KTO KARATAY ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK - ELEKTRONİK ANABİLİM DALI
ELEKTRİK VE BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

DERİN ÖĞRENME VE YÜZ BULMA YÖNTEMLERİ KULLANILARAK YÜZ TANIMA

Ayşe Merve BÜYÜKBAŞ

Yüksek Lisans Tezi

KONYA
Eylül 2021

DERİN ÖĞRENME VE YÜZ BULMA YÖNTEMLERİ KULLANILARAK YÜZ TANIMA

Ayşe Merve BÜYÜKBAŞ

KTO Karatay Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik - Elektronik Anabilim Dalı
Elektrik ve Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

Yüksek Lisans Tezi

Tez Danışmanı: Dr. Öğr. Üyesi Ali ÖZTÜRK

Konya
Eylül 2021

BİLDİRİM

Enstitü tarafından onaylanan Yüksek Lisans tezimin tamamını veya herhangi bir kısmını basılı veya dijital biçimde arşivleme ve aşağıda belirtilen koşullar dahilinde erişime açma iznini KTO Karatay Üniversitesine verdiğimi bildiririm. Bu izinle, Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak ve gelecekteki çalışmalar (makale, kitap, lisans, patent vb.) için tezimin tamamının veya bir bölümünün kullanım hakları yalnızca bana ait olacaktır.

Tezimin bütünüyle kendi çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Telif hakkı bulunan ve sahiplerinden yazılı izinle kullanılması zorunlu olan kaynakları, yazılı izin alarak kullandığımı ve istenildiğinde izinlerin suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayımlanan "Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge" kapsamında, tezim, aşağıda belirtilen koşullar haricince, YÖK Ulusal Tez Merkezi ve KTO Karatay Üniversitesi Açık Erişim Sisteminde erişime açılır.

☐ Enstitü / Fakülte Yönetim Kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir.[1]

☐ Enstitü / Fakülte Yönetim Kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren … ay ertelenmiştir.[2]

☐ Tezimle ilgili gizlilik kararı verilmiştir.[3][4]

7 Eylül 2021

Ayşe Merve BÜYÜKBAŞ

[1] MADDE 6(1) Lisansüstü tezle ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulu iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.

[2] MADDE 6(2) Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez danışmanının önerisi ve enstitü anabilim dalının uygun görüşü üzerine enstitü veya fakülte yönetim kurulunun gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.

[3] MADDE 7(1) Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, tezin yapıldığı kurum tarafından verilir. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, ilgili kurum ve kuruluşun önerisi ile enstitü veya fakültenin uygun görüşü üzerine üniversite yönetim kurulu tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.

[4] MADDE 7(2) Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.

ETİK BEYAN

KTO Karatay Üniversitesi Lisansüstü Enstitüsü Tez Hazırlama ve Yazım Kurallarına uygun olarak Dr. Öğr. Üyesi Ali ÖZTÜRK danışmanlığında tarafımdan üretilen bu tez çalışmasında; sunduğum tüm veri, enformasyon, bilgi ve belgeleri bilimsel etik kuralları çerçevesinde elde ettiğimi, tüm değerlendirme, analiz, bulgu ve sonuçları bilimsel usullere uygun olarak sunduğumu, tez çalışmasında yararlandığım kaynakların tümüne bilimsel normlara uygun biçimde atıfta bulunarak kaynak gösterdiğimi, tezimin kaynak gösterilen durumlar dışında özgün olduğunu bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

7 Eylül 2021

_____

Ayşe Merve
BÜYÜKBAŞ

Geleceğe dair yeni umutlar taşıyan ve kendini bilime adayan herkese…

TEŞEKKÜR

Tez çalışmam boyunca beni yönlendiren, araştırmalarımın her aşamasında değerli bilgilerini benimle paylaşan, kendisine ne zaman danışsam benim için kıymetli zamanını ayırıp sabırla ve tecrübeleriyle bana faydalı olabilmek için elinden gelenin fazlasını sunan, karşılaştığım her sorunda güler yüzünü ve samimiyetini benden esirgemeyen ve gelecekteki mesleki hayatımda da bana verdiği değerli bilgilerden faydalanacağını düşündüğüm kıymetli danışman hocam Sayın Dr. Öğr. Üyesi Ali ÖZTÜRK'e,

Çalışmalarım süresince maddi manevi imkanlar sunan ve destek olan hocalarım Dr. Öğr. Üyesi Hüseyin Oktay ALTUN'a,

Bu sürede birçok konuda benden yardım ve bilgilerini esirgemeyen ve yol gösteren değerli arkadaşlarım İskenderun Teknik Üniversitesi Arş. Gör. Leyla BÜYÜKESEN'e ve Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Moleküler Biyoloji Anabilim Dalı Doktora öğrencisi Kadriye Gizem İMRAK'a,

Hayatım boyunca karşılaştığım her türlü zorlukta bana yanımda olup güven veren, hiçbir fedakarlıktan kaçınmayan ve bu hayattaki en büyük şansım olan babam emekli Prof. Dr. Sadık BÜYÜKBAŞ, annem Ayşe BÜYÜKBAŞ'a ve kardeşlerime,

Hayatımda birçok konuda yanımda olup beni düşünen ve her zaman desteklerini hissettiğim tüm sevdiklerime,

sonsuz teşekkürlerimi sunarım.

Eylül, 2021 Ayşe Merve BÜYÜKBAŞ

ÖZET

Ayşe Merve BÜYÜKBAŞ

DERİN ÖĞRENME VE YÜZ BULMA YÖNTEMLERİ İLE YÜZ TANIMA

Yüksek Lisans Tezi

Konya, 2021

Son yıllarda görüntü işleme ile derin öğrenme çalışmalarının popülaritesi hızla artmaya başlamıştır. Özellikle yüz bulma ve yüz tanıma, günümüzde araştırmaların ana konusudur. Yüz tanıma, kişileri belirleyebilmek için mevcut veri tabanındaki görüntüleri kullanır. Diğer bir yöntem olan kamera sistemleri ile görüntüyü yakalayıp ayırt edebilir. Bu tez çalışmasında, görüntü işleme tabanlı yöntemler ve derin öğrenme mimarileri kullanılarak yüz tanıma yöntemleri analiz edilmiştir. Yüz tanımanın ön adımı olan yüz bulma işleminden bahsedilmiştir. Bu işlemden sonra tespit edilen yüzler ile bir veri tabanı oluşturulmuştur. FEI yüz veri tabanı sağ profilden, sol profilden ve orta profilden pozları içeren görüntülerden oluşmaktadır.

Görüntü işleme tabanlı yöntemler için Temel bileşen analizi (TBA), Doğrusal ayrım analizi (DDA) alınarak oluşturulmuş yüz uzayı ile özyüzler ve fisherfaces yöntemleri kullanılmıştır. Yüz tanımada kullanılan özyüzler ve fisherfaces yöntemleri için uygulamalar yapılmış olup, bu iki yöntemin doğruluk oranları karşılaştırılmıştır. Farklı poz varyasyonları ile yapılan çalışmalar için özyüzler ile yüz tanıma doğruluk oranları daha yüksek çıkmıştır. Derin öğrenme mimarileri için AlexNet, Resnet-18, GoogleNet ve SquuezeNet algoritmaları ile yüz tanıma algoritması eğitilmiş ve bu dört yöntemin doğruluk oranları karşılaştırılmıştır. Her bir mimari kendine ait katmanlardan oluşmaktadır. Oluşturulan veri seti mimarinin özelliklerine göre boyutlandırılıp, eğitime girmiştir. Eğitim sonucunda mimarilerin ImageNet ile eğitimi tamamlanmış olup, doğruluk oranları elde edilmiştir. Yüz tanıma yöntemleri ve derin öğrenme mimarilerinin doğruluk performansları karşılaştırılmıştır. Yüz bulma uygulamasında Viola-Jones algoritması ile %85,71 doğruluk oranı, yüz tanımada özyüzler ile %76,66 doğruluk oranı ve derin öğrenme mimarilerinde ResNet-18 ile %100 en yüksek doğruluk oranı elde edilmiştir.

Anahtar Kelimeler

Derin öğrenme, yüz bulma, yüz tanıma, özyüzler, fisherfaces

ABSTRACT

Ayse Merve BUYUKBAS

FACE RECOGNITION WITH DEEP LEARNING AND FACE DETECTION METHODS

Master's Thesis

Konya, 2021

The popularity of deep learning studies with image precessing has started to increase rapidly in recent times. Especially face detection and face recognition are mainstream of research nowadays. Face recognition utilizes the images in the current database to identify the people. It could also discern between the images with another method known as monitor systems. Face recognition methods are analyzed using deep learning architecture and methods based on image processing in this thesis study. It has been touched on face detection what is pre-phase of face recognition. A database was created with the faces they are detected after this process. FEI face database consist of images containing poses from the right profile, left profile and middle profile.

Face space, that is generated by principal component analysis (PCA) and Linear discrimination analysis (LDA), eigenfaces and fisherfaces were used for image processing-based methods. The implementations/applications of eigenfaces and fisherfaces that are used for face recognition and the accuracy rate of two methods are compared. Accuracy rate of studies with different poses for eigenfaces was found out more comparing with fisherfaces. Face recognition algorithm was trained with AlexNet, Resnet-18, GoogleNet and SquuezeNet algorithms for deep learning architectures and the accuracy rates of these four methods were compared. Each architecture consists of its own layers. The created data set was sized according to the features of the architecture and has entered the training. As a result, the training of the architectures with ImageNet was completed and the accuracy rates were obtained. The accuracy performances of face recognition methods and deep learning architectures were compared as well. The highest accuracy rate was 85.71% with the Viola-Jones algorithm in face detection, 76.66% with eigenfaces in face recognition, and 100% with ResNet-18 in deep learning architectures.

Keywords

Deep learning, face detection, face recognition, eigenfaces, fisherfaces

İÇİNDEKİLER

BİLDİRİM i
ETİK BEYAN ii
TEŞEKKÜR iv
ÖZET v
ABSTRACT vi
İÇİNDEKİLER vii
TABLOLAR DİZİNİ ix
ŞEKİLLER DİZİNİ x
SİMGELER DİZİNİ xiii
KISALTMALAR DİZİNİ xv
1. GİRİŞ 1
2. EVRİŞİMSEL SİNİR AĞLARI MİMARİSİ 4
2.1. Evrişimsel Sinir Ağlarını Oluşturan Katmanlar 5
2.1.1. Giriş Katmanı 5
2.1.2. Konvolüsyon Katmanı 5
2.1.3. Havuzlama Katmanı 5
2.1.4. Tam Bağlantılı Katman 6
3. DERİN ÖĞRENME MODELLERİ 7
3.1. AlexNet Algoritması 7
3.2. GoogleNet Algoritması 7
3.3. ResNet Algoritması 8
3.4. SqueezeNet Algoritması 9
4. YÜZ BULMA YÖNTEMLERİ VE ALGORİTMASI 11
4.1. Yüz Bulma Yöntemleri 11
4.1.1. Bilgi Tabanlı Yöntemler 11
4.1.2. Değişmeyen Özellik Yaklaşımları 12
4.1.3. Şablon Eşleştirme Tabanlı Yöntemler 13
4.1.4. Görüntü İşleme Tabanlı Yöntemler 13
4.2. Viola-Jones Algoritması ile Yüz Bulma 15
4.2.1. Haar Benzeri Öznitelikler 15
4.2.2. Resim (İmge) İntegrali 17

4.2.3. AdaBoost Sınıflandırıcı 19
4.2.4. Basamaklandırma Yöntemi 20
5. YÜZ TANIMA YÖNTEMLERİ 22
5.1. Özyüzler ile Yüz Tanıma 22
5.1.1. Temel Bileşen Analizi 22
5.2 Fisherfaces ile Yüz Tanıma 28
6. MATERYAL VE YÖNTEM 32
6.1. Veri Kümesi 32
6.2. Viola-Jones ile Yüz Bulma Yöntemi 33
6.3. Özyüzler ile Yüz Tanıma Yöntemi 34
6.4. Fisherfaces ile Yüz Tanıma Yöntemi 43
6.5. AlexNet ve ResNet-18 Mimarisi ile Yüz Tanıma 47
6.6. GoogleNet ve SqueezeNet Mimarisi ile Yüz Tanıma 62
7. SONUÇLAR 81
KAYNAKLAR 83
ÖZGEÇMİŞ 86

TABLOLAR DİZİNİ

Tablo 1. Bilgi tabanlı yöntemlerin avantajları ve dezavantajları 12
Tablo 2. Değişmeyen özellik yaklaşımlarının avantajları ve dezavantajları..... 13
Tablo 3. Şablon eşleştirme tabanlı yöntemlerin avantajları ve dezavantajları..... 13
Tablo 4. Görüntü işleme tabanlı yöntemlerin avantajları ve dezavantajları 14
Tablo 5. Viola-Jones ile yüz bulma görüntülerinin doğruluk oranı..... 76
Tablo 6. Özyüzler ile yüz tanıma doğruluk oranı 76
Tablo 7. Fisherfaces ile yüz tanıma doğruluk oranı 76
Tablo 8. AlexNet ile yüz tanımada epoch sayısına göre doğruluk oranı 77
Tablo 9. ResNet-18 ile yüz tanımada epoch sayısına göre doğruluk oranı..... 78
Tablo 10. GoogleNet ile yüz tanımada epoch sayısına göre doğruluk oranı 79
Tablo 11. SqueezeNet ile yüz tanımada epoch sayısına göre doğruluk oranı..... 80

ŞEKİLLER DİZİNİ

Şekil 1. Evrişimsel sinir ağları genel mimarisi. 4
Şekil 2. AlexNet derin öğrenme mimarisi 7
Şekil 3. GoogleNet mimarisi (soldan sağa) 8
Şekil 4. ResNet mimarisi bağlantı örneği 9
Şekil 5. SqueezeNet mimarisi 10
Şekil 6. Haar dikdörtgen öznitelikleri 16
Şekil 7. Haar özniteliklerin resim üzerindeki bölgeleri 16
Şekil 8. İntegral görüntüsünün piksel yoğunluğu hesapları 18
Şekil 9. Örnek integral resmin hesaplanmış değerleri 18
Şekil 10. AdaBoost algoritması 19
Şekil 11. Basamaklandırma yöntemi 20
Şekil 12. Sınıflar arası dağılım 23
Şekil 13. N x N görüntü örneği ve dönüştürülmüş hâli 23
Şekil 14. Ortalama görüntünün hesaplanması 24
Şekil 15. Elde edilen en büyük özdeğere sahip özyüzler 26
Şekil 16. Özyüzler algoritması ile sınıflandırma işlevsel blok diyagramı. 28
Şekil 17. LDA için sınıfları ayıran yön 29
Şekil 18. Fisherfaces yüz algoritması ile sınıflandırma işlevsel blok diyagramı 31
Şekil 19. FEI yüz veri tabanındaki kişinin farklı pozları. 32
Şekil 20. Viola-Jones ile örnek yüz tespiti 33
Şekil 21. Örnek yüz resimlerinin çerçeveye alınması 34
Şekil 22. Bir kişiye ait 12 farklı yüz görüntüsü 35
Şekil 23. Ortalama yüz görüntüsü 35
Şekil 24. Fark yüzlerinin görüntüsü 36
Şekil 25. Örnek yüz tanıma 36
Şekil 26. Veri tabanından alınan 30 sağ test görüntüsü 37
Şekil 27. Özyüzler yöntemi ile sağ yüz resmi tanıma 38
Şekil 28. Veri tabanından alınan 30 sol test görüntüsü 39
Şekil 29. Özyüzler yöntemi ile sol yüz resmi tanıma 40
Şekil 30. Veri tabanından alınan 30 orta test görüntüsü 41

Şekil 31. Özyüzler yöntemi ile orta yüz resmi tanıma 42
Şekil 32. Bir kişiye ait 12 farklı yüz görüntüsü 43
Şekil 33. Fisherfaces yöntemi ile sağ yüz resmi tanıma 44
Şekil 34. Fisherfaces yöntemi ile sol yüz resmi tanıma 45
Şekil 35. Fisherfaces yöntemi ile orta yüz resmi tanıma 46
Şekil 36. AlexNet mimarisi özellikleri 47
Şekil 37. Okuma görüntüsü 47
Şekil 38. AlexNet ağının ImageNet ile eğitimi 48
Şekil 39. 25 örnek doğrulama görüntüleri 49
Şekil 40. AlexNet ağının ImageNet ağı ile eğitimi.....49
Şekil 41. Sağ yüz resmi okuma görüntüsü.....50
Şekil 42. AlexNet ağının ImageNet ile eğitimi 50
Şekil 43. 25 örnek doğrulama görüntüleri 51
Şekil 44. Sol yüz resmi okuma görüntüsü.....51
Şekil 45. AlexNet ağının ImageNet ile eğitimi 52
Şekil 46. 25 örnek doğrulama görüntüleri 52
Şekil 47. Orta yüz resmi okuma görüntüsü 53
Şekil 48. AlexNet ağının ImageNet ile eğitimi 53
Şekil 49. 25 örnek doğrulama görüntüleri 54
Şekil 50. ResNet-18 mimarisi özellikleri 54
Şekil 51. Okuma görüntüsü 55
Şekil 52. ResNet-18 ağının ImageNet ile eğitimi 55
Şekil 53. Katmanlardaki işlemler 56
Şekil 54. 25 örnek doğrulama görüntüleri 56
Şekil 55. ResNet-18 ağının ImageNet ile eğitimi 57
Şekil 56. Sağ yüz resmi okuma görüntüsü.....57
Şekil 57. ResNet-18 ağının ImageNet ile eğitimi 58
Şekil 58. 25 örnek doğrulama görüntüleri 58
Şekil 59. Sol yüz resmi okuma görüntüsü.....59
Şekil 60. ResNet-18 ağının ImageNet ile eğitimi 59
Şekil 61. 25 örnek doğrulama görüntüleri 60
Şekil 62. Orta yüz resmi okuma görüntüsü 60

Şekil 63. ResNet-18 ağının ImageNet ile eğitimi 61
Şekil 64. 25 örnek doğrulama görüntüleri 61
Şekil 65. Okuma görüntüsü 62
Şekil 66. Transfer öğreniminden sonra GoogleNet katmanları 62
Şekil 67. GoogleNet ağının ImageNet ile eğitimi 63
Şekil 68. 25 örnek doğrulama görüntüleri 63
Şekil 69. GoogleNet ağının ImageNet ile eğitimi 64
Şekil 70. Sağ yüz resmi okuma görüntüsü 64
Şekil 71. GoogleNet ağının ImageNet ile eğitimi 65
Şekil 72. 25 örnek doğrulama görüntüleri 65
Şekil 73. Sol yüz resmi okuma görüntüsü 66
Şekil 74. GoogleNet ağının ImageNet ile eğitimi 66
Şekil 75. 25 örnek doğrulama görüntüleri 67
Şekil 76. Orta yüz resmi okuma görüntüsü 67
Şekil 77. GoogleNet ağının ImageNet ile eğitimi 68
Şekil 78. 25 örnek doğrulama görüntüleri 68
Şekil 79. Okuma görüntüsü 69
Şekil 80. Transfer öğreniminden sonra SqueezeNet katmanları 69
Şekil 81. SqueezeNet ağının ImageNet ile eğitimi 70
Şekil 82. 25 örnek doğrulama görüntüleri 70
Şekil 83. SqueezeNet ağının ImageNet ile eğitimi 71
Şekil 84. Sağ yüz resmi okuma görüntüsü 71
Şekil 85. SqueezeNet ağının ImageNet ile eğitimi 72
Şekil 86. 25 örnek doğrulama görüntüleri 72
Şekil 87. Sol yüz resmi okuma görüntüsü 73
Şekil 89. 25 örnek doğrulama görüntüleri 74
Şekil 90. Orta yüz resmi okuma görüntüsü 74
Şekil 91. SqueezeNet ağının ImageNet ile eğitimi 75
Şekil 92. 25 örnek doğrulama görüntüleri 75

