanıldığında ise Öklit sınıflandırıcısı bulunmuştur.

Tablo 2.6. Akromegali teşhisinde İYİÖ(8,1), İYİÖ(8,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                   | İYİÖ (8,1) |       |     | İYİÖ (8,2) |       |     |
|-------------------|------------|-------|-----|------------|-------|-----|
|                   | TPF        | 1-FPF | PPV | TPF        | 1-FPF | PPV |
| <b>Chi Karesi</b> | 100        | 87    | 69  | 78         | 84    | 58  |
| <b>Öklit</b>      | 100        | 78    | 56  | 100        | 84    | 64  |
| <b>Manhattan</b>  | 67         | 84    | 54  | 33         | 75    | 27  |
| <b>Chebyshev</b>  | 67         | 47    | 26  | 55         | 43    | 22  |

Tablo 2.6' ya göre özellik çıkarımında İYİÖ(8,1) kullanıldığında Chi Karesi, İYİÖ(8,2) kullanıldığında Öklit sınıflandırıcısı Akromegali teşhisinde en iyi sınıflandırıcı olarak tespit edilmiştir.

Tablo 2.7. Akromegali teşhisinde TBA, DAA ve Alt uzay DAA kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                  | <b>TBA</b> |              |            | <b>DAA</b> |              |            | <b>Alt uzay DAA</b> |              |            |
|------------------|------------|--------------|------------|------------|--------------|------------|---------------------|--------------|------------|
|                  | <b>TPF</b> | <b>1-FPF</b> | <b>PPV</b> | <b>TPF</b> | <b>1-FPF</b> | <b>PPV</b> | <b>TPF</b>          | <b>1-FPF</b> | <b>PPV</b> |
| <b>Öklit</b>     | 44         | 81           | 40         | 78         | 81           | 54         | 78                  | 91           | 70         |
| <b>Manhattan</b> | 22         | 69           | 17         | 56         | 75           | 38         | 78                  | 91           | 70         |
| <b>Kosinüs</b>   | 44         | 81           | 40         | 67         | 81           | 50         | 44                  | 78           | 36         |

Tablo 2.7 incelendiğinde ise özellik çıkarımında TBA kullanıldığında Öklit ve Kosinüs sınıflandırıcısı, DAA kullanıldığında Öklit ve Alt uzay DAA kullanıldığında Öklit ve Manhattan sınıflandırıcıları en iyi sınıflandırıcı olarak bulunmuştur.

Tablo 2.8. Down sendromu teşhisinde YİÖ(8,1), YİÖ(8,2) ve YİÖ(16,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                   | <b>YİÖ (8,1)</b> |              |            | <b>YİÖ (8,2)</b> |              |            | <b>YİÖ (16,2)</b> |              |            |
|-------------------|------------------|--------------|------------|------------------|--------------|------------|-------------------|--------------|------------|
|                   | <b>TPF</b>       | <b>1-FPF</b> | <b>PPV</b> | <b>TPF</b>       | <b>1-FPF</b> | <b>PPV</b> | <b>TPF</b>        | <b>1-FPF</b> | <b>PPV</b> |
| <b>Chi Karesi</b> | 100              | 91           | 70         | 100              | 88           | 64         | 86                | 76           | 43         |
| <b>Öklit</b>      | 100              | 85           | 58         | 100              | 85           | 58         | 71                | 82           | 45         |
| <b>Manhattan</b>  | 86               | 82           | 50         | 71               | 76           | 38         | 14                | 58           | 7          |
| <b>Chebyshev</b>  | 43               | 62           | 19         | 43               | 53           | 16         | 43                | 50           | 15         |

Tablo 2.8 'e göre Down sendromu teşhisinde YİÖ(8,1) ve YİÖ(8,2)' de Chi karesi sınıflandırıcısı, YİÖ(16,2)' de ise duyarlılık açısından Chi Karesi, özgüllük ve pozitif tahmin değeri açısından Öklit sınıflandırıcısı en iyi sınıflandırıcı olarak seçilmiştir.

Tablo 2.9. Down sendromu teşhisinde İYİÖ(8,1), İYİÖ(8,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                   | İYİÖ (8,1) |       |     | İYİÖ (8,2) |       |     |
|-------------------|------------|-------|-----|------------|-------|-----|
|                   | TPF        | 1-FPF | PPV | TPF        | 1-FPF | PPV |
| <b>Chi Karesi</b> | 100        | 88    | 64  | 86         | 82    | 50  |
| <b>Öklit</b>      | 86         | 82    | 50  | 86         | 88    | 60  |
| <b>Manhattan</b>  | 71         | 82    | 45  | 43         | 70    | 23  |
| <b>Chebyshev</b>  | 43         | 53    | 16  | 43         | 47    | 14  |

Tablo 2.9' un sonuçlarına bakıldığında İYİÖ(8,1) için Chi Karesi ve İYİÖ(8,2) için ise Öklit sınıflandırıcısı en iyi performans göstermiştir.

Tablo 2.10. Down sendromu teşhisinde TBA, DAA ve Alt uzay DAA kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                  | TBA |       |     | DAA |       |     | Alt uzay DAA |       |     |
|------------------|-----|-------|-----|-----|-------|-----|--------------|-------|-----|
|                  | TPF | 1-FPF | PPV | TPF | 1-FPF | PPV | TPF          | 1-FPF | PPV |
| <b>Öklit</b>     | 100 | 68    | 39  | 100 | 76    | 47  | 100          | 85    | 58  |
| <b>Manhattan</b> | 86  | 53    | 27  | 100 | 65    | 37  | 100          | 85    | 58  |
| <b>Kosinüs</b>   | 100 | 68    | 39  | 100 | 73    | 44  | 100          | 68    | 39  |

Tablo 2.10 incelendiğinde ise Down sendromu teşhisinde özellik çıkarımında TBA ve DAA kullanıldığında Öklit sınıflandırıcısı en iyi performans gösterirken, Alt uzay DAA kullanıldığında en iyi performansı Öklit ve Manhattan göstermiştir.

Tablo 2.11. Lupus teşhisinde YİÖ(8,1), YİÖ(8,2) ve YİÖ(16,2) kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                   | YİÖ (8,1) |       |     | YİÖ (8,2) |       |     | YİÖ (16,2) |       |     |
|-------------------|-----------|-------|-----|-----------|-------|-----|------------|-------|-----|
|                   | TPF       | 1-FPF | PPV | TPF       | 1-FPF | PPV | TPF        | 1-FPF | PPV |
| <b>Chi Karesi</b> | 89        | 94    | 80  | 78        | 94    | 78  | 44         | 87    | 50  |
| <b>Öklit</b>      | 78        | 91    | 70  | 67        | 94    | 75  | 56         | 87    | 56  |
| <b>Manhattan</b>  | 89        | 81    | 57  | 67        | 78    | 46  | 56         | 50    | 24  |
| <b>Chebyshev</b>  | 56        | 59    | 28  | 44        | 53    | 21  | 33         | 53    | 17  |

Tablo 2.11' in sonuçlarına bakıldığında  $Y\ddot{I}\ddot{O}(8,1)$  ve  $Y\ddot{I}\ddot{O}(8,2)$  ile birlikte kullanılan Chi Karesi,  $Y\ddot{I}\ddot{O}(16,2)$ ' de ise Öklit sınıflandırıcısı en iyi sınıflandırıcı olarak belirlenmiştir.

Tablo 2.12. Lupus teşhisinde  $\ddot{I}Y\ddot{I}\ddot{O}(8,1)$  ve  $\ddot{I}Y\ddot{I}\ddot{O}(8,2)$  kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                   | $\ddot{I}Y\ddot{I}\ddot{O}(8,1)$ |       |     | $\ddot{I}Y\ddot{I}\ddot{O}(8,2)$ |       |     |
|-------------------|----------------------------------|-------|-----|----------------------------------|-------|-----|
|                   | TPF                              | 1-FPF | PPV | TPF                              | 1-FPF | PPV |
| <b>Chi Karesi</b> | 88                               | 91    | 73  | 89                               | 81    | 57  |
| <b>Öklit</b>      | 56                               | 91    | 62  | 78                               | 91    | 70  |
| <b>Manhattan</b>  | 78                               | 81    | 54  | 78                               | 62    | 37  |
| <b>Chebyshev</b>  | 22                               | 59    | 13  | 11                               | 56    | 6   |

Tablo 2.12' ye göre  $\ddot{I}Y\ddot{I}\ddot{O}(8,1)$  ile Chi Karesi,  $\ddot{I}Y\ddot{I}\ddot{O}(8,2)$  ile duyarlılık açısından Chi Karesi, özgüllük ve pozitif tahmin değeri açısından Öklit sınıflandırıcısı en iyi sınıflandırıcı olarak seçilmiştir.

Tablo 2.13. Lupus teşhisinde TBA, DAA ve Alt uzay DAA kullanılması sonucunda sınıflandırıcıların TPF, 1-FPF ve PPV değerleri

|                  | TBA |       |     | DAA |       |     | Alt uzay DAA |       |     |
|------------------|-----|-------|-----|-----|-------|-----|--------------|-------|-----|
|                  | TPF | 1-FPF | PPV | TPF | 1-FPF | PPV | TPF          | 1-FPF | PPV |
| <b>Öklit</b>     | 55  | 78    | 42  | 56  | 87    | 56  | 78           | 91    | 70  |
| <b>Manhattan</b> | 44  | 62    | 25  | 44  | 78    | 36  | 89           | 87    | 67  |
| <b>Kosinüs</b>   | 55  | 78    | 42  | 56  | 84    | 50  | 56           | 78    | 42  |

Lupus teşhisinde Tablo 2.13 incelendiğinde özellik çıkarımı aşamasında TBA kullanıldığında Öklit ve Kosinüs, DAA kullanıldığında Öklit ve Alt uzay DAA kullanıldığında duyarlılık açısından Manhattan, özgüllük ve pozitif tahmin değeri açısından Öklit sınıflandırıcısı en iyi performans göstermiştir.

Tüm tablolar birlikte değerlendirildiğinde, özellik çıkarma yöntemleri ile birlikte en iyi tanıma performansı veren sınıflandırıcıların ön tanıma programındaki doğruluk değerleri Tablo 2.14' de verilmektedir.

Tablo 2.14. Yöntemler ve Doğruluk değerleri

| Yöntem (Özellik çıkarma + Sınıflandırma) | Doğruluk Değerleri |
|------------------------------------------|--------------------|
| YİÖ(8,1) + Chi Karesi                    | 92                 |
| YİÖ(8,2) + Chi Karesi                    | 90                 |
| İYİÖ(8,1) + Chi Karesi                   | 90                 |
| Alt uzay DAA + Öklit                     | 88                 |
| Alt uzay DAA + Manhattan                 | 88                 |
| İYİÖ(8,2) + Öklit                        | 87                 |
| İYİÖ(8,2) + Chi Karesi                   | 82                 |
| DAA + Öklit                              | 80                 |
| YİÖ(16,2) + Öklit                        | 80                 |
| TBA + Öklit                              | 73                 |

Sonuçlara bakıldığında yüzden hastalık teşhisinde en iyi performans özellik çıkarımında YİÖ(8,1) ve sınıflandırmada Chi Karesi kullanılarak alınmıştır.

#### 2.1.3.9. Ön Tanı Programı Sonuçları

Akromegali, Down sendromu, Lupus, sağlam ve diğer sınıf olmak üzere beş sınıf içeren sistemde YİÖ(8,1) özellik çıkarımı yöntemi ile Chi karesi sınıflandırıcısında tasarlanan Mask4 ağırlık matrisi kullanılarak %92 oranında başarı elde edilmiştir. Aşağıda test görüntüleri için elde edilen ön tanı sonuçları verilmektedir.

| YÜZDEN HASTALIK TEŞHİSİ |            |            |            |       |      |       |        |        |  |
|-------------------------|------------|------------|------------|-------|------|-------|--------|--------|--|
| Test Resimleri          |            |            |            |       |      |       |        |        |  |
| CHI KARESİ              |            |            |            |       |      |       |        |        |  |
| NO                      | ORIJINAL   | TAHMİNLER  | AKROMEGALİ | DIĞER | DOWN | LUPUS | NORMAL | SONUÇ  |  |
| 0                       | AKROMEGALİ | AKROMEGALİ | 86         | 91    | 96   | 89    | 92     | DOĞRU  |  |
| 1                       | AKROMEGALİ | AKROMEGALİ | 92         | 93    | 96   | 96    | 96     | DOĞRU  |  |
| 2                       | AKROMEGALİ | AKROMEGALİ | 87         | 92    | 95   | 88    | 91     | DOĞRU  |  |
| 3                       | AKROMEGALİ | AKROMEGALİ | 94         | 95    | 99   | 98    | 98     | DOĞRU  |  |
| 4                       | AKROMEGALİ | AKROMEGALİ | 98         | 98    | 102  | 105   | 106    | DOĞRU  |  |
| 5                       | AKROMEGALİ | AKROMEGALİ | 90         | 90    | 94   | 91    | 97     | DOĞRU  |  |
| 6                       | AKROMEGALİ | AKROMEGALİ | 88         | 89    | 95   | 92    | 93     | DOĞRU  |  |
| 7                       | AKROMEGALİ | AKROMEGALİ | 97         | 106   | 102  | 100   | 101    | DOĞRU  |  |
| 8                       | AKROMEGALİ | AKROMEGALİ | 92         | 94    | 97   | 94    | 100    | DOĞRU  |  |
| 9                       | DIĞER      | LUPUS      | 96         | 100   | 101  | 92    | 100    | YANLIŞ |  |
| 10                      | DIĞER      | DIĞER      | 92         | 89    | 98   | 92    | 98     | DOĞRU  |  |
| 11                      | DIĞER      | DIĞER      | 103        | 98    | 109  | 103   | 108    | DOĞRU  |  |
| 12                      | DIĞER      | DIĞER      | 105        | 99    | 107  | 103   | 109    | DOĞRU  |  |
| 13                      | DIĞER      | DIĞER      | 98         | 94    | 105  | 97    | 105    | DOĞRU  |  |
| 14                      | DIĞER      | DIĞER      | 93         | 88    | 100  | 95    | 99     | DOĞRU  |  |
| 15                      | DIĞER      | DIĞER      | 111        | 108   | 113  | 111   | 113    | DOĞRU  |  |
| 16                      | DOWN       | DOWN       | 94         | 99    | 89   | 90    | 95     | DOĞRU  |  |
| 17                      | DOWN       | DOWN       | 102        | 103   | 96   | 104   | 103    | DOĞRU  |  |
| 18                      | DOWN       | DOWN       | 103        | 104   | 97   | 106   | 104    | DOĞRU  |  |
| 19                      | DOWN       | DOWN       | 104        | 105   | 96   | 105   | 105    | DOĞRU  |  |
| 20                      | DOWN       | DOWN       | 101        | 103   | 94   | 99    | 104    | DOĞRU  |  |
| 21                      | DOWN       | DOWN       | 96         | 101   | 88   | 97    | 93     | DOĞRU  |  |
| 22                      | DOWN       | DOWN       | 103        | 105   | 91   | 102   | 104    | DOĞRU  |  |
| 23                      | LUPUS      | LUPUS      | 97         | 96    | 102  | 93    | 102    | DOĞRU  |  |
| 24                      | LUPUS      | LUPUS      | 91         | 96    | 98   | 88    | 88     | DOĞRU  |  |