SİMGELER DİZİNİ

Simge	Açıklama
R_{white}	Dikdörtgen içindeki beyaz bölge
R_{black}	Dikdörtgen içindeki siyah bölge
F_{Haar}	Dikdörtgenlerin alanları arasındaki fark
$E(R_{\mu}^{2})$	Standart sapmayı
w	Genişlik
h	Yükseklik
A	İlk köşe noktası
B	İkinci köşe noktası
C	Üçüncü köşe noktası
D	Dördüncü köşe noktası
ii_1	İlk kutucuk içindeki sayı
ii_2	İkinci kutucuk içindeki sayı
ii_3	Üçüncü kutucuk içindeki sayı
ii_4	Dördüncü kutucuk içindeki sayı
sum	Toplam
α	Anlamlılık katsayısı
X_1	İlk eğitim örneği
Y_1	İlk eğitim örneği
X_n	Son eğitim örneği
Y_n	Son eğitim örneği
m	Pozitif örnek sayısı
n	Negatif örnek sayısı
$w_{1,i}$	Ağırlıklar
T	İterasyon sayısı
ε_t	Hata
h_t	Sınıflayıcı
Σ	Toplam
D	Doğru
Y	Yanlış
N	Piksel sayısı

I	Yüz veri tabanındaki görüntü
Ψ	Ortalama görüntü vektörü
M	Toplam görüntü sayısı
Γ	Görüntü vektörü
Φ	Ortalama görüntüden farkı alınmış görüntü vektörü
A	Veri tabanı matrisi
C	Kovaryans matrisi
v_i	Özvektörler
μ_i	Özdeğerler
ω	Ağırlık vektörü
Ω	Ağırlık matrisi
ε	Öklid mesafesi
Φ_i	Ortalama görüntüden farkı alınmış sınıf içi görüntü vektörü
S_w	Sınıf içi saçılma matrisi
S_b	Sınıflar arası saçılma matrisi
$P(C_i)$	Önsel sınıf olasılığıdır
g	Ağırlık vektörü

KISALTMALAR DİZİNİ

Kısaltma	Açıklama
CNN	Convolutional Neural Network
Conv	Konvolüsyon
FEI	Faculdade de Engenharia Industrial
Fire	Ateşleme
HE	Histogram Equalization
HMM	Gizli Markov modelleri
ICA	Bağımsız Bileşenler Analizi
ILSVRC	ImageNet Large Scale Visual Recognition Challenge
LBP	Yerel İkili Örüntü
LDA	Doğrusal Ayraç Analizi
PCA	Principal Component Analysis
PICO	Pixel Intensity Comparison-based Object detection
ReLU	Rectified Linear Unit
RGB	Red-Green-Blue
SVM	Destek vektör makinesi
TBA	Temel Bileşen Analizi

1. GİRİŞ

Son yıllarda teknolojinin büyümesiyle yüz tanıma çalışmaları ve kullanım alanları oldukça yaygınlaşmıştır. Günümüzde ortaya çıkan Covid-19 salgını nedeniyle ölümler arttı, hijyen açısından önlemler alındı. Bu noktada okul, havaalanı, alışveriş merkezi ve hastane gibi kalabalık yerlerde temassız geçişlerde güvenliği sağlamak amacıyla yüz tanıma önemli hale geldi. Kekül, Bircan ve Arslan'a (2018) göre "yüz tanıma sistemleri, insanların digital imgeler aracılığıyla kaydedilmiş yüzleri ile eğitilen bir sisteme, insanların eğitim aşamasında kullanılmayan yeni bir dijital yüz imgesi verildiğinde kimlik tespitinin yapıldığı uygulamalardır" (s. 52).

Literatürde geçmişten günümüze yüz algılama ve tanıma problemi ile ilgili birçok yöntem geliştirilmiştir. Wang (2014) tarafından yapılan çalışmada, yüz algılama yöntemi için Viola-Jones dedektörü hızlı ve doğru bir algılama sağlamak için Haar-like özellik hesaplaması için integral görüntü, özellik seçimi için Adaboost ve dikkat basamaklı sınıflandırıcılar olmak üzere üç bileşen kullanmıştır. Bir yüz dedektörü, rastgele boyuttaki bir görüntünün içerisinde insan yüzü içerip içermediğini ve mevcut ise nerede olduğunu söylemelidir (s. 128).

Lucena, Oliveira, Veloso ve Pereira (2017), cilt özelliklerinin sonradan işlenmesine dayalı olarak yüz algılamayı iyileştiren bir yaklaşım sunmuşlardır. Yüz algılama için Viola-Jones ve PICO algoritması kullanmışlardır (s. 301).

Lan ve Zhiyong (2016), geleneksel Adaboost yüz algılama algoritması, yüz bölgesinde algılama hata oranı düşük olan yüz sınıflandırıcıları eğiten Haar benzeri sınıflandırıcılar kullanmıştır. Karmaşık arka plan altındayken, sınıflandırıcılar benzer yüzler gri seviye dağılımına sahip arka plan bölgelerine kolayca yanlış tespit yapacaktır. Bu da geleneksel Adaboost algoritmasının hata tespit oranının yüksek olmasına yol açmaktadır. Deneysel sonuçlar, geleneksel yöntemlerle karşılaştırıldığında önemli ölçüde iyileştiği göstermektedir (ss. 598-602).

Holat ve Kulaç (2014), yüz bulma ve tanıma sistemleri kullanarak kimlik tanıma için özyüzler, fisherfaces ve yerel ikili örüntü yöntemlerini kullanmışlardır. Özyüzler için temel bileşen analizi (PCA), fisherfaces için doğrusal ayraç analizi (LDA) ve farklı ölçekteki dokuların analizi için yerel ikili örüntü (LBP) kullanmışlardır. Filtreler için

Medyan, Gauss ve Laplace kullanmışlardır. LBP + HE + Medyan yöntemi %85 olup en başarılı tanıma sonucunu vermiştir (s. 62).

Doğan ve Türkoğlu (2019), derin öğrenme katmanlarını giriş, konvolüsyon, aktivasyon, havuzlama, tam bağlı, dropout, sınıflandırma, yumuşatma ve normalizasyon katmanı olarak sınıflandırmıştır. Giriş katmanı veri giriş katmanı olarak bilinmektedir. Sinir ağlarında oluşturulacak olan veri seti ağın mimarisine göre belirlenmelidir. Konvolüsyon katmanı, konvolüsyonel sinir ağlarını oluşturan temel katmandır. Bu katmanda girdi verisi üzerinde daha önceden belirlenmiş bir filtrenin, girdi verisi üzerinde gezdirilerek girdinin belirgin özelliklerinin ortaya çıkması hedeflenmiştir. Genellikle konvolüsyon katmanından sonraki katman aktivasyon katmanıdır. Pekçok aktivasyon katmanı olmasına rağmen derin öğrenme mimarilerinde ReLU (*Rectified Linear Unit*) katmanı kullanılmaktadır. Havuzlama katmanı daha çok ReLU katmanı sonrasında yer alan ve verilerin indirgenerek ağ içerisinde sonraki katman için giriş boyutunu azaltmayı sağlayan katmandır. Tam bağlı katmandaki nöronların tamamı bu katmana bağlı önceki katmandaki aktivasyonların hepsine tam bağlı durumdadır. Bu katmanın özelliği önceki katmana bağlı olarak ortaya çıkar. Nesneyi belirleyecek olan özelliklerin hangi sınıfla ilişkili olduğu belirlenir. Dropout katmanı tam bağlı katmanlar için bir düzenleme katmanıdır. Sınıflandırma katmanı ise tam bağlı katmandan sonra gelir ve sınıflandırılması yapılacak öğe sayısı kadar sonuç üretir. Yumuşatma katmanı kendisinden önce gelen tam bağlı katmandan girdi verisini alır ve sınıflandırmak için kullanır. Normalizasyon katmanı derin konvolüsyonel sinir ağlarının eğitilme süresini azaltmak için nöronların aktivasyonlarını normalize etmektedir (ss. 416-419).

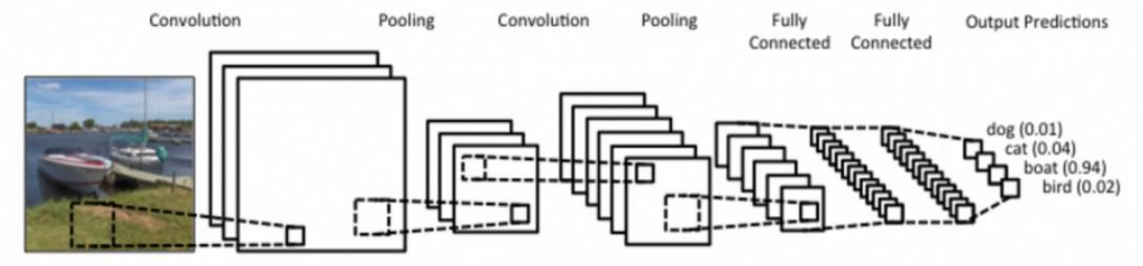
Çalışmanın ikinci bölümünde ise evrişimsel derin öğrenme mimarileri, üçüncü bölümünde ise derin öğrenme mimarileri ile yüz tanıma algoritmaları incelenmiştir. AlexNet, ResNet-18, GoogleNet ve SquuezeNet algoritmaları kullanılmıştır. ResNet18 ve GoogleNet algoritmaları için yüz imgelerinin boyutları 224 x 224 olarak kırpılmıştır. AlexNet ve SquuezeNet algoritmaları için yüz imgelerinin boyutu ise 227 x 227 olarak kırpılmıştır. AlexNet algoritması 25 katman, Resnet-18 algoritması 72 katman, GoogleNet algoritması 144 katman ve SquuezeNet algoritması 68 katmandan oluşmaktadır.

Çalışmanın dördüncü bölümünde yüz bulma ve tanıma yöntemleri açıklanmıştır. Yapılacak çalışma için görüntü tabanlı yöntemler seçilmiştir. Beşinci bölümünde yüz tanıma yöntemleri için özyüzler ve fisherfaces algoritmaları açıklanmıştır. Özyüzler için PCA algoritması kullanılmıştır. Algoritma veri matrisi, kovaryans matrisi, özdeğer ve özvektörler, özimgeler, ağırlık matrisi, ağırlık vektörü, öklid mesafesi ve yüz tespiti olmak üzere 8 ana bileşenden oluşmaktadır. Fisher için LDA algoritması kullanılmıştır. Algoritma sınıf içi ortalama imge, ortalama imge saçılma matrisleri, özvektör matrisi, fisher uzayı, ağırlık matrisi, ağırlık vektörü, öklid mesafesi ve yüz tespiti olmak üzere 7 ana kısımdan oluşmaktadır. Altıncı bölümde ise yüz bulma, yüz tanıma ve derin öğrenme yöntemleri kullanılarak yüz tanıma algoritması eğitilmiştir. Yüz tanıma ve derin öğrenme yöntemlerinin başarı oranları karşılaştırılmıştır. Son bölümde, tez kapsamında yapılan çalışmaların sonuçları ile ilgili değerlendirmeler yapılmıştır.

2. EVRİŞİMSEL SİNİR AĞLARI MİMARİSİ

Evrişimsel sinir ağları mimarisi çok katmanlı dedektörün özel çeşidi olan ve insana ait görme özelliğinin modellenmesi sayesinde oluşmuştur. Görüntü işleme alanında başarılı sonuçlar vermesi sebebiyle günümüzde tercih edilip sık kullanılmaktadır (Kızrak ve Bolat, 2018).

Evrişimsel sinir ağları mimarisine göre ilk birkaç aşama konvolüsyon (convolutional) ve havuzlama (pooling) katmanlarından oluşmaktadır. Son aşaması ise tam bağlı katman ve hemen ardından sınıflandırma katmanı oluşur. Evrişimsel sinir ağları birden fazla eğitilebilir bölümlerden oluşur ve devamında eğitici bir sınıflandırıcı ile devam eder. Giriş verileri alındıktan sonra katman katman işlemler yapılarak eğitim süreci gerçekleştirilir. Son olarak doğru sonuç ile karşılaştırma yapabilmek için bir final çıktısı verir. Üretilen sonuç ile istenen sonuç arasındaki fark kadar hata oluşur. Geriye yayılım algoritması bu hatanın bütün ağırlıklara aktarılması için kullanılır. Her bir iterasyonla birlikte ağırlıkların güncellemesi yapılarak hatanın azaltılması sağlanır. Evrişimsel Sinir Ağlarının mimarisi Şekil 1'deki katmanlardan oluşan bir sinir ağı türüdür (Sert, 2020).



Şekil 1. Evrişimsel sinir ağları genel mimarisi.

Kaynak: Britz (2015)

Şekilde görülen mimaride giriş resmi üzerinden iki tane konvolüsyon katmanı, iki tane havuzlama katmanı ve iki tane tam bağlı katmandan sonra çıkış katmanı gelmektedir. Giriş resmi katmanlardan geçerek eğitildiğinde elde edilen çıktı görüntüsü köpek, kedi ve kuş gibi sınıflandırma isimlerine sahip görüntüler vermektedir.

2.1. Evrişimsel Sinir Ağlarını Oluşturan Katmanlar

2.1.1. Giriş Katmanı

Giriş katmanı CNN'ni oluşturan ilk katmandır. Bu katmanda veri işlenmemiş olarak ağa verilmektedir. Tasarlanacak modelin performansı için bu katmandaki verinin boyutu önem kazanmaktadır. Giriş görüntü boyutunun yüksek seçilmesi hem yüksek bellek ihtiyacını hem eğitim süresini hem de görüntü başına düşen test süresini uzatabilir. Bununla birlikte ağ başarısını arttırabilir. Giriş görüntü boyutunun düşük seçilmesi bellek ihtiyacını azaltır ve eğitim süresini kısaltır. Ancak kurulacak ağın derinliği azalır ve performansı düşük olabilir. Görüntü analizinde ağ derinliği, donanımsal hesaplama maliyeti ve ağ başarısı için uygun bir giriş görüntü boyutu seçilmelidir (Sert, 2020).

2.1.2. Konvolüsyon Katmanı

CNN'nin temelini oluşturan bu katman dönüşüm katmanı olarak da bilinir. Bu dönüşüm işlemi belirli bir filtrenin tüm görüntü üzerinde dolaştırılması işlemine dayanmaktadır. Bu sebeple filtreler katmanlı mimarinin ayrılmaz bir bileşenidir. Filtreler 2 x 2, 3 x 3 ve 5 x 5 gibi farklı boyutlarda olabilir. Filtreler, bir önceki katmandan gelen görüntülere konvolüsyon işlemini uygulayarak çıkış verisini oluşturur. Bu konvolüsyon işlemi sonucu aktivasyon (özellik) haritası oluşur. Aktivasyon haritası, her bir filtreye özgü özelliklerin keşfedildiği bölgelerdir. CNN'lerin eğitimi esnasında bu filtrelerin katsayıları, eğitim kümesindeki her öğrenme tekrarıyla değişir. Böylelikle ağ özelliklerinin belirlenmesi için, verinin hangi bölgelerinin önem taşıdığını belirler (Sert, 2020).

2.1.3. Havuzlama Katmanı

Havuzlama katmanı, genellikle ReLU katmanından sonra yerleştirilir. Temel amacı, sonraki konvolüsyon katmanı için giriş boyutunu (genişlik x yükseklik) azaltmaktadır. Bu işlem veride derinlik boyutunu etkilemez. Katman sonucu boyuttaki azalma bilgi kaybına yol açar. Böyle bir kayıp ağ için iki nedenden dolayı faydalıdır. Birincisi, bir sonraki ağ katmanları için daha az hesaplama yükü oluşturur. İkincisi ise sistemin ezberlemesini önler. İlk basamakta gerçekleştirilen konvolüsyon işlemi gibi, havuzlama katmanında da belli filtreleri tanımlar. Bu filtreler, görüntü üzerinde belli bir adım atma

değerine göre gezdirilerek görüntüdeki piksellerin maksimum değerlerini (maksimum havuzlama) veya değerlerin ortalamasını (ortalama havuzlama) alarak işlem yapılır. Genellikle maksimum havuzlama daha iyi performans gösterdiği için tercih edilir (Sert, 2020).

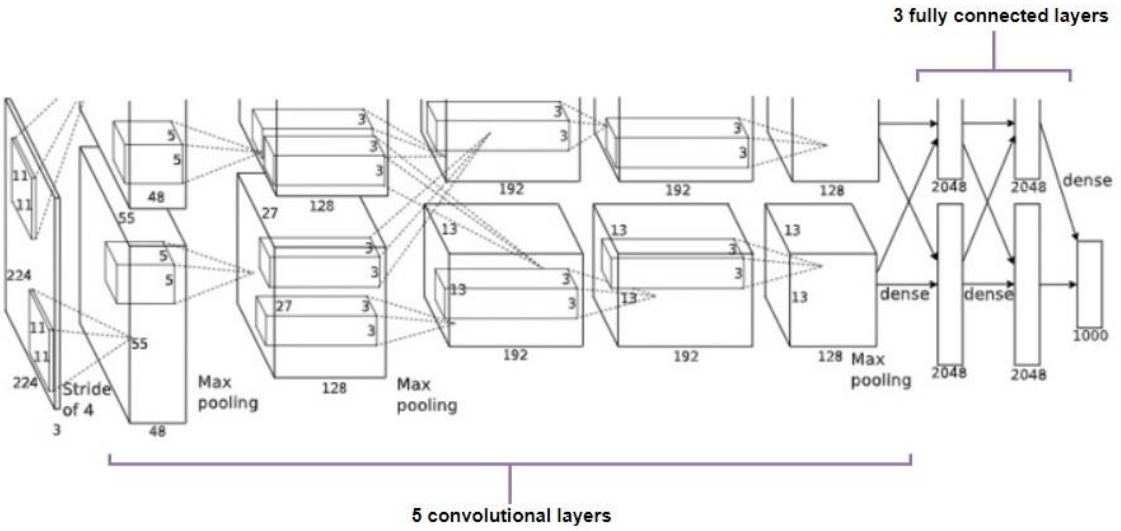
2.1.4. Tam Bağlantılı Katman

CNN mimarisinde ard arda gelen konvolüsyon, ReLU ve havuzlama katmanından sonra tam bağlantılı katman gelmektedir. Bu katman kendinden önceki katmanın tüm alanlarına bağlıdır. Farklı mimarilerde bu katmanın sayısı değişebilir. CNN mimarisinde en son katmanın üretmiş olduğu matris boyutu 25 x 25 x 256 = 160000 x 1 ve tam bağlantılı katmandaki matris boyutu 4096 x 1 olarak seçilirse toplamda 160000 x 4096 ağırlık matrisi oluşur. Her bir 160000 nöron 4096 nöronla bağlanmaktadır. Bu sebepten dolayı bu katmana tam bağlantılı katman denilmektedir (Sert, 2020).

3. DERİN ÖĞRENME MODELLERİ

3.1. AlexNet Algoritması

AlexNet algoritması Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından bulunan bir derin öğrenme algoritmasıdır (Krizhevsky, Sutskever ve Hinton, 2012). Bu derin konvolüsyonel sinir ağı beş adet konvolüsyon katmanı, üç tane maxpool katmanı, iki tane dropout katmanı, üç tane tam bağlı katman, yedi tane ReLU katmanı, iki tane normalizasyon katmanı, yumuşatma (*softmax*) katmanı, giriş ve çıkış katmanı olmak üzere 25 katmandan oluşur. Giriş katmanında yer alan görüntü 227 x 227 x 3 boyutundadır. Son katmanda ise sınıflandırma yapılarak giriş görüntüsündeki sınıflandırma sayısı değeri verilir. ImageNet veri tabanında doğruluk oranı %80'i yakalamış bir derin öğrenme algoritmasıdır (Doğan ve Türkoğlu, 2018). AlexNet derin öğrenme mimarisi Şekil 2'de gösterilmiştir.