| 3          | CHI KARESİ | EUCLIDEAN | MANHATTAN | CHEBSHEV | YÜZDE_CHI    | YÜZDE_EUC     | YÜZDE_MANH     | YÜZDE_CHEB    | Orjinal                                                                              | LBP                                                                                  |
|------------|------------|-----------|-----------|----------|--------------|---------------|----------------|---------------|--------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|
| AKROMEGALİ | 94         | 175       | 7188      | 26       | %89.26940... | %90.426695... | %85.6339604... | %86.170212... |  |  |
| DIĞER      | 95         | 177       | 7132      | 27       | %83.73287... | %85.475929... | %90.4972552... | %78.457446... | ORIJINAL:                                                                            | AKROMEGALİ                                                                           |
| DOWN       | 99         | 182       | 7584      | 27       | %71.74657... | %80.087527... | %74.7375153... | %78.457446... |                                                                                      |                                                                                      |
| LUPUS      | 98         | 187       | 7686      | 27       | %77.62557... | %69.310722... | %69.2773010... | %78.457446... |                                                                                      |                                                                                      |
| NORMAL     | 98         | 185       | 7560      | 27       | %77.62557... | %74.699124... | %79.8539679... | %78.457446... |                                                                                      |                                                                                      |


  

|           |            |
|-----------|------------|
| ORIJINAL: | AKROMEGALİ |
| SONUÇ:    | AKROMEGALİ |

Şekil 2.42. Ön tanı programı test sonuçları

Şekil 2.42' deki 3. test resmi (sağ alt köşedeki) Akromegalinin erken evrelerindeki bir hastaya ait görüntü olduğu için görüntü Akromegaliden çok sağlam (programda NORMAL) sınıfına benzemektedir. Program sonuçlarına bakıldığında ise Chi Karesi, Öklit ve Chebyshev sınıflandırıcısı bu test resmi için Akromegali sonucunu üretmektedir. Bu test görüntüsünün sınıflara olan uzaklıkları yüzdesel olarak Şekil 2.43' de verilmektedir.


Akromegali



Şekil 2.43. Test görüntüsünün ön tanı sonuçları 1


Sistemin, hastalıkların erken evrelerinde de ön tanı koyabilmesinin yanında diğer bir artısıda test resmi olarak, sistemde tanımlı hastalıkların dışında bir hastalıklı yüz girildiğinde sistem bu görüntüyü diğer sınıfına, eğer sağlam bir yüz görüntüsü ise Normal sınıfına dahil etmektedir. Şekil 2.44’ de bu durumu örnekleyici test görüntüsü ön tanı sonuçları verilmektedir.

Diğer




(a)

Şekil 2.44. (a) Test görüntülerinin ön tanı sonuçları




(b)



(c)

Şekil 2.44. (b)(c)Test görüntülerinin ön tanı sonuçları

Sistemin %8' lik hata kısmını oluşturan görüntülerin sınıflara olan uzaklıkları Şekil 2.45' de verilmektedir.

| 9          | CHI KARESİ | EUCLIDEAN | MANHATTAN | CHEBSHEV | YÜZDE_CHI    | YÜZDE_EUC     | YÜZDE_MANH     | YÜZDE_CHEB    | Orjinal                                                                               | LBP                                                                                   |
|------------|------------|-----------|-----------|----------|--------------|---------------|----------------|---------------|---------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------|
| AKROMEGALİ | 96         | 219       | 7472      | 47       | %83.79290... | %85.739092... | %85.5242425... | %86.067193... |  |  |
| DİĞER      | 100        | 245       | 8024      | 55       | %77.49015... | %68.092033... | %68.9096685... | %67.391304... |                                                                                       |                                                                                       |
| DOWN       | 101        | 230       | 7908      | 51       | %71.58131... | %75.037985... | %74.4659416... | %74.802371... |                                                                                       |                                                                                       |
| LUPUS      | 92         | 213       | 7020      | 45       | %89.64546... | %90.753201... | %90.9332782... | %91.106719... |                                                                                       |                                                                                       |
| NORMAL     | 100        | 226       | 7678      | 49       | %77.49015... | %80.377686... | %80.1668690... | %80.632411... |                                                                                       |                                                                                       |
|            |            |           |           |          |              |               |                |               | ORJİNAL:                                                                              | DİĞER                                                                                 |
|            |            |           |           |          |              |               |                |               | SONUÇ:                                                                                | LUPUS                                                                                 |

(a)

Şekil 2.45. (a) Yanlış bulunan test görüntüleri

| 26         | CHI KARESİ | EUCLIDEAN | MANHATTAN | CHEBSHEV | YÜZDE_CHI    | YÜZDE_EUC     | YÜZDE_MANH     | YÜZDE_CHEB    | Orjinal                                                                             | LBP                                                                                 |
|------------|------------|-----------|-----------|----------|--------------|---------------|----------------|---------------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
| AKROMEGALİ | 98         | 252       | 7666      | 60       | %80.56519... | %80.630284... | %80.6122836... | %83.208955... |  |  |
| DIĞER      | 107        | 284       | 8618      | 68       | %68.17055... | %67.255956... | %67.3069384... | %68.283582... |                                                                                     |                                                                                     |
| DOWN       | 103        | 256       | 8006      | 60       | %74.46703... | %75.403535... | %74.6905072... | %83.208955... |                                                                                     |                                                                                     |
| LUPUS      | 94         | 244       | 7128      | 58       | %86.01883... | %85.933897... | %90.9864569... | %89.179104... |                                                                                     |                                                                                     |
| NORMAL     | 93         | 240       | 7168      | 64       | %90.77838... | %90.776325... | %86.4038138... | %76.119402... |                                                                                     |                                                                                     |
|            |            |           |           |          |              |               |                |               | ORIJINAL:                                                                           | LUPUS                                                                               |
|            |            |           |           |          |              |               |                |               | SONUÇ:                                                                              | NORMAL                                                                              |