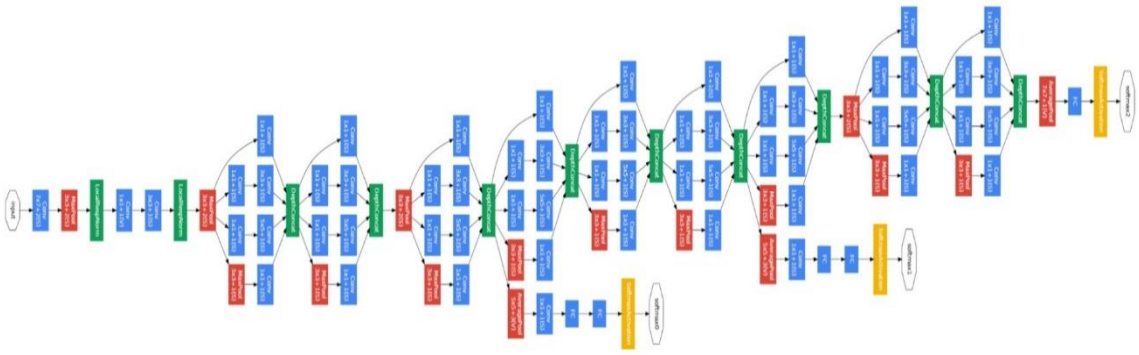
Şekil 2. AlexNet derin öğrenme mimarisi

Kaynak: Krizhevsky vd., (2012)

3.2. GoogleNet Algoritması

GoogleNet algoritması 2014 yılında yapılmış olan ILSVRC yarışmasının kazananı olmuştur (Szegedy vd., 2015). Algoritmanın yapısı komplekstir. Oldukça az bir hata oranıyla yüksek doğruluk oranına sahiptir (Doğan ve Türkoğlu, 2019). GoogleNet

algoritması ImageNet veri tabanında doğruluk oranı %93'ü elde etmiş bir derin öğrenme algoritmasıdır. AlexNet'den 12 kat daha fazla parametre içermektedir. Havuzlama katmanları dahil olmak üzere 27 katman derinliğe sahiptir. Mimari yapısı yaklaşık olarak 100 katmandan oluşmaktadır. Algoritmada konvolüsyon, maxpooling, softmax layer, fullconnected layer, ReLu layer, giriş katmanı ve çıkış katmanı olmak üzere toplam 144 katman bulunmaktadır. Giriş katmanındaki görüntü 224 x 224 x 3 boyutundadır (Doğan ve Türkoğlu, 2018). GoogleNet mimarisi Şekil 3'teki gibi görülmektedir.



Şekil 3. GoogleNet mimarisi (soldan sağa)

Kaynak: Szegedy vd., (2015)

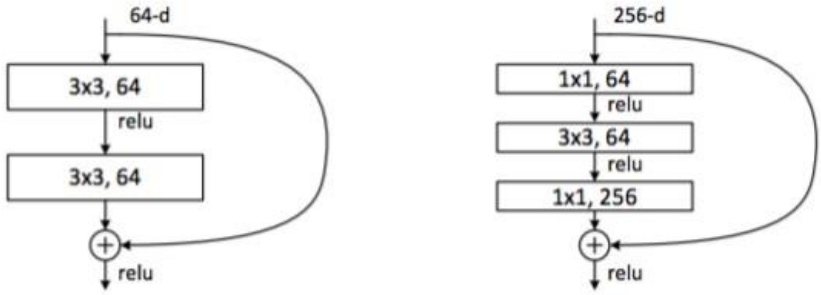
Konvolüsyon katmanı içerisinde 1 x 1, 3 x 3 ve 5 x 5 boyutunda filtreler kullanılır (Doğan ve Türkoğlu, 2018). GoogleNet mimarisinin naive ve inception olmak üzere iki tip bölümü vardır. Naive bölümü 1 x 1, 3 x 3, 5 x 5 konvolüsyon filtreleri ile 3 x 3 maksimum havuzlama katmanı ve önceki katmandan oluşmaktadır. Inception bölümü ise dört tane 1 x 1, 3 x 3, 5 x 5 konvolüsyon filtreleri ile 3 x 3 maksimum havuzlama katmanı ve önceki katmandan oluşmaktadır. Bu modüllerde kullanılan filtreler boyutu azaltmak amacıyla kullanılmaktadır. Kullanılmakta olan katman sayıları çeşitlilik gösterebilir. Öteki derin öğrenme mimarilerindeki katmanlardan farklılaşmış bir yapıya sahip olduğu görülmüştür (Doğan ve Türkoğlu, 2019).

3.3. ResNet Algoritması

ResNet algoritması ResNet18, ResNet50 ve ResNet101 mimarilerine farklı sayıda hesaplama parametrelerine sahiptir. Bu modellerin derinlikleri sırasıyla 18, 50 ve 101 katman sayıları ise 72, 177 ve 347 adet katmandan oluşmaktadır (Raghu, Sriraam,

Temel, Rao ve Kubben, 2020). Giriş katmanı 224 x 224 x 3 boyutundadır. Genellikle ResNet mimarisinde 1 x 1 ve 3 x 3 filtre yapıları kullanılmaktadır. Bu filtreler kullanılan ResNet modeline göre değişmektedir. Matlab ResNet-18 mimarisinde konvolüsyon katmanları için 112 x 112, 56 x 56, 28 x 28, 14 x 14 ve 7 x 7 filtre yapıları kullanılmaktadır.

Şekil 4'te ResNet mimarisine ait bağlantı örneği görülmektedir (Doğan ve Türkoğlu, 2018).



Şekil 4. ResNet mimarisi bağlantı örneği.

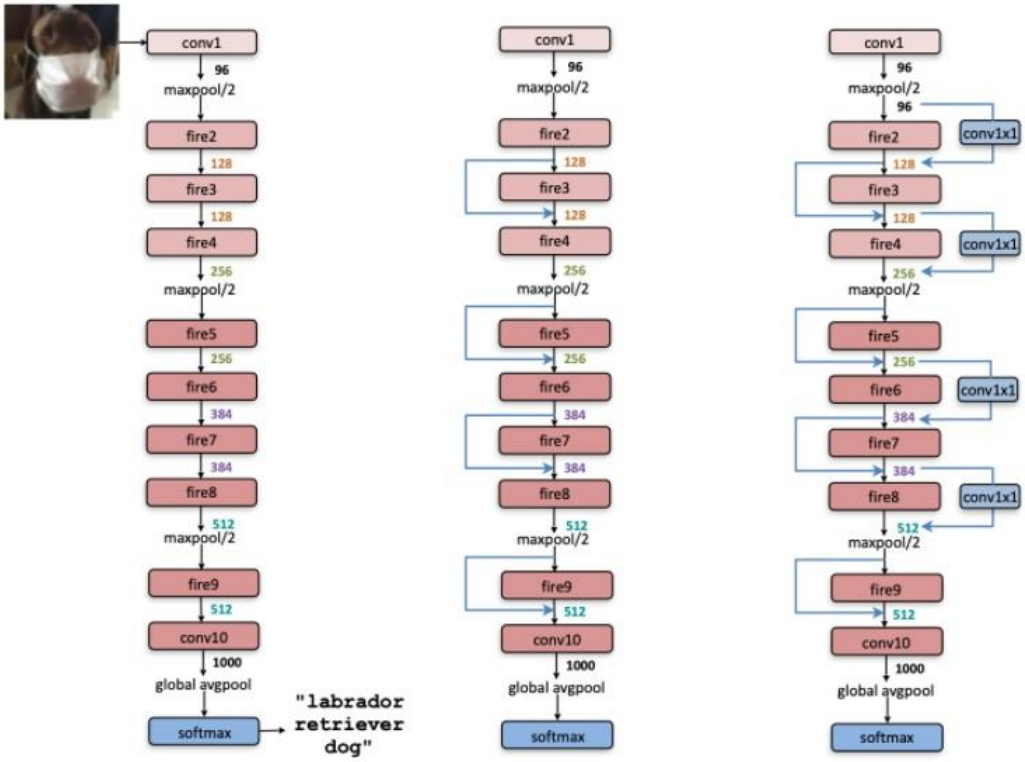
Kaynak: Doğan ve Türkoğlu (2018)

3.4. SqueezeNet Algoritması

Evrişimsel Sinir Ağları modelinde kullanılan başka popüler mimari ise SqueezeNet mimarisidir. Bu mimarinin amacı daha az parametreye sahip bir sinir ağı oluşturmaktır. 50 kat daha az parametre ile AlexNet düzeyinde doğruluk sağlamaktadır. SqueezeNet mimarisinin avantajı ise daha verimli dağıtılmış katmanlar sayesinde sinir ağındaki iş yükünü azaltmakta ve böylece daha hızlı çalışmaktadır (Aksoy, Halis ve Salman, 2020). SqueezeNet mimarisi ilk olarak Iandola ve arkadaşları ile yapmış oldukları çalışmada gösterilmiştir. Algoritma giriş köpek görüntüsü, her bir algoritmada conv1 ve conv10 iki tane konvolüsyon katmanı, fire2, fire3, fire4, fire5, fire6, fire7, fire8 ve fire9 olmak üzere toplam sekiz tane ateşleme modülü ve son olarak softmax olarak yumuşatma katmanı bulunmaktadır. İlk konvolüsyon katmanında, dördüncü ateşleme modülünde, sekizinci ateşleme modülünde ve 10. konvolüsyon katmanında havuzlama katmanları bulunmaktadır. Giriş resmi üzerinden bu katmanlarda eğitime girdikten sonra sonuç çıktısı üretmektedir. 1 x1 ve 3 x 3 filtre yapılarından gelen çıkış aktivasyonlarını aynı

yükseklik ve genişliğe sahip olabilmesi amacıyla, genişletme modüllerinin 3 x 3 filtre giriş verisine bir piksellik sıfır dolgulu kenar eklemişlerdir. Daha sonra ReLU adımı ve %50 oranında dropout katmanı uygulamışlardır. SqueezeNet mimarisini 0,04 değeriyle eğitmeye başlamışlardır (Iandola vd., 2016). Eğitimler sonucunda çıkışta köpek sınıfına ait olduğu bulunmuştur.

SqueezeNet mimarisine ait katmanlar ve bağlantıları Şekil 5'te gösterilmiştir.



Şekil 5. SqueezeNet mimarisi

Kaynak: Iandola vd., (2016)

4. YÜZ BULMA YÖNTEMLERİ VE ALGORİTMASI

4.1. Yüz Bulma Yöntemleri

Yüz bulma sistemi, yüz tanıma için ilk adımdır ve görüntü üzerindeki yüzleri algılamak için kullanılır. Yüz tespiti ve tespit edilen yüz imgesinin konumlandırılması işlemi yüz tanıma uygulamalarında kullanılan en önemli işlemlerden birisidir (Mamak, Konyar, Solak ve Uçar, 2020). Araştırmacılar, bir yüzü etkin ve verimli bir şekilde tanımak için çok sayıda algoritma önermişlerdir. Bu amaçla, bireyler için ağız, burun, göz, yüz şekli konumu ve boyutu gibi özelliklerin saptanmasına odaklanmışlardır. Yüz tanımayı zorlaştıran yaş, yüzün kısmi bölümünü kapatma, poz varyansı, aydınlatma gibi etkenlerdir (Lal ve Kumar, 2018).

Literatürde yüz bulma sistemi için kullanılan çeşitli yöntemler bulunmaktadır. Yüz bulma yöntemlerini dört kategoride inceleyecek olursak; bilgi tabanlı yöntemler, değişmez özellik tabanlı yöntemler, şablon eşleştirme tabanlı yöntemler ve görüntü tabanlı yöntemlerdir (Yang, Kriegman ve Ahuja, 2002).

4.1.1. Bilgi Tabanlı Yöntemler

Bilgi tabanlı yöntemler, tipik bir yüzün neyin oluşturduğuna dair insan bilgisini kodlayan yöntemlerdir (Sütçüler, 2006). Örnek bir görüntüdeki yüz genelde birbirine simetrik duran gözler, burun ve ağız olarak görünür (Kaplan, 2018). Karakteristik bir bilgi tabanlı yöntem sürecinde aşağıda belirtilen temel kurallar yüzü arama işlemi sırasında uygulanmaktadır:

(1) Yüzün merkez bölgesi, benzer renk yoğunluğu dağılımı özelliğini gösterir.

(2) Yüzün merkez bölgesindeki ortalama renk yoğunluğu ile diğer bölgelerdeki ortalama renk yoğunluğu arasında önemli farklılıklar bulunur.

(3) Bir test yüz resminde genellikle birbirine simetrik iki göz, bir burun ve ağız gözükmektedir (Sütçüler, 2006).

Bilgi tabanlı yüz bulma yöntemlerinin avantajları olduğu kadar dezavantajları da bulunmaktadır. Bu yüz bulma yöntemlerinin avantajları ve dezavantajları Tablo 1'de gösterilmiştir.

Tablo 1. Bilgi tabanlı yöntemlerin avantajları ve dezavantajları

Avantajları	Dezavantajları
• Yüze ait özellikleri ve bu özelliklere ait ilişkileri tanımlayacak kurallar bulmak çok kolaydır. • Kodlanmış kurallar baz alınarak, bir test resmi içerisindeki yüze ait özellikleri çıkartmak ve ardından aday yüzleri onaylamak uygulaması oldukça kolay yöntemlerdir. • Karmaşık olmayan arka planlarda oldukça başarılı sonuçlar üreten yöntemlerdir.	• İnsan bilgisini kurallara dönüştürmek her zaman kolay olmayabilir. Çok detaylı kurallar kullanıldığında yüzleri bulmak mümkün olmayabilir. Daha az detaylı kurallar kullanıldığında ise hatalı pozitif sonuçlar bulunabilir. • Farklı pozlardaki resimler için bu yöntemlerin uygulanması oldukça zordur.

Kaynak: Sütçüler (2006)

4.1.2. Değişmeyen Özellik Yaklaşımları

Değişmeyen özellik yaklaşımları kenar, renk çeşitliliği, renk yoğunluğu, desen ve şekil gibi insan yüzüne ait değişmez özellikleri kullanarak yüzü tanımayı amaçlar. Bu yöntemde önce test resmindeki aday yüzleri bulurlar ve sonra bunların gerçekten insan yüzü olduklarını ispat ederler. Bunun için en iyi bilinen iki yöntem vardır: rastlantısal graf eşleme ve özellik gruplama. Rastlantısal graf eşleme yönteminde yüz bulma problemi yüze ait özelliklerin geometrik düzenlemesini bulma problemine dönüştürülmüştür. Yüze ait özellikler genellikle çoklu doğrultulama ve çok özellikli Gaussian türevi filtrelerinin ortalama cevaplarından elde edilir. Özellik gruplama yönteminde ise rastlantısal graf eşleme yöntemine benzeyen Gaussian filtrelerin ikinci türevi kullanılarak test resmindeki aday yüz bölgelerinin taranması işlemini gerçekleştirmektedir. Daha sonra her bir özellik ve gruplama Bayesian ağlar içerisinde incelenerek değerlendirilir (Sütçüler, 2006). Değişmeyen özellik yaklaşımlarının avantajları dezavantajları karşılaştırıldığında, dezavantajının daha fazla olduğu görülmektedir.

Bu yaklaşımların avantajları ve dezavantajları Tablo 2'de gösterilmiştir.

Tablo 2. Değişmeyen özellik yaklaşımlarının avantajları ve dezavantajları

Avantajları	Dezavantajları
• Yüze ait özellikler, poz doğrultuları ve aydınlanma koşullarından bağımsızdır.	• Aydınlanma ve resimlerdeki diğer benzeri gürültüler, yüzlerdeki özelliklerin bulunmasını zorlaştırır. • Karmaşık arka planlar üzerindeki yüzlerin bulunması pek kolay değildir.

Kaynak: Sütçüler (2006)

4.1.3. Şablon Eşleştirme Tabanlı Yöntemler

Şablon eşleştirme tabanlı yöntemler, önceden tanımlanmış yüzlere ait kenar ve alan bilgilerini kullanarak bu şablonlara denk düşen modellerin test resmi üzerinde nerede bulunduğunun araştırması esasına dayanmaktadır. Yüzlere ait baskın özellikleri içeren kenar maskesi kullanılarak verilen test resimleri üzerinde yüz bölgelerini bulmaya çalışır (Sütçüler, 2006). Şablon eşleştirme tabanlı yöntemlerin avantajları ve dezavantajları Tablo 3'te gösterilmiştir.

Tablo 3. Şablon eşleştirme tabanlı yöntemlerin avantajları ve dezavantajları

Avantajları	Dezavantajları
Hesaplama bakımından oldukça kolay yöntemlerdir.	Şablonlar eğer yüze yakın bölgelerden itibaren test resimleri üzerinde taranmazlarsa yüzün bulunması çok maliyetli olabilir. Farklı poz doğrultuları için şablon yüzlerin bulunması ve doğru olarak uygulanması çok kolay değildir.

Kaynak: Sütçüler (2006)

4.1.4. Görüntü İşleme Tabanlı Yöntemler

Görüntü işleme tabanlı yöntemlerde çoğunlukla şekil tanıma, makine öğrenmesi ve veri madenciliği konuları kapsamında geliştirilmiş iyi bilinen sınıflandırma algoritmaları kullanılır. Karakteristik bir görüntü tabanlı yöntemler ile yüz bulma süreci belirtilen temel adımları içermektedir.

Belirtilen temel adımlar şunlardır:

(1) Giriş resimlerine önişleme uygulanarak, bu resimlerin yüz bulma sürecine hazır hâle getirilmesi,

(2) Öğrenme ve test resimlerinin tekilleştirilen bir standarda getirilmesi,

(3) Bir sınıflandırma algoritmasının pozitif ve bazen de negatif giriş verileri ile eğitilmesi,

(4) Yüzleri bulabilmek için bir arama stratejisinin uygulanmasıdır.

Giriş resimlerindeki önişleme işlemi, verilen giriş resimlerinin renk çeşitliliği, renk yoğunluğu, arka plan deseni, kenar, şekil, boyut ve kontrast dağılımı gibi özelliklerin tekilleştirilmiş bir standarda getirilmesini amaçlamaktadır. Farklı aydınlanma koşulları, yüz doğrultuları ve arka planlarda çalıştırılması amaçlanan yüz bulma uygulamaları için oldukça önemli bir adımdır (Sütçüler, 2006). İyi bilinen yüz tanıma algoritmalarından bazıları ise şunlardır: Temel bileşenler analizi (PCA), Destek vektör makinesi (SVM), Yapay sinir ağları, Naïve Bayes sınıflandırıcısı, Tümevarımsal öğrenme, Adaboost (Sütçüler, 2006), Doğrusal Ayrımcılık Analizi (LDA), Bağımsız Bileşenler Analizi (ICA), Gizli Markov modelleri (HMM), Kernel metodu (Çınar, 2021).

Görüntü işleme tabanlı yöntemler içerisinde temel bileşen analizi, doğrusal ayrımcılık analizi ve destek vektör makinesi ile ilgili çalışmalar çok tercih edilmektedir. Görüntü işleme tabanlı yöntemlerin avantajları ve dezavantajları Tablo 4'te gösterilmiştir.

Tablo 4. Görüntü işleme tabanlı yöntemlerin avantajları ve dezavantajları

Avantajları	Dezavantajları
• Başarılı ve güçlü makine öğrenmesi algoritmalarını kullanırlar. • İspatlanmış başarılı sonuçlar üretirler. • Hızlı ve etkin çalışırlar. • Farklı boyutlardaki ve doğrultulardaki yüz resimleri için de başarıyla çalışırlar.	• Genellikle resim üstünde tarama işlemi gerektirirler. • Sınıflandırma algoritmalarını eğitmek için birçok pozitif ve negatif örnek gerektirirler.

Kaynak: Sütçüler (2006)

Görüntü işleme tabanlı yöntemler diğer yöntemlere kıyasla çok fazla avantaja sahiptir. Yüz bulma yöntemi için görüntü işleme tabanlı yöntemlerin performansları daha iyi sonuçlar vereceğinden dolayı yapılacak çalışma için görüntü işleme tabanlı yöntemler tercih edilmiştir.

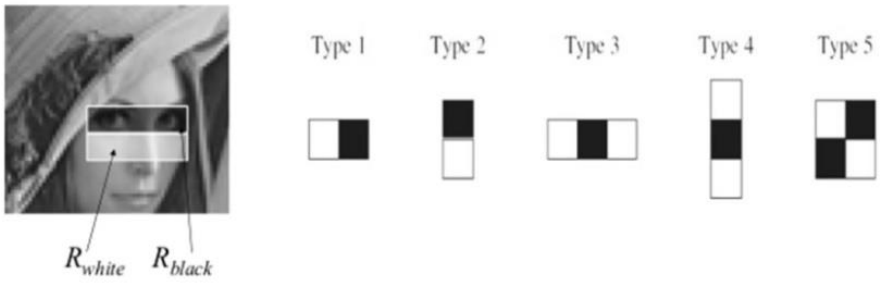
4.2. Viola-Jones Algoritması ile Yüz Bulma

Paul Viola ve Micheal Jones tarafından 2001 yılında geliştirilen Viola-Jones nesne algılama çerçevesi, görüntülerdeki nesneleri doğru ve hızlı bir şekilde algıladığı ve özellikle insan yüzünde iyi çalıştığı gözlenmiştir (Jones ve Viola, 2003). Li, Niaz ve Merialdo (2012) çalışmasında belirttiği gibi, görüntü işleme alanında Viola-Jones nesne dedektörü, en başarılı ve yaygın olarak kullanılan bir yöntemdir. Viola-Jones algoritmasını diğerlerinden ayıran en belirgin özellikler kararlı ve gerçek zamanlı olmasıdır. Doğruluk oranı yüksek bir tanımlama yapması kararlı olduğu anlamına gelmektedir. Yapılan iyileştirmeler ile algoritma saniyede 15 kare ile insan gözünün yakalayamayacağı bir hızda çalışıyor olması gerçek zamanlılığını göstermektedir. Viola-Jones algoritması sırası ile dört ana alt bileşenden oluşmaktadır: Haar Benzeri Öznitelikler, Resim (İmge) İntegrali, AdaBoost Sınıflandırıcı ve Basamaklandırma Yöntemi (Omert, 2020).

4.2.1. Haar Benzeri Öznitelikler

Haar benzeri öznitelikler veya haar öznitelikleri bir pikselde belirlenmiş iki veya daha fazla bitişik dikdörtgensel bölgenin imgecik (piksel) değerlerinin toplamının farkı ile ifade edilir. İki bitişik dikdörtgensel bölgenin kullanımı, iki bitişik dikdörtgensel farkını ve üç dikdörtgensel bölge ise ortadaki bölgenin piksel toplamının dışarıda kalan iki dikdörtgensel bölgenin piksel toplamlarından çıkartılması ile elde edilir. Dört bölgeli Haar öznitelikte ise çapraz dikdörtgensel bölgelerinin piksel toplamlarının farkı ile ifade edilir (Omert, 2020). İkili bitişik dikdörtgenli öznitelik siyah beyazdan oluşan karelerdir. Üç dikdörtgensel öznitelik iki beyaz bir siyahtan oluşan karelerdir. Dört dikdörtgensel öznitelik ise iki siyah ve iki beyaz kareden oluşmaktadır.

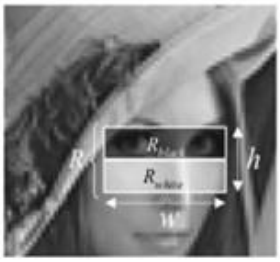
İki bitişik dikdörtgenli (type1 ve type2), üç dikdörtgensel (type3 ve type4) ve dört dikdörtgensel (type5) olmak üzere üç farklı öznitelikler Şekil 6'da gösterilmiştir.



Şekil 6. Haar dikdörtgen öznitelikleri

Kaynak: Omert (2020)

Burada görüntü üzerindeki R_{white} dikdörtgen içindeki beyaz bölgeyi, R_{black} siyah bölgeyi ifade etmektedir. Kestirimde bulunacak nesnenin özelliklerine ve istenilen performansa göre optimum Haar benzeri öznitelikleri seçilerek işlem yapılır. Viola-Jones algoritması çeşitlik pencere boyutlarında (genellikle 24 x 24) alt pencereler ile hedef imgeyi tarayacaktır. Ardından bu imgeye ait Haar benzeri öznitelikler çıkartır. Daha sonra AdaBoost algoritmasına öğretilmiş eşik değerleri ve öznitelik çıkarımları ile bu veriler işleme sokularak o karede yüz olup olmadığı kestirimine ulaşılır. Çıkarılan öznitelik kestirimleri 160 000'in üzerindedir. Bu kadar veriyi değerlendirmek ve elemek büyük bir işlem gücü gerektirmektedir. Bu durumdan dolayı basamak sınıflandırıcı kullanılmaktadır (Omert, 2020). Haar benzeri özniteliklerinin görüntüsü üzerindeki siyah ve beyaz bölgeler Şekil 7'de gösterilmiştir.



Şekil 7. Haar özniteliklerin resim üzerindeki bölgeleri

Kaynak: Omert (2020)

Haar benzeri özniteliklerinin formülü denklem 1'de verilmiştir.

$$F_{Haar} = \frac{E\,(R_{black}) - E\,(R_{white})}{w\,.\,h\,.\sqrt{|E\,(R_{\mu})^{2} - E\,(R_{\mu}{}^{2})|}} \quad (1)$$

Buradaki denklemde F_{Haar} dikdörtgenlerin alanları arasındaki fark, $E(R_{white})$ beyaz bölgedeki yoğunluğu, $E(R_{black})$ siyah bölgedeki yoğunluğu, $E(R_{\mu}^{2})$ standart sapmayı, w dikdörtgen ölçeklendirme için genişliği ve h dikdörtgenin ölçeklendirme için yüksekliği ifade eder. Bölme işlemi piksel değerinin varyansını normalize etmek için uygulanır (Rondahl, 2011).

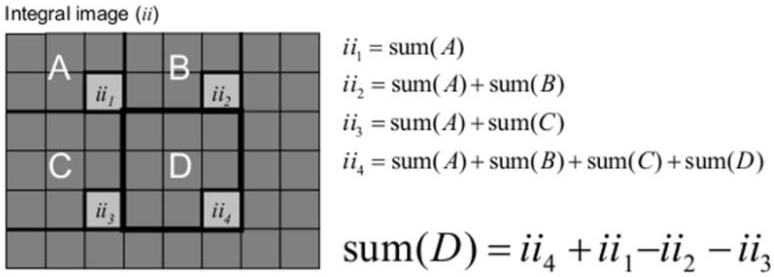
Örnek olarak; göz çukurlarının daha koyu, yanak ve burnun daha parlak piksellere sahip olması nedeniyle bu duruma uygun olarak kullanılan ikili bitişik dikdörtgenlerin piksel yoğunlukları toplamının farkının belirli bir eşik değerinin üzerinde olması taranan veride bir göz bulunduğu önermesini güçlendirmektedir. Paydada bulunan değer fonksiyonun standart sapmasıdır ve normalizasyon olarak ifade edilir. F_{Haar} toplamı standart sapmaya bölünerek normalizasyon sağlanır. Normalizasyon, büyük verileri küçük verilerle ifade edebilmektir. Burada F_{Haar} toplamlarını daha küçük bir aralığa normalize edip işlem yükünü azaltmak için hedeflenmektedir (Omert, 2020).

4.2.2. Resim (İmge) İntegrali

Veri filtreleme ve tanımlama gibi birçok uygulamaya sahip olan görüntü transformasyonu dalgacık dönüşümüyle canlılık kazanmıştır. Birçok nesne dedektörü uygulamasında kullanılan Haar-Cascade sınıflandırıcısı bunlardan biridir (Kaplan, 2018).

Haar özniteliklerinin çıkartılması dikdörtgensel bölgelerdeki piksel yoğunluklarının toplamı ile elde edilir. Belli bir bölgedeki piksel toplamı kullanılan Haar benzeri özniteliği boyutuna ve özelliğine göre değişebilir. Özellikle gerçek zamanlı işlemlerde bu toplamı gerçekleştirmek işlem hantallığına sebep olacaktır. Bu işlem hantallığını gidermek için resim integrali kullanılmaktadır.

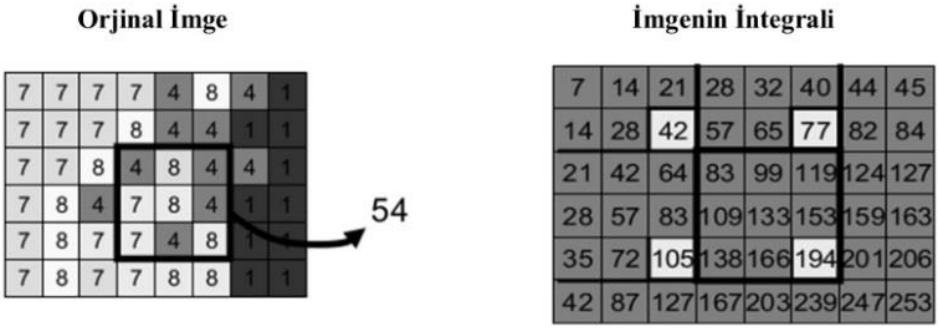
Bir imgenin bir piksel noktasındaki integrali demek, o piksel referans alınarak üst-sol alanında kalan tüm piksel yoğunluklarının toplamı ile elde edilir. İntegrali alınmış bir resimdeki piksel yoğunluğunun hesaplanması ise bir kutucuk üzerindeki dört köşe noktaları üzerinden yapılmaktadır. İntegrali alınmış bir resimde taranan bir alt pencerede yapılan piksel yoğunluğu hesaplaması Şekil 8'de gösterilmiştir (Omert, 2020).



Şekil 8. İntegral görüntüsünün piksel yoğunluğu hesapları

Kaynak: Omert (2020)

Burada A, B, C ve D köşe noktaları, ii_1, ii_2, ii_3 ve ii_4 kutucukların içerisindeki sayıları ve sum (A), sum (B), sum (C) ve sum (D) köşe noktasının toplamını ifade eder. Pikseller toplanarak oluşan integral görüntü örneği Şekil 9'da gösterilmiştir.



Şekil 9. Örnek integral resmin hesaplanmış değerleri

Kaynak: Omert (2020)

Örnek integral resmin hesaplanmış değerleri şekil üzerinden integral görüntünün köşe noktalarındaki değerleriyle 194 + 42 – 77 – 105 = 54 olarak hesaplanır.

4.2.3. AdaBoost Sınıflandırıcı

AdaBoost zayıf sınıflandırıcıların farklı kombinasyonlarıyla kuvvetli bir sınıflandırıcı ortaya çıkartan algoritmadır. AdaBoost Viola-Jones algoritmasında sınıflandırıcının eğitilmesi ve özniteliklerin çıkartılması olarak iki şekilde kullanılmaktadır. Her bir zayıf öğrenici kuvvetli öğrenici denkleminde α anlamlılık katsayısına sahiptir. AdaBoost algoritmasındaki zayıf sınıflandırıcılar birer öznitelikmiş gibi ele alınarak pozitif ve negatif örnekleri en iyi şekilde ayıran öznitelikler aranır (Omert, 2020). AdaBoost algoritmasının çalışma prensibi Şekil 10'daki gösterildiği gibidir.

- Eğitim örnekleri $(x_1, y_1),...,(x_n, y_n)$ olarak düzenlenir. Burada y_i, negatif örnekler için 0, pozitif örnekler için 1 olarak kabul edilir.
- m ve n sırasıyla pozitif ve negatif örnek sayısını göstermek üzere ağırlıklar $w_{1,i} = \frac{1}{2m}, \frac{1}{2l}$ olacak şekilde her $y_i \in \{0,1\}$ için ilklenir.
- T iterasyon sayısı olmak üzere, her t=1,..,T için:
  1. Ağırlıklar normalize edilir.
  $$w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^{n} w_{t,j}}$$
  2. Her bir j özniteliği için, sadece bu j özniteliğini kullanan bir h_j sınıflayıcısı eğitilir. Hata w_t ağırlığına göre ölçülür.
  $$\varepsilon_j = \sum_i w_i \left| h_j(x_i) - y_i \right|$$
  3. En az ε_t hatasına sahip h_t sınıflayıcısı seçilir.
  4. Ağırlıklar güncellenir:
  $$w_{t+1,i} = w_{t,i} \beta_t^{1-e_i}$$
  Burada x_i doğru olarak sınıflandırıldıysa $e_i = 0$, aksi halde $e_i = 1$ olur. β_t ise $\beta_t = \frac{\varepsilon_t}{1-\varepsilon_t}$ olarak hesaplanır.
- Sonunda oluşan sınıflayıcı:
  $$h(x) = \begin{cases} 1, & \sum_{t=1}^{T} \alpha_t h_t(x) > \frac{1}{2} \sum_{t=1}^{T} \alpha_t \\ 0, & diger \end{cases}$$
  burada $\alpha_t = \log \frac{1}{1-\beta_t}$ olarak alınır.

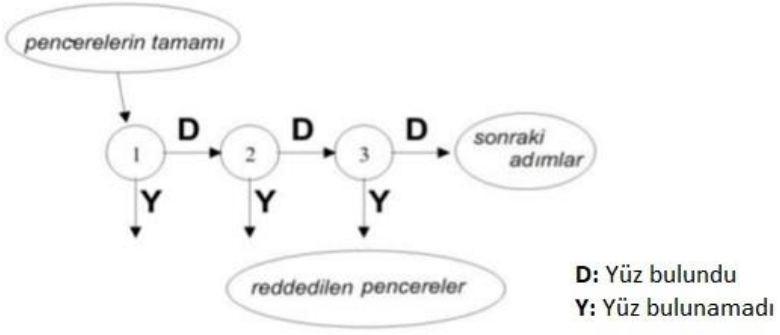
Şekil 10. AdaBoost algoritması

Kaynak: Tetik ve Bolat (2011)

AdaBoost sınıflandırıcı algoritması çalışmaya her bir eğitim örneği için eşit D dağılımı ile başlar. Her adımda sınıflama performansına bağlı olarak en iyi zayıf sınıflayıcı bulunur. Ağırlıklar güncellenerek bir olasılık dağılım fonksiyonu elde edilir. Sonraki adımda bu adımlar tekrar edilir, belirli bir iterasyon sonucunda en güçlü zayıf sınıflayıcılar bir araya getirilerek güçlü bir sınıflayıcı oluşturulur (Tetik ve Bolat, 2011).

4.2.4. Basamaklandırma Yöntemi

Resim birçok Haar benzeri özelliğiyle tarandıktan sonra bir özelliğinden çıkan bulgunun o karede bir yüzün olduğuna dair pozitif veya negatif durumuna göre bir sonraki özellikle ilişkilendirilip ilişkilendirmeme durumuna peş peşe (*cascading*) yöntemi denir. Basamaklandırma yöntemi doğru pozitif örnekleri tespit edip negatif örnekleri hızlı bir şekilde elemek için kullanılır. Sınıflandırıcıları az öznitelik taşıyandan çok öznitelik taşıyana göre farklı boyutlarda ve hassasiyetlerde basamaklandırılır. İçerisinde yüz bulunmayan pencereleri birkaç öznitelik taşıyan basit bir sınıflandırıcı ile elenebilir. Bir pencere birinci dereceden sınıflandırıcıya girdiğinde eğer bu sınıflandırıcıdan geçerse ikinci dereceden sınıflandırıcı tetiklenir. Sonrasında üçüncü ve dördüncü istenilen hassasiyete göre devam eder. Bu yöntem ile her bir pencere yoğun öznitelik içeren sınıflandırıcıdan geçemez ve bu durum işlem yükünü önemli ölçüde azaltarak hız kazandırır (Omert, 2020). Basamaklandırma yönteminin modeli Şekil 11'de gösterilmiştir.



Şekil 11. Basamaklandırma yöntemi

Kaynak: Omert (2020)

Burada yüz bulunduğu zaman doğru, bulunamadığı zaman yanlış cevabını verecektir. Doğrulardan geçen yüzler sonraki adıma geçecektir. Yanlışlardan geçen yüzler ise reddedilen pencereler ile son bulacaktır.

Suma ve Raga (2018) tarafından gerçekleştirilen bir araştırmada, kamera ile yüz tanıma sistemi yüz algılama ve yüz tanıma olarak iki şekilde yapılmıştır. Yüz algılama için yaptıkları çalışmada Viola-Jones algoritmasını yüksek hassasiyet ve gerçek zamanlı olması nedeniyle kullanmışlardır. Yüz tanıma için eğitim ve değerlendirme aşaması olmak üzere iki kategoriyi dikkate almışlardır. Eğitim aşamasında, öğrenilecek görüntünün örnekleri üzerinden algoritma eğitilmiştir. Tahmin aşamasında ise test görüntüsü için veri setinde eğitilmiş tüm örneklerle karşılaştırma yapmışlardır. Yüz algılamada Viola-Jones işlemleri Haar-like öznitelikleri, resmin integrali, AdaBoost eğitimi ve basamaklı sınıflandırıcılar ile yapılmıştır. Viola-Jones algoritması kullanılarak yapılan yüz algılamanın en iyi tanıma oranına sahip olduğu görülmüştür. Yapılan uygulamalar ve testlerden sonra elde edilen deneysel sonuçların doğruluğu %85-%95 olarak bulunmuştur.

5. YÜZ TANIMA YÖNTEMLERİ

Yüz tanıma tekniği iki farklı şekilde yapılmaktadır; resim veya video üzerinden yüz tanıma şeklindedir. Bu çalışma için FEI yüz veri tabanı üzerinden yüz tanıma tekniği yapılmıştır. Yüz tanıma yöntemleri özyüzler (*eigenface*) ile yüz tanıma ve fisherfaces ile yüz tanıma teknikleridir.

5.1. Özyüzler ile Yüz Tanıma

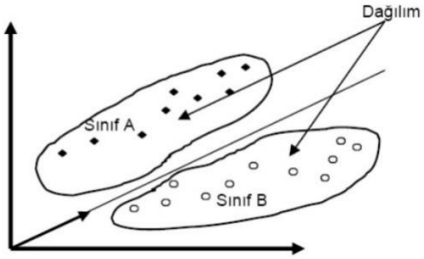
Özyüzler yöntemi ile yüz tanıma ilk olarak Sirovich ve Kirby (1987) tarafından yüzü daha etkili bir biçimde gösterebilmek için kullanılmıştır. Bu yöntemin adı Temel Bileşen Analizi ve PCA (Principal Component Analysis) olarak da bilinmektedir. Temel bileşen analizi (PCA) olarak bilinen bu yöntem Karhunen-Louve dönüşümüne dayanmaktadır. Bu, bilgi teorisinde veriyi kodlama ve kodu çözmede iyi bilinen bir teknik haline gelmiştir. Bu kişiler yüz resimleri gruplarından başlayarak resimlerin temel bileşenlerini hesaplamışlardır. Ardından özvektörün sadece küçük parçalarının ağırlıklı birleşimini kullanarak yüz resmini yeniden oluşturmuşlardır (Holat, 2014).