(b)

| 32         | CHI KARESİ | EUCLIDEAN | MANHATTAN | CHEBSHEV | YÜZDE_CHI    | YÜZDE_EUC     | YÜZDE_MANH     | YÜZDE_CHEB    | Orjinal                                                                             | LBP                                                                                 |
|------------|------------|-----------|-----------|----------|--------------|---------------|----------------|---------------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
| AKROMEGALİ | 90         | 203       | 6941      | 38       | %80.32786... | %80.494835... | %80.4001298... | %78.129496... |  |  |
| DIĞER      | 97         | 230       | 7703      | 42       | %68.19672... | %66.850828... | %67.3726121... | %69.784172... |                                                                                     |                                                                                     |
| DOWN       | 93         | 205       | 7169      | 38       | %74.59016... | %75.378332... | %74.6953845... | %78.129496... |                                                                                     |                                                                                     |
| LUPUS      | 84         | 192       | 6383      | 37       | %90.81967... | %86.163824... | %86.4818501... | %84.028776... |                                                                                     |                                                                                     |
| NORMAL     | 85         | 185       | 6339      | 35       | %86.06557... | %91.112178... | %91.0500232... | %89.928057... |                                                                                     |                                                                                     |
|            |            |           |           |          |              |               |                |               | ORIJINAL:                                                                           | NORMAL                                                                              |
|            |            |           |           |          |              |               |                |               | SONUÇ:                                                                              | LUPUS                                                                               |

(c)

Şekil 2.45. (b)(c) Yanlış bulunan test görüntüleri

Şekil 2.45 (a)'daki test görüntüsü diğer sınıfında olan vitiligo hastasına ait bir yüz görüntüsüdür. Test resmine dikkat edilirse, yüzdeki döküntüler tıpkı Lupus hastalığında olduğu gibi yanaklarda oluşmuştur. Üstelik yüz görüntüsünün gözleri kapalıdır. Bu nedenle sistemde sınıflandırıcıların hepsi test görüntüsünü Lupus sınıfına dahil ederek yanlış sonuç üretmektedirler.

Şekil 2.45 (b)'deki test görüntüsü incelendiğinde ise Lupus sınıfına ait test görüntüsünü, Chi Karesi ve Öklit sınıflandırıcıları normal sınıfına dahil ederek yanlış sonuç, Manhattan ve Chebyshev sınıflandırıcıları Lupus sınıfına dahil ederek doğru sonuç üretmektedir. Benzer durum Şekil 2.45 (c)'deki normal sınıfına ait test görüntüsü için de geçerlidir. Chi Karesi dışındaki tüm sınıflandırıcılar test görüntüsünü normal sınıfına dahil etmektedir. Chi Karesi ise bir uzaklık farkıyla (Lupus-84, Normal-85) Lupus sonucunu vererek yanlış sonuç üretmektedir. Bu nedenle sınıflandırıcı sonuçları birlikte değerlendirilerek, sonuçlara Borda sayısı yöntemi [80] uygulanmaktadır. Bu yöntem çalışmaya uygulanırken sınıflandırıcıların her bir sınıf için ürettikleri sonuçlar önce normalize edilip ardından küçükten büyüğe doğru sıralanmıştır. En küçük uzaklık sonucuna en yüksek oy 3 verilerek azalan bir şekilde 2, 1, 0

oyları verilmiştir. YİÖ(8,1)' de dört sınıflandırıcı kullanıldığı için oylar 3, 2, 1, 0 şeklindedir. Bu şekilde en yüksek oy alan sınıf sonuç sınıf olarak belirlenmiştir. Şekil 2.46' da Borda sayısı yöntemi uygulanması sonucu Şekil 2.45' deki test örneklerinin yeni sonuçları verilmektedir.

| BORDO |          |           |                 |           |            |            |            |       |
|-------|----------|-----------|-----------------|-----------|------------|------------|------------|-------|
| NO    | ORIJINAL | TAHMINLER | AKROMEGALI      | DİĞER     | DOWN       | LUPUS      | NORMAL     | SONUÇ |
| 18    | DOWN     | DOWN      | 2.0049310089... | 2.3747... | 2.87028... | 0.80622... | 1.22356... | DOĞRU |
| 19    | DOWN     | DOWN      | 1.8284491778... | 2.0154... | 2.67557... | 1.59527... | 1.36952... | DOĞRU |
| 20    | DOWN     | DOWN      | 1.8058921137... | 0.6117... | 2.87017... | 2.54483... | 0.81401... | DOĞRU |
| 21    | DOWN     | DOWN      | 1.6236893205... | 0.2326... | 2.96537... | 1.34336... | 2.32161... | DOĞRU |
| 22    | DOWN     | DOWN      | 2.0290132453... | 1.6243... | 2.87221... | 1.43078... | 0.42022... | DOĞRU |
| 23    | LUPUS    | LUPUS     | 1.9377815031... | 1.5631... | 1.01716... | 2.93370... | 0.41077... | DOĞRU |
| 24    | LUPUS    | LUPUS     | 1.7858722990... | 0.8367... | 0.82916... | 3.03679... | 2.49053... | DOĞRU |
| 25    | LUPUS    | LUPUS     | 2.3168952201... | 0.6437... | 0.78038... | 2.91566... | 1.61794... | DOĞRU |
| 26    | LUPUS    | LUPUS     | 1.7689352710... | 0.2193... | 1.19683... | 2.63067... | 2.47407... | DOĞRU |
| 27    | LUPUS    | LUPUS     | 1.4132657999... | 1.6016... | 1.74107... | 2.88260... | 0.39716... | DOĞRU |
| 28    | LUPUS    | LUPUS     | 1.8036570181... | 2.4520... | 1.40069... | 2.57324... | 1.64416... | DOĞRU |
| 29    | LUPUS    | LUPUS     | 1.9816024760... | 1.2108... | 0.41835... | 2.85066... | 1.52754... | DOĞRU |
| 30    | LUPUS    | LUPUS     | 2.1710785273... | 1.0227... | 1.21516... | 2.88138... | 0.75007... | DOĞRU |
| 31    | LUPUS    | LUPUS     | 1.9900468919... | 0.8350... | 1.15784... | 3.00206... | 2.17404... | DOĞRU |
| 32    | NORMAL   | NORMAL    | 1.6028598855... | 0.2210... | 1.01668... | 2.45450... | 2.76804... | DOĞRU |
| 33    | NORMAL   | NORMAL    | 2.0042977333... | 0.2126... | 1.64150... | 1.41303... | 2.69755... | DOĞRU |
| 34    | NORMAL   | NORMAL    | 1.6270275525... | 0.4407... | 1.61252... | 2.21870... | 2.76462... | DOĞRU |
| 35    | NORMAL   | NORMAL    | 1.9897120690... | 0.6218... | 1.22085... | 2.21304... | 2.93690... | DOĞRU |
| 36    | NORMAL   | NORMAL    | 1.5792408343... | 0.4191... | 0.42063... | 2.31812... | 2.90197... | DOĞRU |
| 37    | NORMAL   | NORMAL    | 1.4002346830... | 0.4269... | 1.79482... | 2.37421... | 2.97010... | DOĞRU |
| 38    | NORMAL   | NORMAL    | 1.7882286256... | 0.4628... | 1.19695... | 2.35510... | 2.86908... | DOĞRU |
| 39    | NORMAL   | NORMAL    | 1.9709603737... | 0.8144... | 0.41348... | 2.16894... | 3.02127... | DOĞRU |
| 40    | NORMAL   | NORMAL    | 2.1372981539... | 0.6402... | 1.05906... | 2.18125... | 2.74731... | DOĞRU |
| 41    | NORMAL   | NORMAL    | 1.7910266175... | 0.2151... | 2.17260... | 1.02590... | 2.97268... | DOĞRU |