5.1.1. Temel Bileşen Analizi

Temel Bileşen Analizi (PCA) yüz tanıma amacıyla Turk ve Petland (1991) tarafından geliştirilen boyut azaltmak ve resimler arasındaki başlıca farklılıkları çıkartmak için kullanılan bir özyüz yöntemidir. PCA karşılıklı ilişkisi olan verinin N boyutlu uzay yerinde daha düşük boyutlu uzayda önemli bir bilgi kaybı olmadan boyut azaltmanın en uygun yoludur. Azaltılmış alt uzayı kullanarak, veri tabanı üzerinden hesaplamalar daha verimli hale gelir. Oluşturulan tasvirler genellikle öz uzaylar olarak adlandırılır ve yüz tanıma uygulamalarında ise özyüzler olarak adlandırılır (Erdoğan, 2010).

Yöntemin en önemli özelliği, tanımladığı yeni koordinat sistemindeki boyutların veri setinin varyansı ile doğru orantılı olmasıdır. Boyutlardan bir kısmının veri seti varyansının çoğunluğunu kapsamasından dolayı düşük varyanslı boyutların kullanılmayarak veri setinde büyük ölçüde boyut kazancı sağlamasıdır (Topkaya, 2008).

İki sınıf arasındaki dağılım Şekil 12'de gösterilmiştir.



Şekil 12. Sınıflar arası dağılım

Kaynak: Erdoğan (2010)

Şekil 12'de gösterilen sınıfların dağılımı PCA yöntemi ile daha düzenli bir hâle gelmiştir. Dağılımlar sınıf A ve sınıf B olarak ikiye ayrılmıştır.

Özyüzler yaklaşımında, her biri N x N boyutlu yüz görüntüleri N^2'lik vektörler haline getirilmektedir ve Şekil 13'teki gibidir.



$$= \begin{bmatrix} I1_{11} \dots\dots\dots\dots\dots I1_{1N} \\ I1_{21} \dots\dots\dots\dots\dots I1_{2N} \\ . \qquad\qquad\qquad . \\ . \qquad\qquad\qquad . \\ . \qquad\qquad\qquad . \\ I1_{N1} \dots\dots\dots\dots\dots I1_{NN} \end{bmatrix} \quad \text{I1} = \begin{bmatrix} I1_{11} \\ . \\ I1_{1N} \\ I1_{21} \\ . \\ I1_{2N} \\ . \\ I1_{N1} \\ . \\ I1_{NN} \end{bmatrix}$$

Şekil 13. N x N görüntü örneği ve dönüştürülmüş hâli

Kaynak: Erdoğan (2010)

Burada I yüz veri tabanındaki görüntüleri, N piksel sayısını ifade etmektedir. Daha sonra veri tabanındaki tüm görüntülerden oluşan ortalama görüntü vektörü denklem 2'de gösterildiği gibi hesaplanarak bulunur.

$$\Psi = \frac{1}{M} \sum_{n=1}^{M} \Gamma_n \qquad (2)$$

Burada Γ görüntü vektörü, Ψ ortalama görüntü vektörü ve M toplam görüntü sayısını ifade etmektedir (Erdoğan, 2010).

Ortalama görüntünün hesaplanması ise Şekil 14'te gösterilmiştir.



$$= \frac{1}{M}\begin{bmatrix} I1_1 + \ldots\ldots\ldots + IM_1 \\ I1_1 + \ldots\ldots\ldots + IM_2 \\ \vdots \\ I1_{N^2} + \ldots\ldots\ldots + IM_{N^2} \end{bmatrix}$$

Şekil 14. Ortalama görüntünün hesaplanması

Kaynak: Erdoğan (2010)

Burada I yüz veri tabanındaki görüntüleri, N piksel sayısını ve M toplam görüntü sayısını ifade etmektedir. Kolon vektörü hâline getirilen görüntülere ait pikseller toplanır. Daha sonra bu pikseller toplam görüntü sayısına bölünür, ortalama görüntü ise görüntülenmek istendiğinde elde edilen kolon matrisi N x N boyutlu matrise dönüştürülür.

Ortalama görüntü vektörünün, her bir görüntü vektöründen çıkarılması ile sıfır ortalamaya sahip bir veri tabanı matrisi (A) elde edilmiş olur. Ortalama görüntüden farkı alınmış görüntü vektörü denklem 3'te gösterildiği gibi hesaplanarak bulunur.

$$\Phi_i = \Gamma_i - \Psi \tag{3}$$

Denklem 3'te Φ ortalama görüntüden farkı alınmış görüntü vektörünü, i = 1, 2, …, M ise görüntü sayısını göstermektedir. Görüntü veri tabanı matrisi A denklem 4'teki gibi gösterilir.

$$A = [\Phi_1\ \Phi_2\ \Phi_3 \ldots\ \Phi_M] \tag{4}$$

Denklem 4'te A, N^2 x M boyutundaki görüntü veri tabanı matrisini ifade eder (Erdoğan, 2010). A matrisi ortalama görüntüden farkı alınmış görüntü vektörlerinden oluşmaktadır.

Denklem 5 ortalama merkezli görüntüler matrisinin matematiksel formunu ifade etmektedir.

$$\vec{I}\,1_m = \begin{bmatrix} I1_1 - m_1 \\ I1_2 - m_2 \\ \vdots \\ I1_{N^2} - m_{N^2} \end{bmatrix}, \ldots \quad \vec{I}\,M_m = \begin{bmatrix} IM_1 - m_1 \\ IM_2 - m_2 \\ \vdots \\ IM_{N^2} - m_{N^2} \end{bmatrix} \quad \mathrm{A} = \begin{bmatrix} \vec{I}\,1_m \ldots & \vec{I}\,M_m \end{bmatrix} \qquad (5)$$

Elde edilen görüntü veri tabanından özyüzlerin elde edilebilmesi için A matrisiyle kovaryans işlemi gerçekleştirilir. Kovaryans matrisi (C) formülü denklem 6'daki gibidir.

$$\mathrm{C} = \frac{1}{M} \sum_{n=1}^{M} \Phi_n \, {\Phi_n}^T = \mathrm{A}\, A^T \qquad (6)$$

Elde edilen kovaryans matrisinin boyutu, görüntü vektörünün uzunluğu ile ilişkilidir. N^2'lik görüntü vektörlerinden elde edilecek olan kovaryans matrisi N^2 x N^2 boyutundadır. Kovaryans matrisinin daha düşük boyutta işlem görmesi için denklem 6 yerine denklem 7 kullanılabilir.

$$\mathrm{C} = \frac{1}{M} \sum_{n=1}^{M} {\Phi_n}^T \, \Phi_n = A^T \mathrm{A} \qquad (7)$$

Denklem 6'da elde edilen kovaryans matrisinin özvektörleri v_i olarak ifade edilirse, özdeğerlerin hesaplanması denklem 8'deki hesaplama ile bulunur.

$$A^T \mathrm{A}\, v_i = \mu_i \, v_i \qquad (8)$$

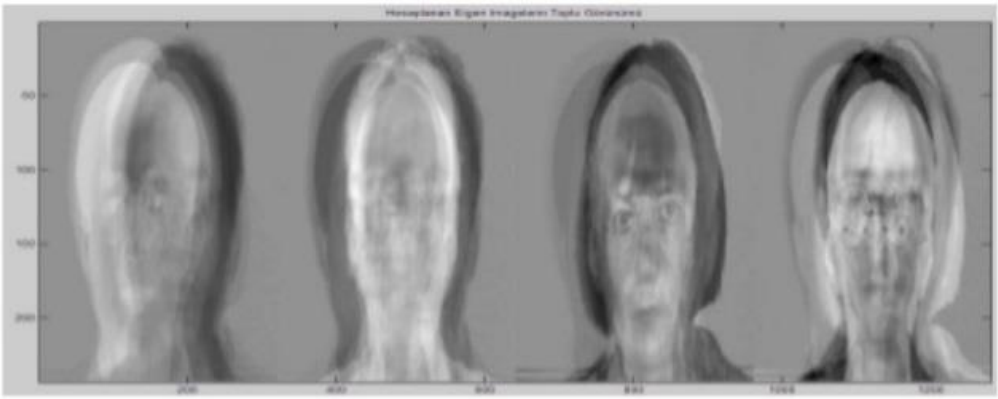
Denklem 8'de v_i özvektörleri μ_i ise özdeğerleri ifade etmektedir. A görüntü veri tabanı matrisini, A^T ise görüntü veri tabanı matrisinin transpozunu göstermektedir.

Eşitliğin her iki tarafı da A görüntü veri tabanı matrisi ile çarpılırsa, denklem 9 ile ifade edilir.

$$A\ A^T A\ v_i = \mu_i\ A\ v_i \tag{9}$$

AA^T matrisinin özvektörleri $A\ v_i$ olarak bulunur. Denklem 7'de elde edilen özvektörler A görüntü veri tabanı matrisi ile çarpılarak istenen özvektörlere ulaşılmış olacaktır.

Buradaki amaç, işlem yükü N^2 x N^2'lik kovaryans matrisini M^2 x M^2'lik kovaryans matrisi oluşturmaya indirgemektir. Şekil 15'te elde edilen en büyük özdeğere sahip ilk dört yüz örnek olarak verilmiştir (Erdoğan, 2010).



Şekil 15. Elde edilen en büyük özdeğere sahip özyüzler

Kaynak: Holat (2014)

Oluşturulan özvektörler özyüz, özyüzlerin oluşturduğu matris ise görüntü uzayı olarak ifade edilmektedir. Tanımlama yapılabilmesi için, her bir görüntünün görüntü uzayı üzerindeki izdüşümünün bulunması ve ağırlık vektörünün oluşturulması gerekmektedir. Ağırlık vektörünün formülü denklem 10'daki gibidir.

$$\omega_k = v_k^T\ A \tag{10}$$

Denklem 10'da ω: ağırlık vektörü (1xM), k = 1, 2, …, M' göstermektedir. Ağırlık vektörleri her bir görüntü için veri tabanında Ω matrisinde saklanmaktadır.

Ağırlık matrisi, ω ağırlık vektörlerinin transpozları matrisi ile denklem 11'deki gibi ifade edilir.

$$\Omega = \left[\omega_1^T \; \omega_2^T \; \ldots \; \omega_{M'}^T\right] \tag{11}$$

Burada Ω ağırlık matrisi (MxM)'ni ifade eder (Erdoğan, 2010).

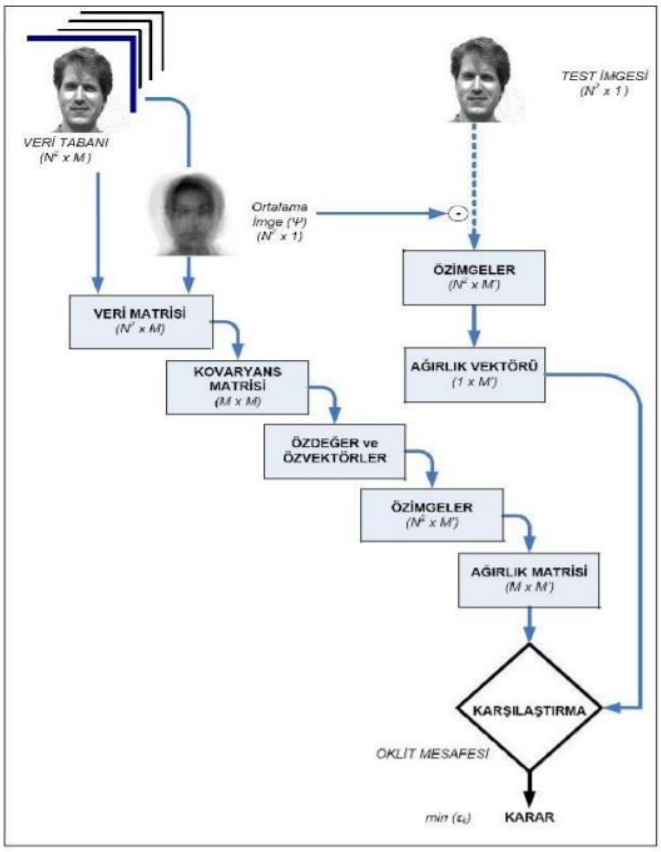
Görüntü uzayına düşürülen her bir görüntünün ağırlık matrisinden ne kadar uzakta olduğu ölçütüne göre tanımlama gerçekleştirilir. Yakınlık ölçütü, öklid mesafesi (*Euclidean distance*) ile ifade edilmektedir. Öklid mesafesi hesabı denklem 12'deki gibidir.

$$\varepsilon_k^2 = || \; (\Omega - \; \Omega_k) \; ||^2 \tag{12}$$

Ağırlık matrisine göre öklid mesafesi ile elde edilen test görüntüsünün, en küçük öklid değerine karşılık gelen görüntü olduğu kabul edilerek tanımlanması gerçekleştirilmektedir.

Özyüzler ile yüz tanıma algoritmasının çalışma prensibi N^2 x M eğitim yani giriş görüntüsünün ortalama imgesi bulunur. Veri matrisi aracılığıyla kovaryans matrisine dönüştürülür. Kovaryans matrisi özdeğerler ve özvektörler yardımıyla özimgeler matrisine çevirilir. Özimgeler N^2 x M matris boyutundan ağırlık matrisi M x M haline gelir. Test görüntüsü ise özimgeler ve ağırlık vektörü işlemlerinden sonra eğitim görüntüsüyle karşılaştırmaya hazır hale gelir. Her bir görüntünün ağırlık matrisinden ne kadar uzakta olduğunu belirleyebilmek için, eğitim ve test görüntüsünün karşılaştırılma yapılabilmesi amacıyla öklid uzaklık mesafesinin hesaplanması gerekmektedir. Eğitim ve test çıktı görüntülerinin karşılaştırılması bu işlemlerden geçtikten sonra yapılmaktadır. Çıktı görüntüleri birbiriyle aynıysa özyüzler algoritması doğru sonuç üretir, değilse yanlış sonuç üretir.

Özyüzler ile yüz tanıma yaklaşımına ait işlevsel blok diyagramı Şekil 16'da gösterilmiştir (Holat, 2014).



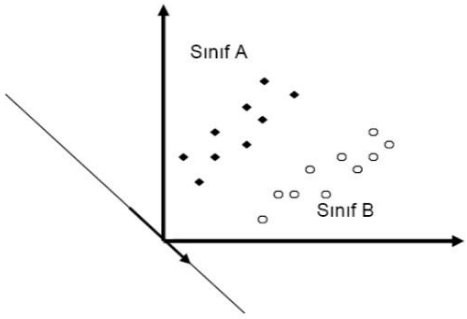
Şekil 16. Özyüzler algoritması ile sınıflandırma işlevsel blok diyagramı.

Kaynak: Holat (2014)

5.2. Fisherfaces ile Yüz Tanıma

Fisherfaces ile yüz tanıma algoritması Belhumer Hespanha ve Kriegman (1997) tarafından Doğrusal Ayrım Analizi (LDA) daha iyi tanıma oranları elde edebilmek için geliştirilmiştir. Bu yüz tanıma algoritması, sınıflandırma tabanlı tanımlama için kullanılan bir yöntemdir. Aynı kişiye ait çok sayıda, farklı görüntünün veri tabanına tanıtılarak sınıf içi dağılımın en aza, sınıflar arası dağılımın en fazlaya ulaşılabilmesi için geliştirilmiştir. Böylece, Fisherfaces yaklaşımında tanımlama başarım oranında artış gözlenmektedir. LDA veriler arasındaki ayrımı sağlayan yönün bulunmasını

hedefler. Sınıflar arasındaki dağılımı en büyük yaparken aynı zamanda sınıf içi dağılımı da en küçük yapmaya çalışır (Erdoğan, 2010). LDA için sınıfları ayıran yönün görünümü Şekil 17'deki gibidir.



Şekil 17. LDA için sınıfları ayıran yön

Kaynak: Erdoğan (2010)

Fisherfaces yaklaşımında, her biri N x N boyutunda olan yüz görüntüleri N^2'lik vektörler hâline getirilir. Ortalama görüntü vektörü denklem 13'teki gibi hesaplanmaktadır.

$$\Psi = \frac{1}{M_t} \sum_{k=1}^{M_t} \Gamma_k \tag{13}$$

Denklem 13'te Γ_k görüntü vektörü, Ψ ortalama görüntü vektörü ve M_t toplam görüntü sayısını ifade eder. Veri tabanında, c farklı sınıfa ait toplam M_t tane görüntü vektörü kaydedilmektedir. Ortalama görüntü vektörü hem tüm veri tabanı içerisinde hemde her bir sınıf için ayrı ayrı bulunmaktadır (Erdoğan, 2010).

Ortalama görüntüden farkı alınmış sınıf içi görüntü vektörü (Φ_i) denklem 14'teki gibi bulunur.

$$\Phi_i = \Gamma_i - \Psi_{ci} \tag{14}$$

Oluşturulan vektörlerden sınıf içi ve sınıflar arası saçılma matrisleri elde edilmektedir.

Sınıf içi saçılma matrisi ise denklem 15'teki formülle hesaplanır.

$$S_w = \sum_{i=1}^{c} P(C_i)\, \Sigma_i \tag{15}$$

Denklem 15'te S_w sınıf içi saçılma matrisini, P (C_i) önsel sınıf olasılığıdır. P (C_i) ise $\frac{1}{c}$ ile bulunur. $\sum_i$'nün hesaplanması denklem 16'daki gibidir.

$$\Sigma_i = E\,[\Phi_i\, \Phi_i^T] = E\,[\,(\Gamma_i - \Psi_{ci})\,(\Gamma_i - \Psi_{ci})^T\,] \tag{16}$$

Sınıflar arası saçılma matrisi S_b'nin hesaplanması denklem 17'deki gibidir.

$$S_b = \sum_{i=1}^{c} P(C_i)\ (\Psi_{ci} - \Psi)\,(\Psi_{ci} - \Psi)^T \tag{17}$$

Denklem 15 ve 17'den elde edilen saçılma matrisleri denklem 18'de kullanılarak en iyi W matrisi bulunması amaçlanmaktadır. Bu sayede, sınıflar arası saçılma en fazla, sınıf içi saçılma en aza indirgenmiş olacaktır.

$$W = \underset{T}{\operatorname{argmax}}\,(J(T)) \Rightarrow \max\ (J(T)) = \frac{|\,T^T S_b\, T\,|}{|\,T^T S_w\, T\,|}\,|_{T=W} \tag{18}$$

W matrisinin çözümü genelleştirilmiş özdeğer çözümü ile denklem 19'da verilen formülle bulunmaktadır (Erdoğan, 2010).

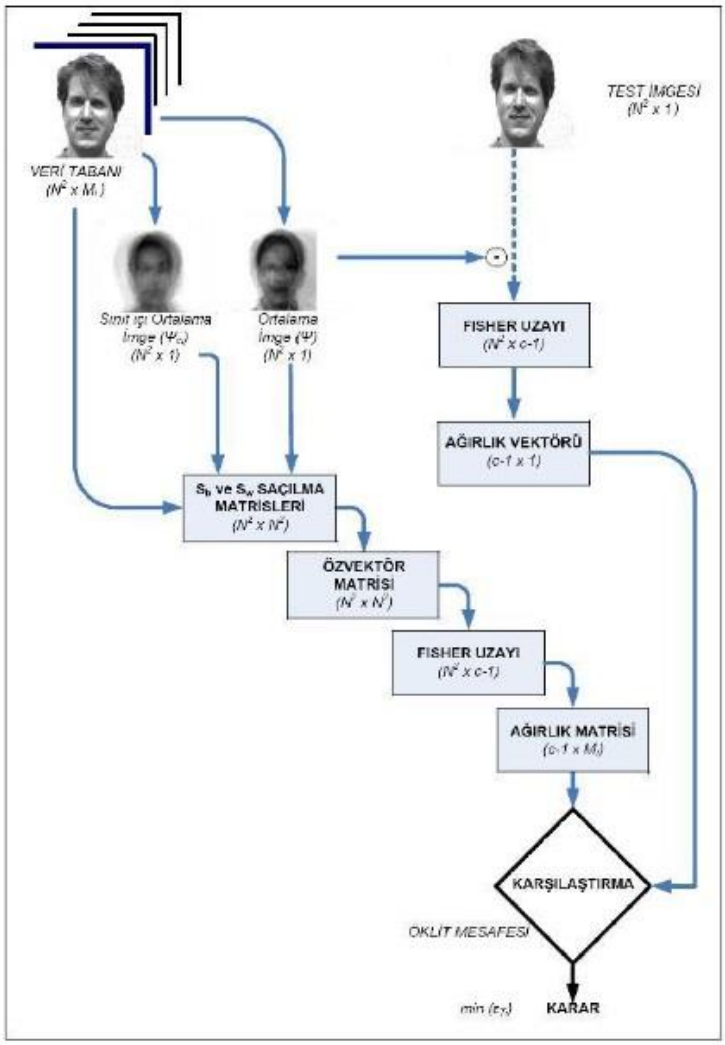
$$S_b\, W = S_W\, W\, \lambda_W \tag{19}$$

Tanımlama için kullanılacak olan W matrisi, S_w ve S_b matrislerinden elde edilmiş olan özvektör matrisidir. Özvektör matrisi, anlamlı özdeğerlere göre sıralandığında en fazla c-1 tane özyüzden oluşmaktadır. Özyüz yaklaşımına benzer şekilde, her bir görüntünün özvektörler ya da görüntü uzayına yansıtılması ile o görüntüye ait ağırlık vektörü (g)

elde edilir (Erdoğan, 2010). Ağırlık vektörü denklem 20'de gösterilen formülle hesaplanmaktadır.

$$g(\Phi_i) = W^T \Phi_i \tag{20}$$

Fisherfaces ile yüz tanıma yaklaşımına ait işlevsel blok diyagramı Şekil 18'de gösterilmiştir.



Şekil 18. Fisherfaces yüz algoritması ile sınıflandırma işlevsel blok diyagramı

Kaynak: Erdoğan (2010)

6. MATERYAL VE YÖNTEM

Tez kapsamında yürütülen deney çalışmaları nVIDIA® GeForce® RTX2060 Intel® UHD Graphics özellikli ekran kartı ve Intel® Core™ i7-10750H CPU işlemci ve @2.60 GHz işlemci temel frekansı ve 16 GB RAM'e sahip 64 bit Windows 10 Home SL işletim sistemine sahip bir dizüstü bilgisayar ortamında gerçekleştirilmiştir. Yazılım olarak ise MATLAB R2018b sürümü ile çalışmalar yapılmıştır.

Yüz tanıma sistemi uygulanması için FEI (*Faculdade de Engenharia Industrial*-Endüstri Mühendisliği Fakültesi) veri tabanındaki yüz fotoğrafları kullanılmıştır. FEI yüz veri tabanında 10 kişinin yüz fotoğrafları bulunmaktadır. Her bir kişi için sağ, sol, karşıdan ve yandan olarak 14 farklı açıdan çekilmiş pozları içermektedir. Toplam 140 tane fotoğraf için denemeler yapılmıştır. Ayrıca 39 kişinin 14 farklı pozundan oluşan toplam 546 yüz fotoğrafları içinde çalışmalar yapılmıştır.

6.1. Veri Kümesi

Sistemin test edilmesi için FEI yüz veri tabanı kullanıldı. Brezilya'daki FEI Yapay Zekâ Laboratuvarı'nda 19-40 yaş arası öğrenci ve personel tarafından farklı imajlar seçilerek çekilmiş bir dizi yüz görüntüsü mevcuttur. Toplamda 200 kişinin her birinin 14 farklı pozundan (birinde gülümsüyor, birinde gülümsemiyor, birinde nötr ve diğerleri farklı açıdan) oluşmaktadır. FEI yüz veri tabanında toplam 2800 yüz görüntüsü vardır. Her görüntünün boyutu 640 x 480 pikseldir (Thomaz, 2012). Bir kişinin 14 farklı pozu Şekil 19'da gösterilmiştir.

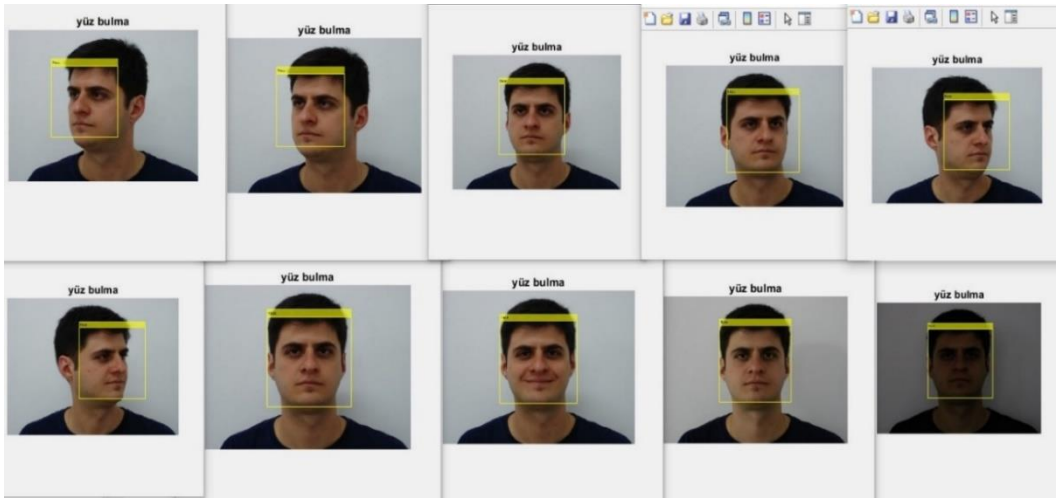


Şekil 19. FEI yüz veri tabanındaki kişinin farklı pozları.

Kaynak: FEI face database (2012)

6.2. Viola-Jones ile Yüz Bulma Yöntemi

Eğitim setindeki fotoğraflar için Viola-Jones algoritması ile yüz bulma denemesi yapılmıştır. Örnek bir yüzün tespit edilmesi Şekil 20'de görüldüğü gibi bulunmuştur.



Şekil 20. Viola-Jones ile örnek yüz tespiti

Kaynak: FEI face database (2012)

Viola-Jones algoritmasını kullanarak yüzleri algılamak için öncelikle bir dedektör oluşturur. Daha sonra burada oluşturulan dedektör arama bölgesi içerisindeki yüzü algılar. Algılanan yüz sarı bir kare içine alınmaktadır ve köşesinde face yazmaktadır. Giriş görüntüsündeki yüzün poz açısından dolayı bazı yüz resimlerinde bu sarı kare oluşmamaktadır. Bunlar algoritmadan başarıyla geçemeyen görüntüler olarak değerlendirmeye alınmıştır. Viola-Jones algoritması ile yüz bulma sistemi için öncelikle yüzü kare içinde bulan pozlar kaydedilmiştir. Kullanılan 140 tane yüz görüntüsünden bulunabilen yüzler 120 tanedir. Diğer 20 tanesi algoritmadan başarıyla geçememiştir. 39 kişinin 14 farklı görüntüsünden oluşmuş 546 tane yüz veri tabanında bu denemeler yapıldığında 462 tane yüzün görüntüsü bulunmuştur. Diğer 84 tane görüntü algoritmadan başarıyla geçememiştir.

Yüz tanıma algoritmasının ilk adımı olan yüz bulma işlemi bu adımlar sayesinde gerçekleşmiştir. Yüz bulma işleminden geçemeyen yüz veri tabanındaki görüntüler, sonraki adımda gerçekleştirilecek olan görüntü işleme tabanlı yöntemlerde kullanılan özyüzler ve fisherfaces ile yüz tanıma çalışmalarında kullanılmamıştır. Farklı poz

varyasyonlarının ve farklı ışık miktarlarının yüz bulmayı büyük ölçüde etkilediği gözlenmiştir.

Viola-Jones algoritması ile bulunan örnek yüzler için oluşan algılayıcı sarı renkteki kare, her bir resim için kesilirse oluşan çerçeve boyutunun görüntüsü Şekil 21'deki gibi olacaktır.



Şekil 21. Örnek yüz resimlerinin çerçeveye alınması

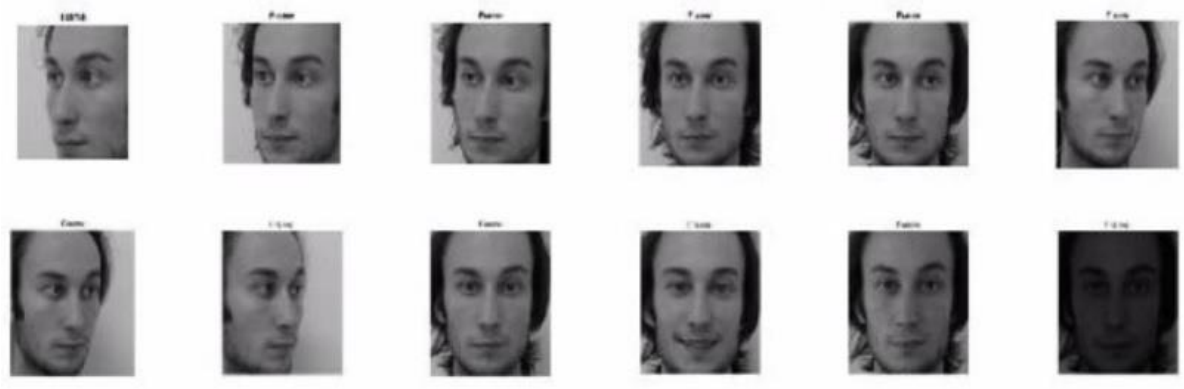
Kaynak: FEI face database (2012)

Eğitim setindeki görüntüler 480 x 640 piksel boyutundadır. Oluşan kutucuk içine alınıp kesilen yeni yüz fotoğraflarının boyutları değişkendir. Örnek bir resimde oluşan piksel boyutu 431 x 360'tır. Bulunamayan yüz görüntüleri yan taraftan çekilen resimleri içermektedir. Viola-Jones ile yüz bulma sistemi %85,71 doğruluk oranı olarak sonuç vermiştir.

6.3. Özyüzler ile Yüz Tanıma Yöntemi

Eğitim setindeki 140 tane yüz görüntülerinin öncelikle Viola-Jones algoritması ile yüz tespiti yapılmıştır. Bulunan yüzler kaskad obje dedektörü ile bir kutucuk içine alınmıştır. Kutucuk içine alınan yüzler kesilmiştir. Elde edilen görüntüler 120 tanedir. Kesilen yüz görüntüleri RGB renk uzayında siyah beyaza çevrilip kaydedilmiştir. Kaydedilen bu görüntüler 431 x 360 örnek piksel boyutu siyah beyaza çevrildiğinde ise 180 x 200 piksel boyutuna düşürülmüştür. Kaydedilen yeni görüntülerin piksel boyutu 180 x 200 olarak ayarlanmıştır.

Eğitim setindeki bir kişinin 12 farklı görüntüsünden oluşturulan örnek resim Şekil 22'deki gibidir.



Şekil 22. Bir kişiye ait 12 farklı yüz görüntüsü

Kaynak: FEI face database (2012)

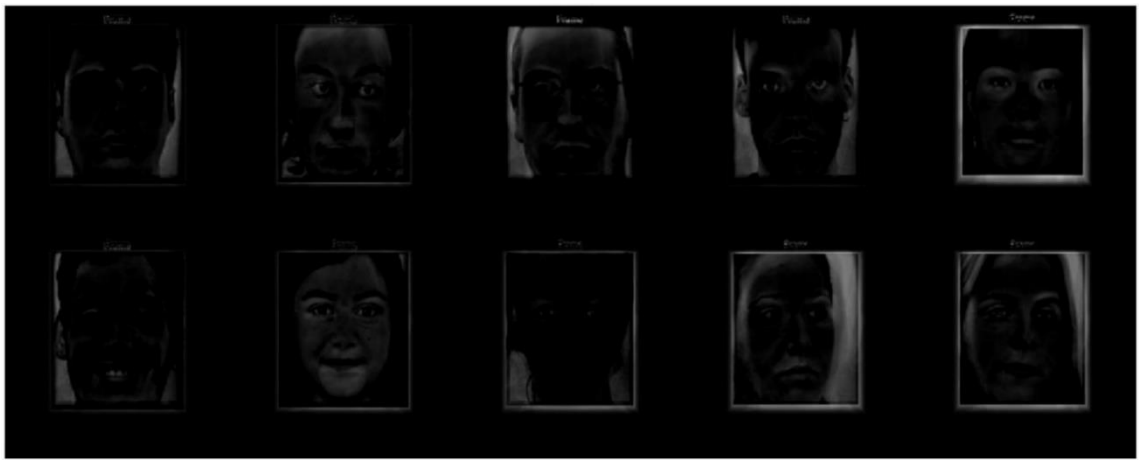
Veri tabanı için oluşturulan resimler Viola-Jones algoritmasından geçerek elde edilmiştir. Ortalama yüz vektörü ile hesaplanan eğitim setindeki görüntülerin ortalama yüz görüntüsü oluşturulmuştur. Ortalama yüz görüntü örneği Şekil 23'teki gibi gözükmektedir.



Şekil 23. Ortalama yüz görüntüsü

Ortalama yüz görüntüsünü elde edebilmek için görüntüyü tek hassasiyete dönüştürme işlemi yapılmıştır. Görüntülerin ortalaması hesaplanarak elde edilen sonuca göre üretilen çıkış resmi Şekil 23'teki gibi olmuştur. Buradaki görüntü, işleme dahil olan tüm yüzlerin ortalamasıyla elde edildiği için, yüz görüntüleri üst üste eklenmiş olarak görülmektedir.

Ortalama yüz vektörü tüm yüz vektörlerinden çıkartılarak oluşan fark yüzleri Şekil 24'te gösterilmiştir.



Şekil 24. Fark yüzlerinin görüntüsü

10 farklı kişiden oluşan 120 tane fotoğrafın 30 tanesi test görüntüsü, 90 tanesi eğitim görüntüsü olarak iki ayrı klasöre ayrılmıştır. Resimlerin %75'i eğitim verisi, %25'i test verisi için kullanılmıştır. Bu çalışma için program çalıştırılırken 30 farklı kişiden oluşturulan test görüntüsü girilir. Bu görüntüler sağdan, soldan ve karşıdan (orta) çekilen olarak üçe ayrı şekilde incelenmiştir. Geriye kalan 90 tanesi eğitim görüntüsü sonuç görüntüsü için ayrılmıştır. Özyüzler ile yüz tanıma yöntemi için yapılan çalışma test ve eğitim görüntüsü olmak üzere iki farklı görüntü üzerinden gerçekleştirilir.

Tanıma görüntüsü ile test görüntüsünün örneği Şekil 25'teki gibi bulunmuştur.



Şekil 25. Örnek yüz tanıma

Kaynak: FEI face database (2012)

Oluşturulan eğitim seti, 10 kişinin farklı sağ poz görüntülerinden oluşturulmuş yeni veri tabanıdır. Veri tabanından alınan 30 test sağ yüz görüntüsü Şekil 26'daki gibi görünmektedir.



Şekil 26. Veri tabanından alınan 30 sağ test görüntüsü

Kaynak: FEI face database (2012)

FEI veri tabanındaki pozlarda sağ yüz resimleri için her bir kişiye ait üç tane poz seçilmiştir. Çerçeveye alınarak kesilen resimler siyah beyaza çevrilmiştir.

Özyüzler yöntemi ile sağ yüz tanıma eşleşmeleri Şekil 27'deki gibi sonuç vermektedir.



Şekil 27. Özyüzler yöntemi ile sağ yüz resmi tanıma

Kaynak: FEI face database (2012)

30 tane test görüntüsü 90 tane eğitim görüntüsünden aynı kişilerin başka pozları ile eşleşmiştir. Sonuç olarak %43,33 doğruluk oranı elde edilmiştir.

Oluşturulan eğitim seti, 10 kişinin farklı sol poz görüntülerinden oluşturulmuş yeni veri tabanıdır. Veri tabanından alınan 30 test sol yüz görüntüsü Şekil 28'deki gibi görünmektedir.



Şekil 28. Veri tabanından alınan 30 sol test görüntüsü

Kaynak: FEI face database (2012)

FEI veri tabanındaki pozlarda sol yüz resimleri için her bir kişiye ait üç tane poz seçilmiştir. Çerçeveye alınarak kesilen resimler siyah beyaza çevrilmiştir.

Soldan çekilmiş kişilerin pozları ile oluşturulan yeni veri tabanı ayrı bir test klasöründe tutulmuştur. Kişilerin geriye kalan diğer pozları ise eğitim klasöründe oluşturulmuştur.

Özyüzler yöntemi ile sol yüz görüntüsü tanıma eşleşmeleri Şekil 29'daki gibidir.

Test Sonuç Test Sonuç Test Sonuç

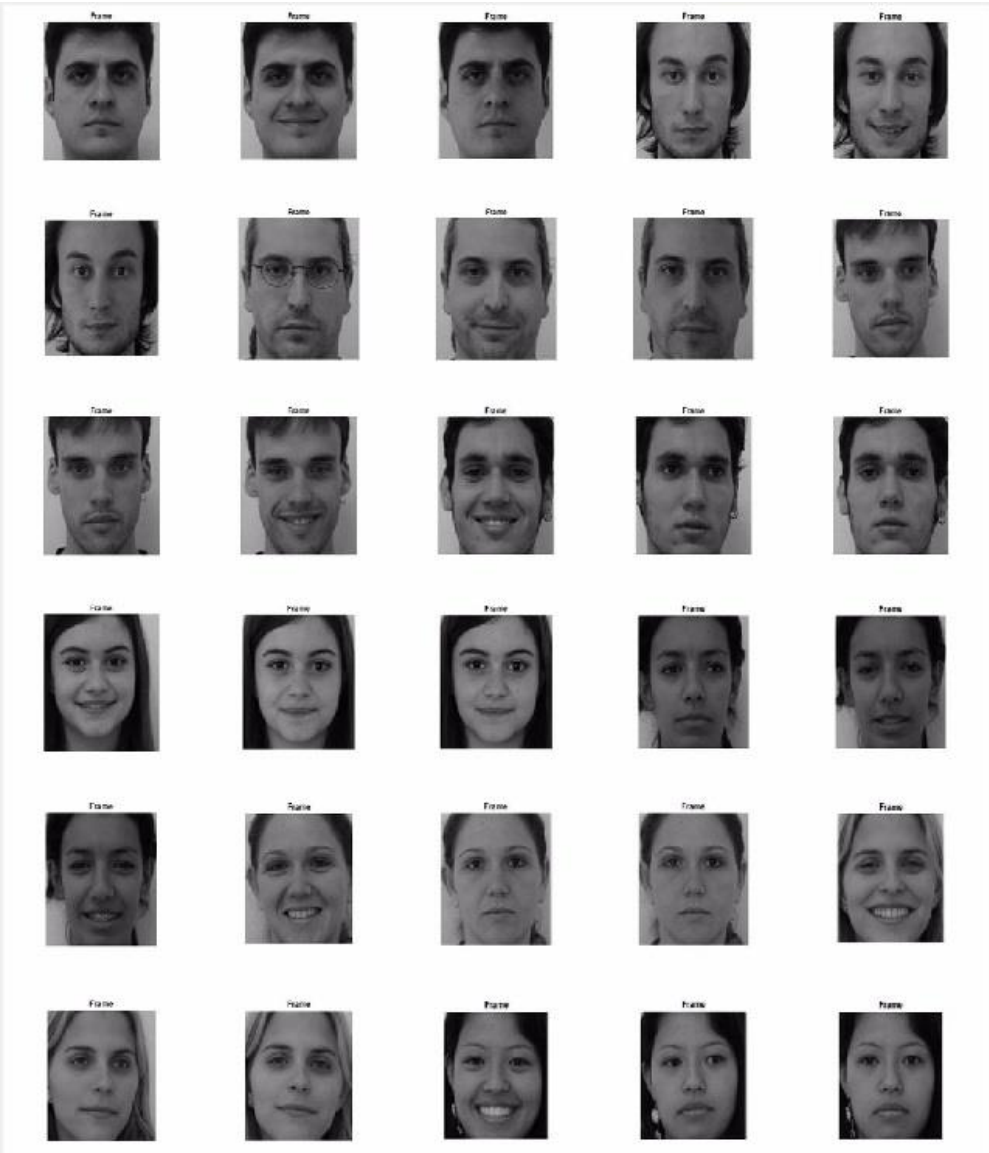


Şekil 29. Özyüzler yöntemi ile sol yüz resmi tanıma

Kaynak: FEI face database (2012)

30 tane test görüntüsü 90 tane eğitim görüntüsünden aynı kişilerin başka pozları ile eşleşmiştir. Sonuç olarak %20 doğruluk oranı elde edilmiştir.