Şekil 2.46. Yanlış bulunan test görüntülerinin Borda sayısı yöntemi sonuçları

Chi Karesiyle yanlış bulunan test görüntüleri, Borda sayısı yöntemi ile doğru bulunarak sistemin performansı %95' e çıkarılmıştır.

### 3. SONUÇLAR VE ÖNERİLER

Bu tez kapsamında, yüzden hastalık teşhisi yapan, cinsiyetten, yaşdan ve ışıklandırma koşullarından bağımsız otomatik ön tanı programı gerçekleştirilmiştir. Ön tanının hekimden hekime değişmesi sebebiyle, geliştirilen programla ön tanıya nesnellik getirilmesi amaçlanmıştır.

Çalışma, eğitim ve test veri tabanlarının oluşturulması, ön işlemler, özellik çıkarımı ve sınıflandırma olmak üzere dört kısımda incelenmiştir. Eğitim aşamasında her bir sınıfta 20 görüntü olmak üzere toplamda 100, testte ise 41 görüntü kullanılmıştır.

Eğitim veri tabanı, Akromegali, Lupus ve Down sendromu sınıfları dışında, “sağlam” ve bu sınıflar dışındaki hastalık ve farklı görüntüleri içeren “diğer” bir sınıf olmak üzere beş sınıftan oluşturulmuştur. Bu sayede sisteme giriş olarak Akromegali, Lupus ve Down sendromu dışında bir yüz görüntüsü verildiğinde, bu görüntü gerçek durumuna göre “sağlam” veya “diğer” sınıftan birine dahil edilmektedir.

Eğitim ve test veritabanındaki görüntülere ön işlem olarak, döndürme, kesme ve histogram eşitleme uygulanmıştır. Uygulanan ön işlemlerle tüm görüntülerin aynı forma dönüştürülmesi sağlanarak tanıma performansı arttırılmıştır.

Bütünsel yaklaşımların en önemli aşamasını oluşturan özellik çıkarımında ise karşılaştırmalı olarak Yerel İkili Örüntüler ve çeşitlerinden İyileştirilmiş Yerel İkili Örüntüler, Merkezi Simetrik Yerel İkili Örüntüler, bunun yanında alt uzay temelli yaklaşımlardan Temel Bileşen Analizi, Doğrusal Ayrıştırıcı Analizi ve Alt uzay Doğrusal Ayrıştırıcı Analizi incelenmiştir. Sınıflandırma aşamasında ise Yerel Örüntülerle, Chi Karesi, Öklit, Manhattan ve Chebyshev uzaklık ölçütlerini kullanan NM sınıflandırıcısı, alt uzay temelli yaklaşımlarla ise Öklit, Manhattan uzaklıklarını ve Kosinüs benzerliğini kullanan NN ve NM sınıflandırıcıları ele alınmıştır.

Yerel Örüntülerde; farklı YİÖ operatörleri: YİÖ(8,1), YİÖ(8,2) ve YİÖ(16,2) operatörleri denendiğinde Chi Karesi, Manhattan ve Chebyshev sınıflandırıcılarında YİÖ(8,1) operatörü, YİÖ(8,2) ve YİÖ(16,2) operatörlerine göre daha iyi tanıma performansı verirken, Öklit sınıflandırıcısında YİÖ(8,1) ve YİÖ(8,2) operatörleri aynı tanıma oranı vermiştir. İYİÖ’

ler için aynı test yapıldığında ise  $Y\ddot{I}\ddot{O}$ ' de olduğu gibi Chi karesi, Manhattan ve Chebyshev sınıflandırıcılarında  $\ddot{I}Y\ddot{I}\ddot{O}(8,1)$  operatörü,  $\ddot{I}Y\ddot{I}\ddot{O}(8,2)$  operatörüne göre daha yüksek tanıma oranı vermiştir. Öklit sınıflandırıcısında ise  $\ddot{I}Y\ddot{I}\ddot{O}(8,2)$  operatöründen  $\ddot{I}Y\ddot{O}(8,1)$ ' e göre daha çok başarı elde edilmiştir.

$MSY\ddot{I}\ddot{O}$ ' de eşik değeri  $T$  belirlenirken,  $T=0.00-0.09$  arasındaki değerler için her sınıflandırıcının performansına bakılmıştır. Sonuçlara göre  $MSY\ddot{I}\ddot{O}(8,1)$  için en yüksek doğruluk değeri Chi Karesi sınıflandırıcısı ile  $T=0.07$  alınarak elde edilmiştir. Diğer sınıflandırıcılar için belirlenen en iyi eşik değeri ise Öklit için  $T=0.08$ , Manhattan için  $T=0.06$  veya  $T=0.07$  ve Chebshev için  $T=0.02$ ' dir.  $MSY\ddot{I}\ddot{O}(8,2)$  için sonuçlar incelendiğinde ise en yüksek doğruluk değeri  $T=0.09$  alınarak Manhattan sınıflandırıcısı ile elde edilirken, Öklit için  $T=0.08$  veya  $T=0.09$ , Chi Karesi için  $T=0.09$  ve Chebyshev için  $T=0.01$  dir.

Chi Karesinde ağırlık matrisi belirlenirken literatürdeki yüz tanıma için kullanılan ağırlık matrisleri ve bu matrislerin hastalıklara uygun kombinasyonları denenmiştir. Tasarlanan ağırlık matrisinde Akromegali yüz görüntüsü için burun ve ağıza, Lupus için yanaklara, Down sendromu için ise göz ve gözler arasındaki bölgeye, diğer bölgelere oranla daha büyük katsayılar verilerek %92 oranında tanıma performansı elde edilmiştir.

Alt uzay temelli yaklaşımlarla özellik çıkarımı yapılırken; TBA ve TBA+DAA' da farklı sayıdaki özvektörlerin tanıma performansına etkisi incelendiğinde Özyüz uzayı küçük olduğunda, TBA, TBA+DAA' dan daha iyi performans gösterirken, Özyüz uzayı büyüdüğünde TBA+DAA, TBA' dan daha iyi performans gösterdiği görülmüştür.

DAA için en ideal görüntü boyutu araştırılmış ve sonuç olarak 32x32 boyutundaki görüntülerin kullanılması sonucunda kabul edilebilir bir koşum zamanı ile en yüksek tanıma oranı elde edilmiştir.

Sınıflandırıcıların performansını değerlendirebilmek amacıyla tüm özellik çıkarım yöntemlerinin hepsi için ayrı ayrı ikili tanı testi uygulanmıştır. Test sonucunda  $Y\ddot{I}\ddot{O}(8,2)$  + Chi Karesi %90,  $Y\ddot{I}\ddot{O}(16,2)$  + Öklit %80,  $\ddot{I}Y\ddot{I}\ddot{O}(8,1)$  + Chi Karesi %90,  $\ddot{I}Y\ddot{I}\ddot{O}(8,2)$  + Chi Karesi % 82,  $\ddot{I}Y\ddot{I}\ddot{O}(8,2)$  + Öklit %87, TBA + Öklit %73, DAA + Öklit %80, Alt uzay DAA + Öklit %88, Alt uzay DAA + Manhattan %88 ve %92 doğruluk değeriyle en iyi performans  $Y\ddot{I}\ddot{O}(8,1)$ +Chi Karesi+Mask4 alınmıştır. Çünkü  $Y\ddot{I}\ddot{O}(8,1)$  özellik çıkarım algoritması ile bölgesel özellik çıkarımı yapılarak yüze ait çok küçük önemli örüntüler tanımlanabilmiştir.

Bunun yanında Chi karesi ile de elde edilen bölgelere önem derecesine göre katsayılar verilerek bir ağırlık matrisi oluşturulması performansı büyük oranda artırmıştır.

Sınıflandırıcı sonuçlarına Borda sayısı yöntemi uygulanarak ve tanıma performansı %95' e çıkarılmıştır. Ön tanı için önerilen bu yaklaşımın diğer bir yararı, başka tür problemlere de genelleştirilebilir olmasıdır.

Öneriler olarak;

- Ağırlık matrisindeki bölgesel katsayıların etki derecesinin netleştirilmesi ile sistem performansı artırılabilir.
- Veri tabanı bilgileri genişletilebilir. Veri tabanındaki görüntü sayısının fazla olması durumunda ise morflemeden yararlanılabilir.
- Kullanıma yönelik online bir program haline getirilebilir.
- Performansın daha da artırılması adına, çeşitli özellik çıkarım ve sınıflandırma yöntemleri denenebilir.

Çalışma sırasında uygulanan yaklaşımlar, insanlar arası benzerliğin tespiti problemi için de gerçekleşmiş, 2012 Sinyal İşleme ve İletişim Uygulamaları Kurultayına ve Çankaya Üniversitesi Mühendislik ve Teknoloji sempozyumuna 2 adet bildiri sunulmuş ve bildiri kitapçıklarında basılmıştır [81, 82].

## KAYNAKLAR

1. Aase M. J., Diagnostic Dysmorphology, First Edition, Plenum Medical Book Co.,1990.
2. [http://www.adahed.org.tr/belge\\_egitim/bas\\_yuz\\_boyun\\_muayenesi.pdf](http://www.adahed.org.tr/belge_egitim/bas_yuz_boyun_muayenesi.pdf) Baş yüz boyun mua-yenesi. 15 Aralık 2012.
3. Schneider, H., J., Kosilek, R., P., Günther, M., Roemmler, J., Stalla, G., K., Sievers, C., Reincke, M., Schopohl, J. ve Würtz, R., P., A Novel Approach to the Detection of Acromegaly: Accuracy of Diagnosis by Automatic Face Classification, J Clin Endocrinol Metab, 96, 7 (2011) 2074–2080.
4. Miller, R., E., Learned-Miller, E., G., Trainer, P., Paisley, A. ve Blanz, V., Early diagnosis of acromegaly: computers vs clinicians, Clinical Endocrinology, 75 (2011) 226–231.
5. Kurt, B. ve Nabyev, V., V., Down syndrome recognition using local binary patterns and statistical evaluation of the system, Expert Systems with Applications, 38 (2011) 8690–8695.
6. Loos, H., S., Wiczorek, D., Würtz, R., P., Malsburg, C. ve Horsthemke, B., Computer-based recognition of dysmorphic faces, European Journal of Human Genetics, 11, 8 (2003) 555–560.
7. Landry, D. J., Raisideb, D. E., ve Vanhouttec, J. J. (1979). On the classification of congenital abnormalities from hand radiographs, Pattern Recognition, 11, 4, 289–296.
8. <http://www.saglik.im/akromegali/> Akromegali Nedir. 15 Aralık 2012.
9. [http://www.haberler.com/akromegali-hastaligini-hastalar-kendisi-teshis-haberi/Akromegali Teşhis.](http://www.haberler.com/akromegali-hastaligini-hastalar-kendisi-teshis-haberi/Akromegali_Teshis.) 15 Aralık 2012.
10. <http://www.meleklermekani.com/hastaliklar-ve-tedavileri/57132-down-sendromu-tani-ve-tedavisi.html> Down Sendromu. 15 Aralık 2012.
11. <http://www.xn--salk-1wa3i.net/downsendromu.html> Down Sendromu. 15 Aralık 2012.
12. [http://www.webanne.com/bebek\\_anomalileri.html](http://www.webanne.com/bebek_anomalileri.html) Bebek Anomalileri. 15 Aralık 2012.
13. <http://www.bakterim.net/saglik/76442-sistemik-lupus-eritematoz-hastaligi-nedir-nasil-teda-vi-edilir.html> Sistemik Lupus Eritematoz. 15 Aralık 2012.
14. <http://www.antalyaozon.com/sistemik-lupus-eritematozus-sle-> Sistemik Lupus Eritematozus. 15 Aralık 2012.