Oluşturulan eğitim seti, 10 kişinin üç farklı karşıdan (orta) poz görüntülerinden oluşturulmuş yeni veri tabanıdır. Veri tabanından alınan 30 test orta yüz görüntüsü Şekil 30'daki gibi görünmektedir.



Şekil 30. Veri tabanından alınan 30 orta test görüntüsü

Kaynak: FEI face database (2012)

Karşıdan çekilmiş kişilerin pozları ile oluşturulan yeni veri tabanı ayrı bir test klasöründe tutulmuştur. Kişilerin geriye kalan diğer pozları ise eğitim klasöründe

oluşturulmuştur. Özyüzler yöntemi ile orta yüz görüntüsü tanıma eşleşmeleri Şekil 31'deki gibi elde edilmiştir.



Şekil 31. Özyüzler yöntemi ile orta yüz resmi tanıma

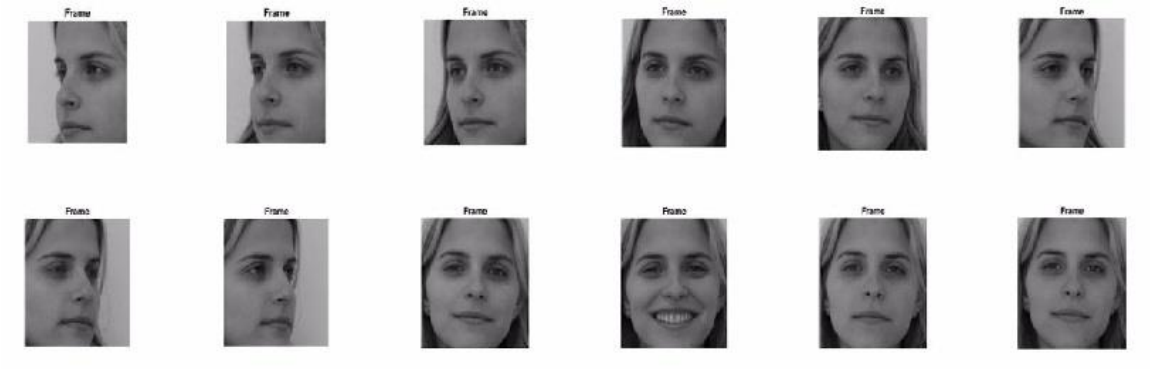
Kaynak: FEI face database (2012)

30 tane test görüntüsü 90 tane eğitim görüntüsünden aynı kişilerin başka pozları ile eşleşmiştir. Sonuç olarak %76,66 doğruluk oranı elde edilmiştir.

6.4. Fisherfaces ile Yüz Tanıma Yöntemi

Eğitim setindeki 140 tane yüz görüntülerinin öncelikle Viola-Jones algoritması ile yüz tespiti yapılmıştır. Bulunan yüzler kaskad obje dedektörü ile bir kutucuk içine alınmıştır. Kutucuk içine alınan yüzler kesilmiştir. Elde edilen görüntülerde tanınan yüz görüntüleri 120 tanedir. Kesilen yüz görüntüleri RGB renk uzayında siyah beyaza çevrilip kaydedilmiştir. Kaydedilen yeni görüntülerin piksel boyutu 180x200 olarak ayarlanmıştır.

Oluşturulan eğitim seti, 10 kişinin 12 farklı görüntülerinden oluşturulmuş yeni veri tabanıdır. Her bir kişi için 12 farklı açıdan çekilen görüntülerinin örneği Şekil 32'deki gibidir.



Şekil 32. Bir kişiye ait 12 farklı yüz görüntüsü

Kaynak: FEI face database (2012)

10 farklı kişiden oluşan 120 tane fotoğrafın 30 tanesi test, 90 tanesi eğitim görüntüsü olarak iki ayrı klasöre ayrılmıştır. Bu çalışmada program çalıştırılırken 30 farklı kişiden oluşturulan test görüntüsü girilir. Test görüntüsü sağdan, soldan ve karşıdan(orta) olmak üzere üç ayrı şekilde incelenmiştir. Geriye kalan 90 tanesi eğitim görüntüsü sonuç görüntüsü için ayrılır. Fisherfaces ile yüz tanıma yöntemi için yapılan çalışma test ve eğitim görüntüsü olmak üzere iki farklı görüntü üzerinden gerçekleştirilir. Veri tabanından alınan 30 test sağ, sol ve orta görüntülerinin örnekleri Özyüzler yöntemi ile yüz tanıma bölümünde verilmiştir. Fisherfaces yöntemi içinde aynı test görüntüleri kullanılmıştır.

Oluşturulan veri tabanından Fisherfaces yöntemi ile sağ yüz görüntüsü tanıma eşleşmeleri Şekil 33'teki gibi sonuç vermektedir.

Test Sonuç Test Sonuç Test Sonuç



Şekil 33. Fisherfaces yöntemi ile sağ yüz resmi tanıma

Kaynak: FEI face database (2012)

Sonuç olarak %20 doğruluk oranı elde edilmiştir.

Fisherfaces yöntemi ile sol yüz görüntüsü tanıma eşleşmeleri Şekil 34’teki gibi sonuç vermektedir.



Şekil 34. Fisherfaces yöntemi ile sol yüz resmi tanıma

Kaynak: FEI face database (2012)

Sonuç olarak %20 doğruluk oranı elde edilmiştir.

Fisherfaces yöntemi ile orta yüz görüntüsü tanıma eşleşmeleri Şekil 35'teki gibi sonuç vermektedir.



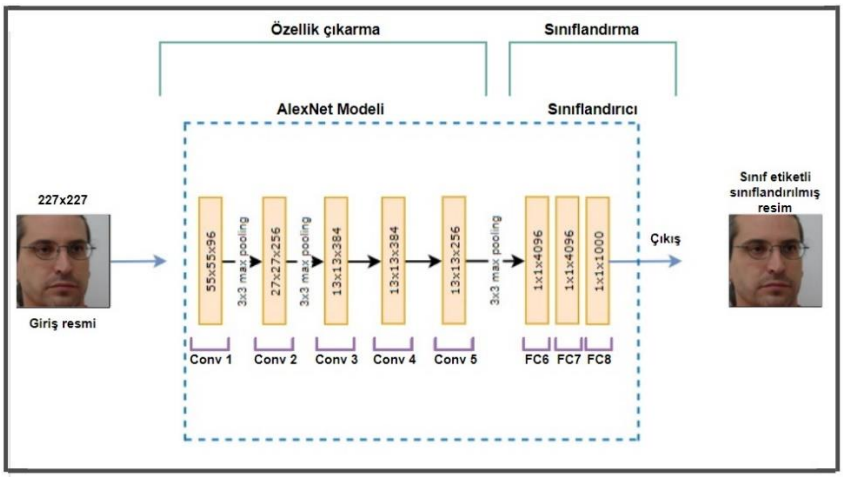
Şekil 35. Fisherfaces yöntemi ile orta yüz resmi tanıma

Kaynak: FEI face database (2012)

30 tane test görüntüsü 90 tane eğitim görüntüsünden aynı kişilerin başka pozları ile eşleşmiştir. Sonuç olarak %73,33 doğruluk oranı elde edilmiştir.

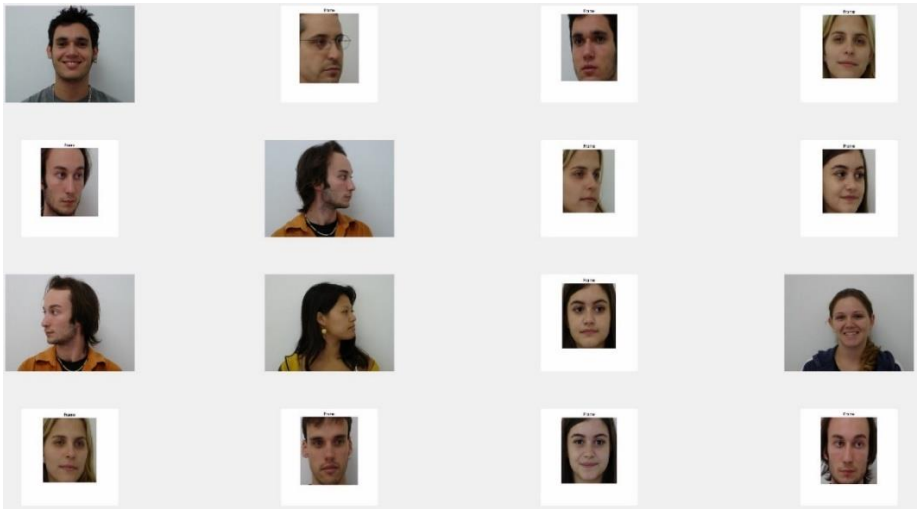
6.5. AlexNet ve ResNet-18 Mimarisi ile Yüz Tanıma

Mimaride giriş resmi öncelikle Viola-Jones yüz bulma sistemi ile belirlenmiş daha sonra yüz kenarları kesilmiştir. Bu resimler eğitilip örnek resimleri ve sınıflandırılmaları elde edilmiştir. AlexNet mimarisine dayanan özellikler Şekil 36'da gösterilmiştir.



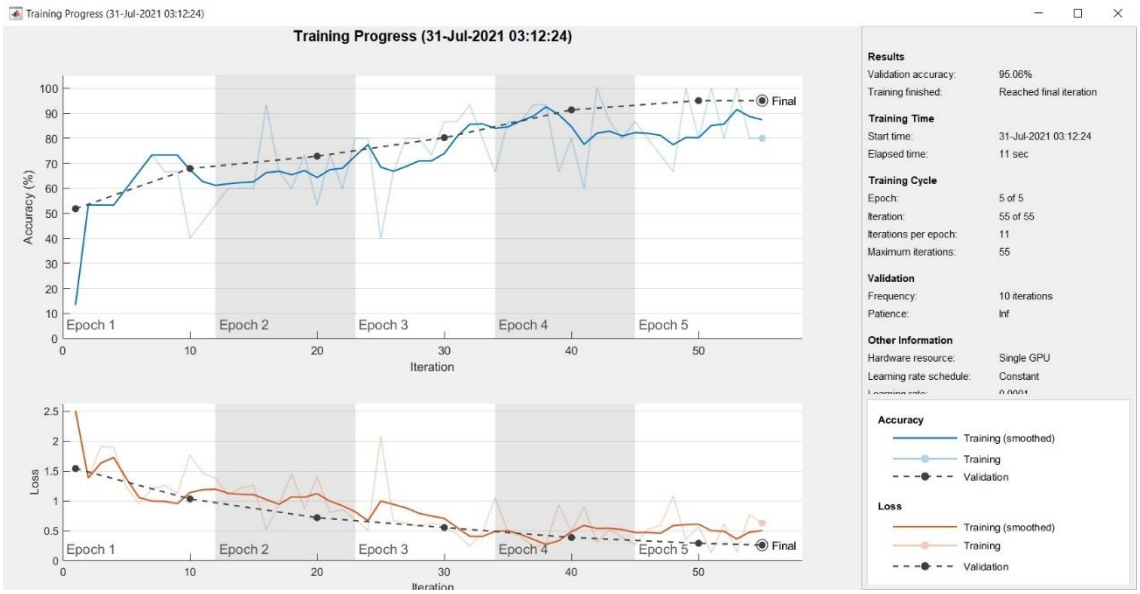
Şekil 36. AlexNet mimarisi özellikleri

Çalışmada AlexNet için 120, 462, 30 sağ poz, 30 sol poz ve 30 orta poz olmak üzere dört kategoride yüz fotoğrafları kullanılmıştır. Mimari toplam 25 katmandan oluşmaktadır. Ağın görüntü giriş boyutları 227 x 227'dir. Veriler her bir kişi için ayrı klasörde ve orijinal resimlerin tamamı ayrı klasörde oluşturulmuştur. Bu veri seti için bazı örnek resimler 120 yüz resmi için Şekil 37'deki gibidir.



Şekil 37. Okuma görüntüsü

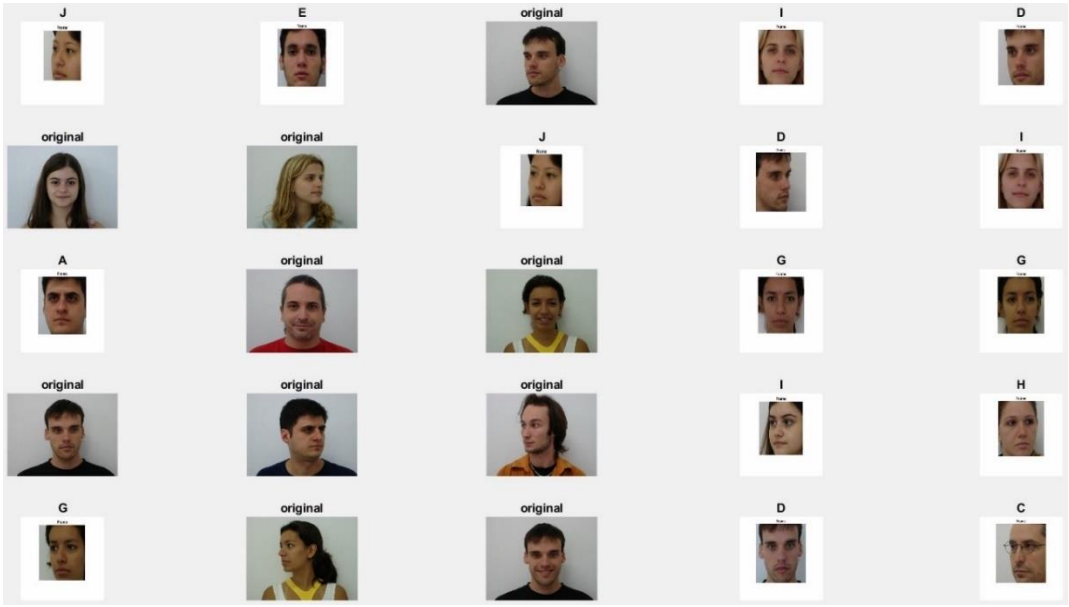
İlk katman, görüntü giriş katmanı 227 x 227 x 3 boyutundadır. Önceden eğitilmiş ağın son 3 katmanı net1000 sınıfı için yapılandırılmıştır. Önceden eğitilmiş ağdan son üçü hariç tüm katmanlar çıkarılmıştır. Son üç katmanı tamamen bağlantılı bir katman, bir yumuşatma katmanı ve bir sınıflandırma çıktı katmanı ile değiştirilerek yeni bir sınıflandırma görevine aktarılmıştır. Eğitim görüntülerini yeniden boyutlandırmak için bir görüntü veri deposu kullanılmıştır. Bu görüntüler yatay ve dikey olarak rastgele 30 piksele kadar çevrilmiştir. Aktarılan ve yeni katmanlardan oluşan ağ eğitilir. Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 38'deki gibi görülmektedir.



Şekil 38. AlexNet ağının ImageNet ile eğitimi

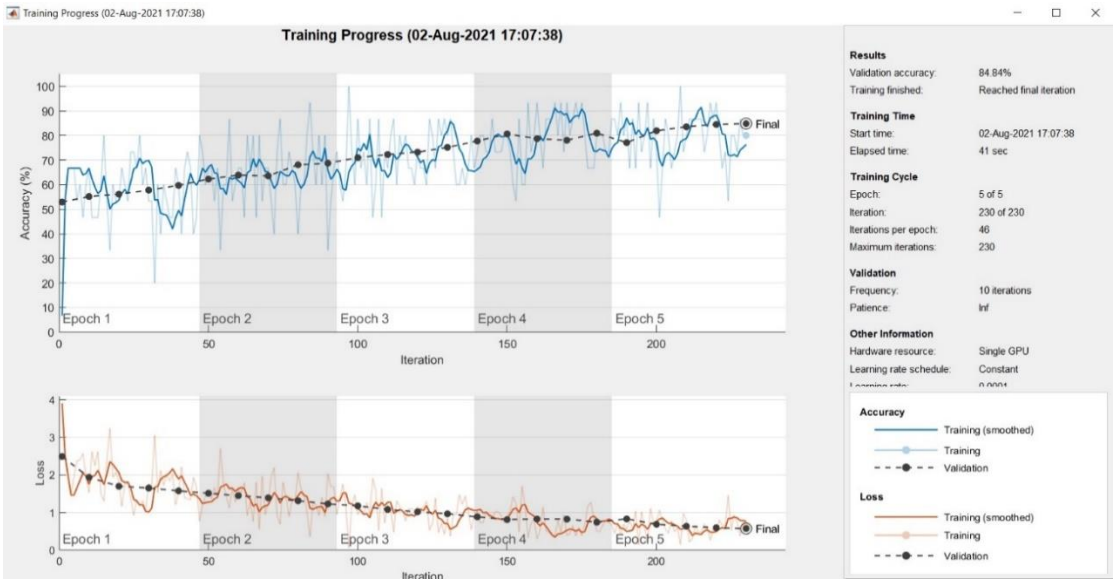
AlexNet algoritması ile eğitilen görüntülerin doğruluk ilerlemesi bu şekilde sonuçlanmıştır. Epoch (döngü) sayısı, eğitim sırasında tüm verilerin ağda gösterilmesini temsil eder. Daha yüksek doğruluk oranı elde edebilmek için örnek olarak 5 verilmiştir. Epoch sayısının değişmesine bağlı olarak doğruluk performanslarının değiştiği gözlenmiştir. Bu değişimler 3-10 aralığında yapılan denemelerle elde edilmiştir. Mini batch size ise birden fazla girdiyi parçalar haline bölmektedir ve 15 olarak alınmıştır. Özelliklere sahip katmanlar 25 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı %95,06 olarak sonuç vermiştir.

Tahmin edilen etiketlerle birlikte 25 örnek doğrulama resmin görüntülenmesi Şekil 39'daki gibidir.