15. Zhengyou, Z., Lyons, M., Schuster, M. ve Akamatsu, S., Comparison Between Geometry based and Gabor-Wavelet based Facial Expression Recognition Using Multi-layer Perceptron, IEEE International Conference on Automatic Face and Gesture Recognition, Nisan 1998, 454-459.
16. Brunelli, R. ve Poggio, T., Face recognition: features versus templates, IEEE Transactions on Pattern Analysis and Machine Intelligence, 15, 10 (1993) 1042-1052.
17. Tan, X., Chen, S., Zhou, Z. H. ve Zhang, F., 2006, Face recognition from a single image per person: A survey, Pattern Recognition, 39, 9 (2006) 1725-1745.
18. Wiskott, L., Fellous, J., M., Krger, N. ve Malsburg, C., Face Recognition by Elastic Bunch Graph Matching, IEEE Transactions on Pattern Analysis and Machine Intelligence, 19, 1997, 775-779.
19. Lades, M., Vorbruggen, J., C., Buhmann, J., Lange, J., Malsburg, C., Wurtz, R., P. ve Konen, W., Distortion Invariant Object Recognition in the Dynamic Link Architecture, IEEE Transactions on Computers, 42, 3 (1993) 300 -311.
20. <http://www.neuroinformatik.ruhr-unibochum.de/ini/VDM/research/computerVision/Graph-Matching/identification/faceRecognition/contents.html> Yüz Tanıma. 15 Haziran 2007.
21. Jian, L., Shaohua, Z. ve Shekhar, C., A comparison of subspace analysis for face recognition, Multimedia and Expo International Conference (ICME), 3, 2003.
22. Kirby, M. ve Sirovic, L., Application of the Karhunen-Loeve Procedure for the Characterization of Human Faces, IEEE Transactions on Pattern Analysis and Machine Intelligence, 12, 1 (1990) 103 – 108.
23. Belhumeur, P., N., Hespanha, J., P. ve Kreigman, D., J., Eigenfaces vs. fisherfaces: Recognition using class specific linear projection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 19, 7 711 - 720.
24. Zhao, W., Chellappa, R. ve Krishnaswamy, A., Discriminant analysis of principal components for face recognition, Automatic Face and Gesture Recognition, 3rd IEEE International Conference, 1998, 336-341.
25. Zhao, W., Chellappa, R., Philips, P., J. ve Rosenfeld, A., Face recognition: A literature survey, ACM Computing Surveys (CSUR), 35, 4 (2003) 399-458.
26. Delac, K., Grgic, M. ve Liatsis, P., Appearance-based Statistical Methods for Face Recognition, 47th International Symposium ELMAR-2005, 2005, Zadar, 151-158.
27. Zhao, W., Chellappa, R. ve Krishnaswamy, A., Discriminant Analysis of Principal Components for Face Recognition, Proc. of the 3rd IEEE International Conference on Automatic Face and Gesture Recognition, 1998, Nara, 336-341.

28. Beveridge, J., R., She, K., Draper, B. ve Givens, G., H., A Nonparametric Statistical Comparison of Principal Component And Linear Discriminant Subspaces for Face Recognition, Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, 2001, Kauai, 535-542.
29. Baudat, G. ve Anouar, F., Generalized Discriminant Analysis Using a Kernel Approach, Neural Computation, 12, 10 (2000) 2385-2404.
30. Shen, L. ve Bai, L., Gabor wavelets and kernel direct discriminant analysis for face recognition, Pattern Recognition 17th International Conference (ICPR), 1, 2004, 284-287.
31. Ojala, T., Pietikainen, M. ve Harwood, D., A comparative study of texture measures with classification based on feature distributions, Pattern Recognition, 29, 1 (1996) 51-59.
32. Ahonen, T., Hadid, A. ve Pietikainen, M., Face recognition with local binary patterns. Proceedings of the European Conference on Computer Vision, Prague, Czech (2004) 469-481.
33. Hadid, A., Pietikinen, M. ve Ahonen, T., A discriminative feature space for detecting and recognizing faces, Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2 (2004) 797-804.
34. Moghaddam, B. ve Pentland, A., Face Recognition using View-Based and Modular Eigenspaces, In Automatic Systems for the Identification and Inspection of Humans, SPIE, 1994, 12-21.
35. Lanitis, A., Taylor, C., J. ve Cootes, T., F., Automatic interpretation and coding of face images using flexible models, IEEE Transactions on Pattern Analysis and Machine Intelligence, 19, 7 (1997) 743-756.
36. Shan, C. ve Gritti, T., Learning discriminative lbp-histogram bins for facial expression recognition, Proceedings of the British Machine Vision Conference 2008.
37. Chan, C., Kittler, J. ve Messer, K., Multi-scale local binary pattern histograms for face recognition, The 2nd International Conference on Biometrics, 4642(2007) 809-818.
38. Wang, X., Han, T., X. ve , Yan, S., An hog-lbp human detector with partial occlusion handling, International Conference on Computer Vision, ICCV09 (2009) 32-39.
39. Ojala, T., Pietikäinen, M. ve Harwood, D., A comparative study of texture measures with classification based on feature distributions. Pattern Recognition, 29, 1(1996) 51-59.
40. Ojala, T., Pietikäinen, M. ve Mäenpää, T., Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. IEEE Transactions on Pattern Analysis and Machine intelligence, 24, 7(2002) 971-987.

41. Ahonen, T., Hadid, A. ve Pietikäinen, M., Face description with local binary patterns: application to face recognition, IEEE Transactions Pattern Analysis and Machine Intelligence, 28, 12 (2006) 2037–2041.
42. Ahonen, T., Hadid, A. ve Pietikäinen, M., Face recognition with local binary patterns, Proc. Euro. Conf. Computer Vision (ECCV), 2004, 469–481.
43. Hongliang, J., Qingshan, L., Hanqing, L. ve Xiaofeng, T., Face detection using improved LBP under Bayesian framework, Proceedings International Conference Image and Graphics(ICIG), 2004, 306–309.
44. Heikkila, M., Pietikainen, M. ve Schmid, C., Description of interest regions with Local Binary Pattern, Journal Pattern Recognition, 42, 3 (2009) 425-436.
45. Shengcai, L., Xiangxin, Z., Zhen, L., Lun, Z. ve Stan, Z., L., Learning Multi-scale Block Local Binary Patterns for Face Recognition, IAPR/IEEE International Conference on Biometrics, 2007, 828-837.
46. Crow, F. C., Summed-area tables for texture mapping, SIGGRAPH, 18, 3 (1984) 207–212.
47. Viola, P. ve Jones, M., Robust real time object detection, IEEE ICCV Workshop on Statistical and Computational Theories of Vision, Vancouver, Canada, Temmuz 2001.
48. Duda, R. O., Hart, P. E. ve Stork, D. G., Pattern Classification, Second Edition, 654 sayfa Wiley-Interscience, New York, 2001.
49. Kirby, M. ve Sirovich, L., Application of the Karhunen-Loeve Procedure for Characterization of Human Faces, IEEE Transactions on Pattern Analysis and Machine Intelligence, 12, 1 (1990) 103–108.
50. Sirovich, L. ve Kirby, M., Low-dimensional procedure for the characterization of human faces, Journal of the Optical Society of America, 4, 3 (1987) 519-524.
51. [http://www.cs.cmu.edu/~guestrin/Class/10701-S06/Handouts/recitations/recitationpca\\_svd.ppt](http://www.cs.cmu.edu/~guestrin/Class/10701-S06/Handouts/recitations/recitationpca_svd.ppt), Boyut Azaltma. 24 Nisan 2007.
52. Turk, M., A. ve Pentland A., P., Face recognition using eigenfaces, Computer vision and pattern recognition IEEE Computer Society Conference, 1991, 586-591.
53. <http://tr.wikipedia.org/wiki/Varyans>, Varyans. 15 Aralık 2012.
54. Alpar, R., Uygulamalı Çok Değişkenli İstatiksel Yöntemlere Giriş-1, İkinci Baskı, 412 sayfa, Nobel Yayın Dağıtım/Teknik Dizisi, İstanbul, 2003.

55. [http://www.cs.princeton.edu/picasso/mats/PCA-Tutorial-Intuition\\_jp.pdf](http://www.cs.princeton.edu/picasso/mats/PCA-Tutorial-Intuition_jp.pdf), Sezgisel PCA. 15 Aralık 2012.
56. Jackson, J., E., A User Guide to Principle Component, 592 sayfa, Wiley-Interscience, 1991.
57. Bokman, L., Syungkwon, R. ve Park, F., C., Movement Primitives, Principal Component Analysis, and the Efficient Generation of Natural Motions, Proceedings of the 2005 IEEE International Conference on Robotics and Automation, Spain, 2005, 4630-4635.
58. Romdhani, S., Face Recognition using Principal Components Analysis, Yüksek Lisans, Master of Science in Electronics Engineering at the University of Glasgow, Glasgow, 1996.
59. Pentland, A., Moghaddam, B. ve Starner, T., View-based and modular eigenspaces for face recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR'94), Haziran 1994 17 -38.
60. Fisher, R., A., The Use of Multiple Measurements in Taxonomic Problems, Annual Eugenics, 7, 2 (1936) 179-188.
61. Swets, D., L. ve Weng J., J., Using Discriminant Eigenfeatures for Image Retrieval, IEEE Transactionson Pattern Analysis and Machine Intelligence, 18, 8 (1996) 831–836.
62. Belhumeur, P., N., Hespanha, J., P. ve Kriegman, D., J., Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 19, 7 (1997) 711–720.
63. Zhao, W., Krishnaswamy, A. ve Chellappa, R., Discriminant Analysis of Principal Components for Face Recognition, IEEE International Conference on Automatic Face and Gesture Recognition, 1998, 336-341.
64. Rui, H., Qingshan, L., Hanqing, L. ve Songde, M., Solving the Small Sample Size Problem of LDA, 16th International Conference on Pattern Recognition (ICPR'02), 3, 2002 29-32.
65. McLachlan G., J., Discriminant Analysis and Statistical Pattern Recognition, 552 sayfa, Wiley-Interscience, Chichester, 2004.
66. Zhao, W., Chellappa, R. ve Philips, P., J., Subspace linear discriminant analysis for face recognition, 24 sayfa, Computer Vision Laboratory, Center for Automation Research, University of Maryland.
67. Açıklık C., Meta-analiz ve kanıta dayalı tıptaki yeri, Klinik Psikofarmakoloji Bülteni 2009, 19, 2 164-172.

68. Egger, M., Smith, G.,D. ve Phillips, A., N., Meta-Analysis: Principles and Prosedures. BMJ, 315, 7121 (1997) 1533 – 1537.
69. Akçıl, M. ve Karaağaoğlu, E., Tıpta Meta-analizi, Hacettepe Tıp Dergisi, 32 (2001) 184-90.
70. Akçay, A. ve Demirel, A., Pyometralı Köpeklerde Bazı Kan Parametrelerinin Optimal Pozitiflik Eşiğinin Özgün Oranlar ve ROC (Receiver Operating Characteristic) Eğrisi Yöntemi ile Belirlenmesi, Erciyes Üniversitesi Veteriner Fakültesi Dergisi, 8, 3 (2011) 153-163.
71. Genç, Y., Tanı testi çalışmalarında metodolojik standartların kullanılması. Ankara Üniversitesi Tıp Fakültesi Mecmuası, 56, 4 (2003).
72. Ayakta, B., K., Tanı Testleri ve Bu Testler Yardımıyla Mide Kanseri Hastalarda Risk Faktörlerinin Belirlenmesi, Yüksek Lisans Tezi, Uludağ Üniversitesi. Sağlık Bilimleri Enstitüsü, Biyoistatistik Programı, Bursa, 1999.
73. Pepe, M., S., The statistical evaluation of medical tests for classification and prediction, 318 sayfa, Oxford University Press, New York, 2003.
74. Özdamar K, SPSS ile Biyoistatistik, Beşinci baskı, 506 sayfa, Kaan Kitabevi, Eskişehir, 2005.
75. [http://www.bioen.utah.edu/wiki/index.php?title=Basic\\_Gray\\_Level\\_Transformation](http://www.bioen.utah.edu/wiki/index.php?title=Basic_Gray_Level_Transformation) Gri Seviye Dönüşümü. 15 Aralık 2012.
76. Mäenpää, T. ve Pietikäinen, M., Multi-scale binary patterns for texture analysis, Lecture Notes in Computer Science, 2749, 885-892.
77. Shimada, K., Matsukawa, T., Noguchi, Y. ve Kurita, T., Appearance-Based Smile Intensity Estimation by Cascaded Support Vector Machines, ACCV'10 Proceedings of the 2010 international conference on Computer vision, 277-286.
78. Ahonen, T., Hadid, A. ve Pietikäinen, M., Face Description with Local Binary Patterns: Application to Face Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28, 12 (2006) 2037-2041.
79. Lopez, L. S., Local Binary Patterns applied to Face Detection and Recognition, Yüksek Lisans, Universitat Politècnica de Catalunya, İspanya, 2010.
80. Nabiye, V, V., Teoriden Uygulamalara Algoritmalar, Seçkin Yayıncılık, Ankara, 2009.
81. Nabiye, V, V., Gençtürk, B., Yerel İkili Örnekler Yardımıyla Benzerlik Araştırması, Signal Processing and Communications Applications Conference (SIU), 20, 2012 1-4.

82. Genc Turk, B., Nabyev, V, V., ve Ustubioglu, A., Yüz Benzerliđinin Otomatik Tespiti, 5. Mühendislik ve Teknoloji Sempozyumu, Nisan 2012, Ankara, Bildiriler Kitabı, 129-133.

## ÖZGEÇMİŞ

Beste GENÇTÜRK, 1988 Trabzon doğumludur. İlkokulu Trabzon Cudibey İlkokulu' nda, ortaokulu Trabzon Kanuni Ortaokulu' nda ve liseyi Trabzon Kanuni Anadolu Lisesi'nde tamamlamıştır. Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü'nden 2010 yılında birincilikle mezun olmuştur. Aynı yıl güz döneminde Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans programına, bahar döneminde de aynı bölümde araştırma görevlisi olarak çalışmaya başlamıştır. Halen Bilgisayar Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaktadır. İyi derecede İngilizce bilmektedir.