Şekil 39. 25 örnek doğrulama görüntüleri

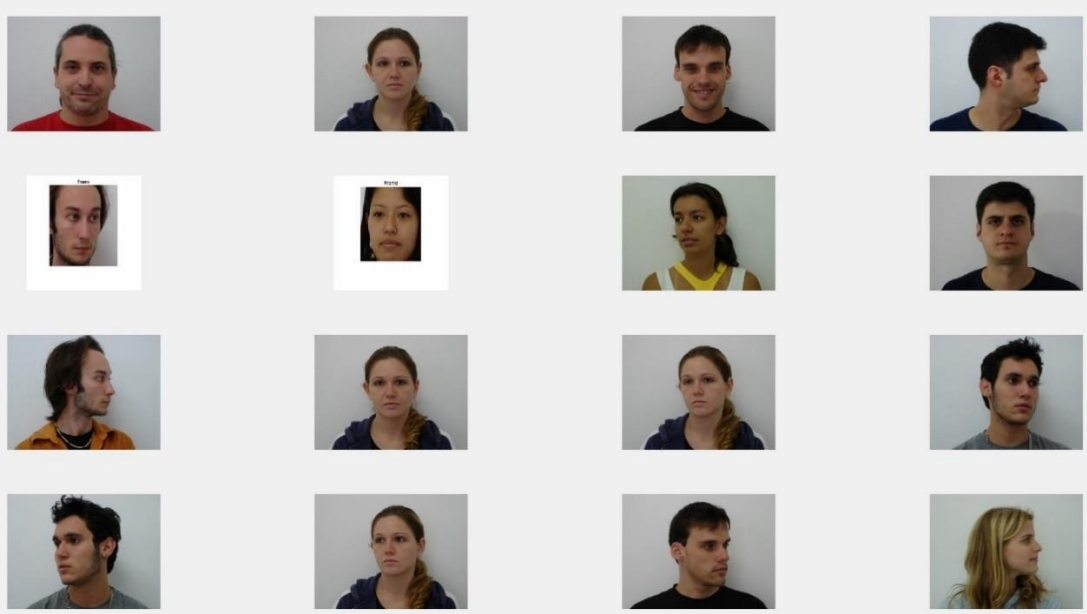
39 farklı kişinin 462 yüz fotoğrafı ile elde edilen eğitim ağındaki doğruluk ilerlemesi Şekil 40'taki gibidir.



Şekil 40. AlexNet ağının ImageNet ağı ile eğitimi

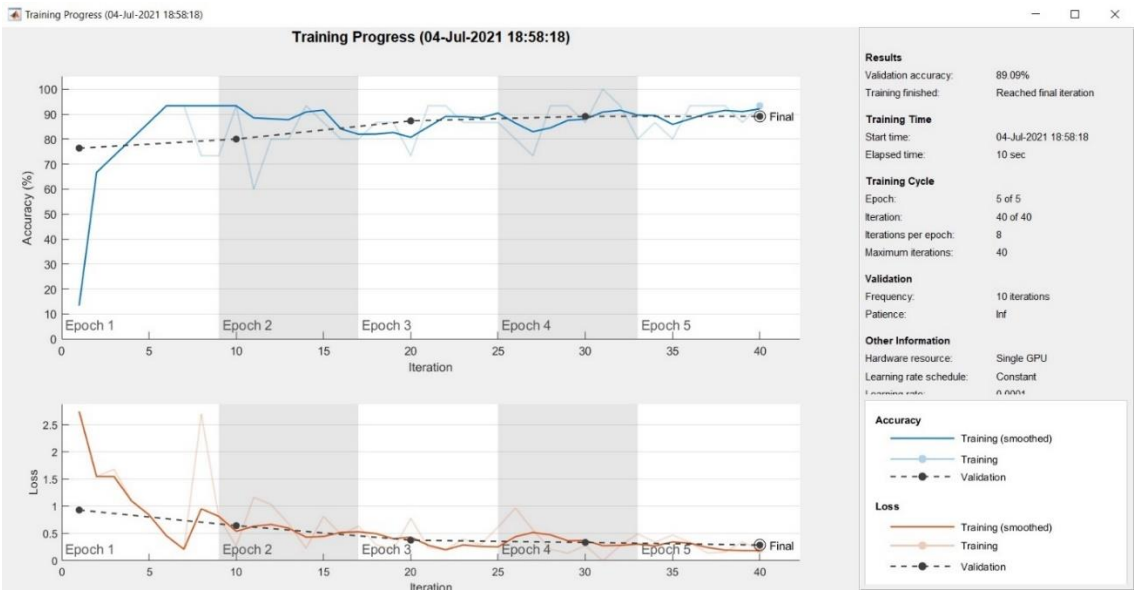
Doğruluk oranı %84,84 olarak bulunmuştur.

AlexNet için sağ yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 41'taki gibidir.



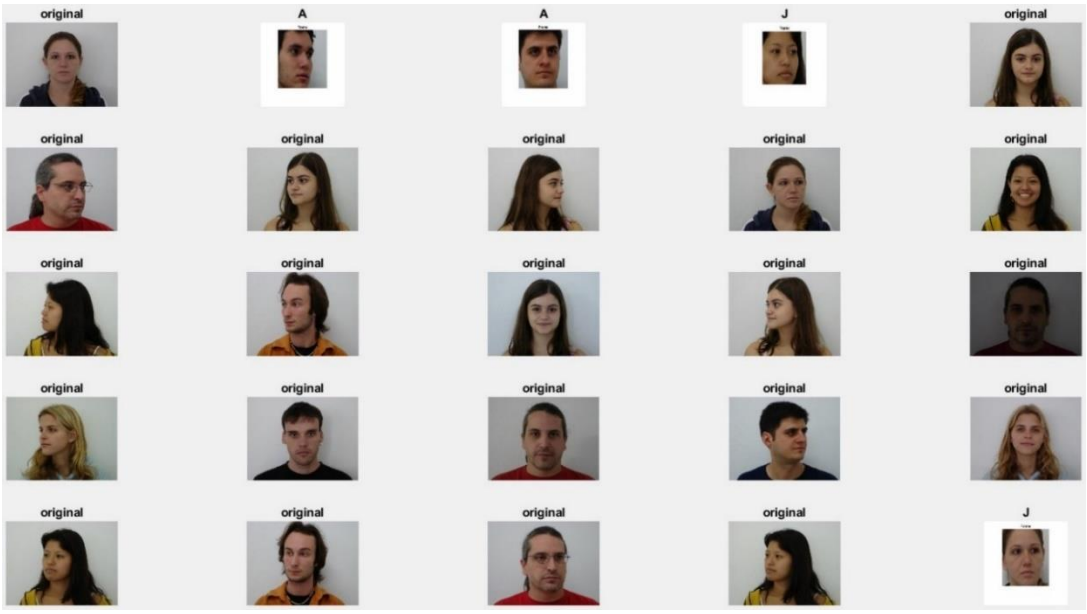
Şekil 41. Sağ yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi ise Şekil 42'deki gibidir.



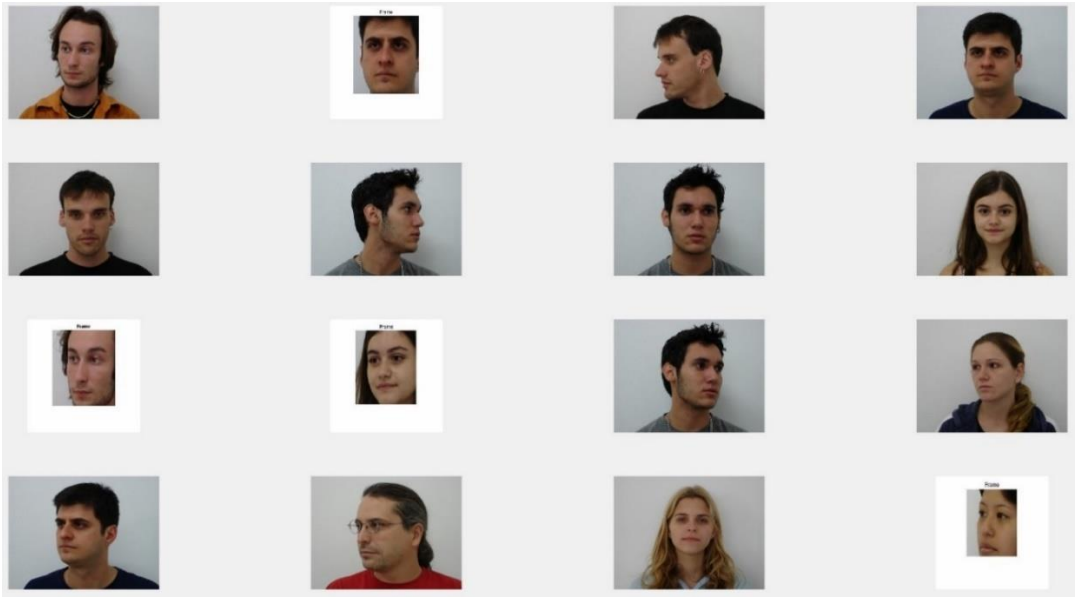
Şekil 42. AlexNet ağının ImageNet ile eğitimi

Özelliklere sahip katmanlar 25 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı sağ yüz resmi için %89,09 olarak sonuç vermiştir. Epoch (döngü) sayısı örnek olarak 5 verilmiştir. 25 örnek doğrulama resmin görüntülenmesi Şekil 43'teki gibidir.



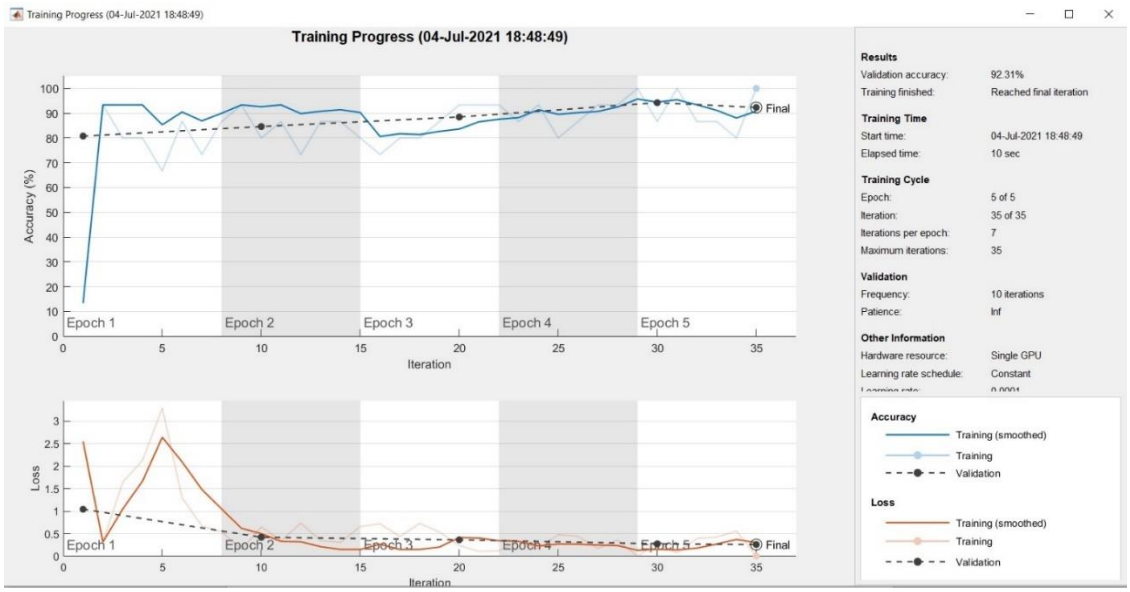
Şekil 43. 25 örnek doğrulama görüntüleri

AlexNet için sol yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 44'teki gibidir.



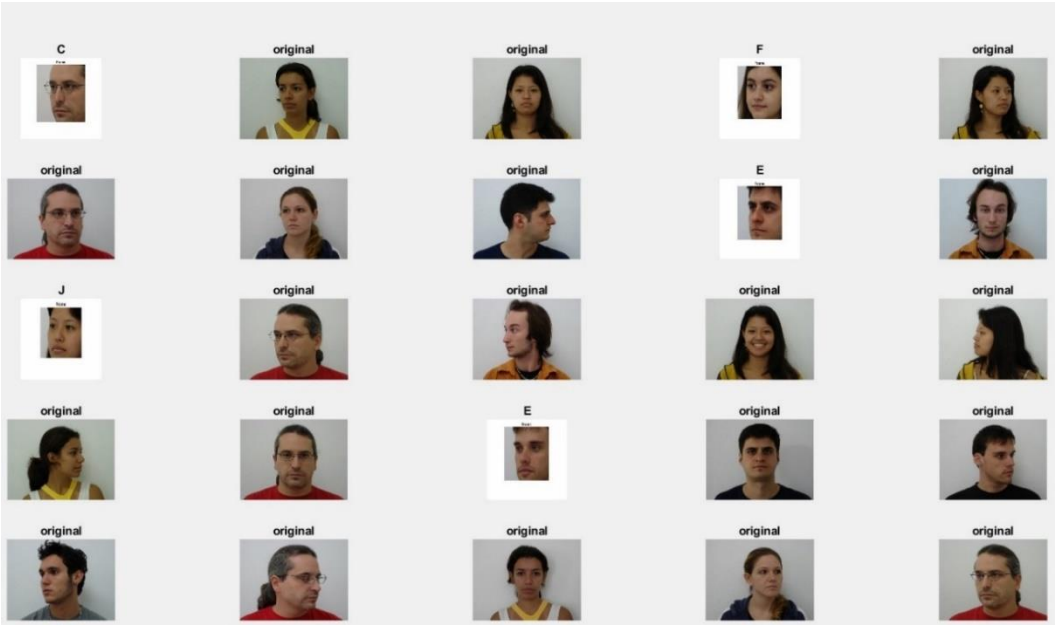
Şekil 44. Sol yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 45'teki gibidir.



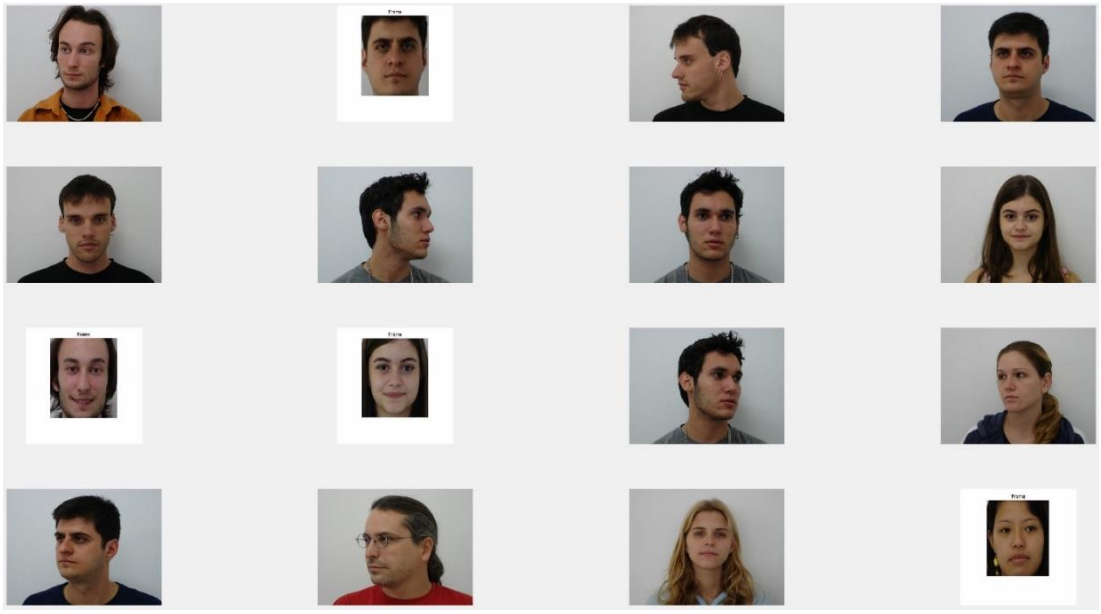
Şekil 45. AlexNet ağının ImageNet ile eğitimi

Epoch sayısı daha yüksek doğruluk oranı elde edebilmek için beş olarak ayarlanmıştır. Özelliklere sahip katmanlar 25 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı sol yüz resmi için %92,31 olarak sonuç vermiştir. Tahmin edilen etiketlerle birlikte 25 örnek doğrulama resmin görüntülenmesi Şekil 46'daki gibidir.



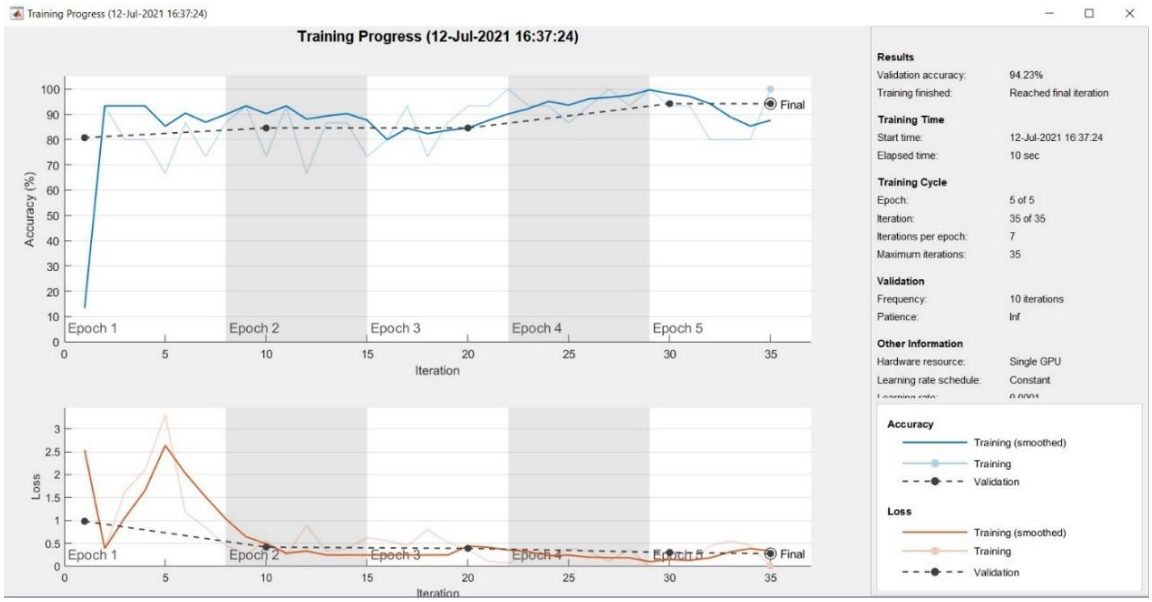
Şekil 46. 25 örnek doğrulama görüntüleri

AlexNet için orta yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 47'deki gibidir.



Şekil 47. Orta yüz resmi okuma görüntüsü

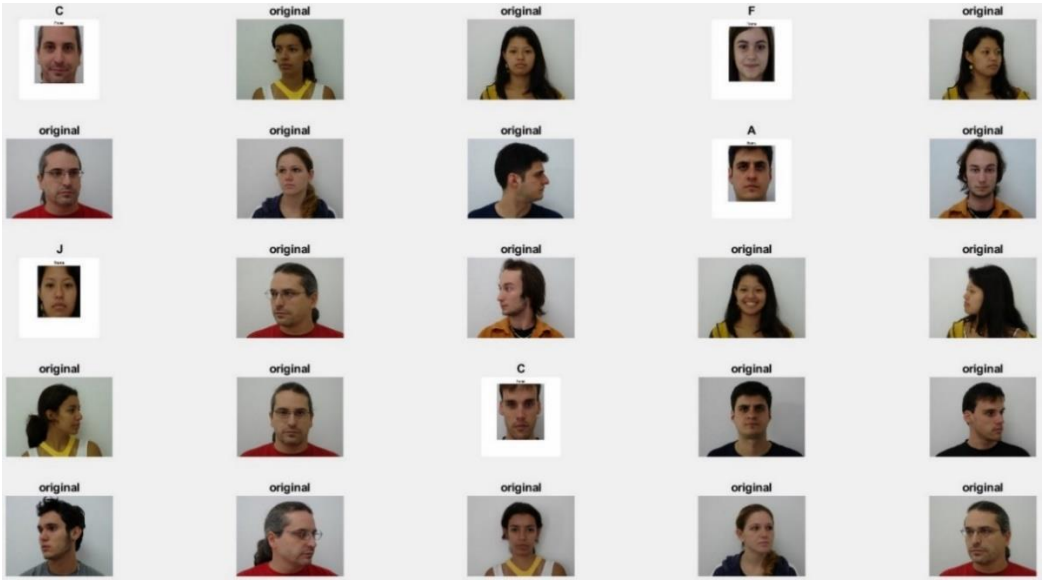
Eğitim ilerlemesinde oluşan doğruluk eğrisi orta yüz resmi için Şekil 48'deki gibidir.



Şekil 48. AlexNet ağının ImageNet ile eğitimi

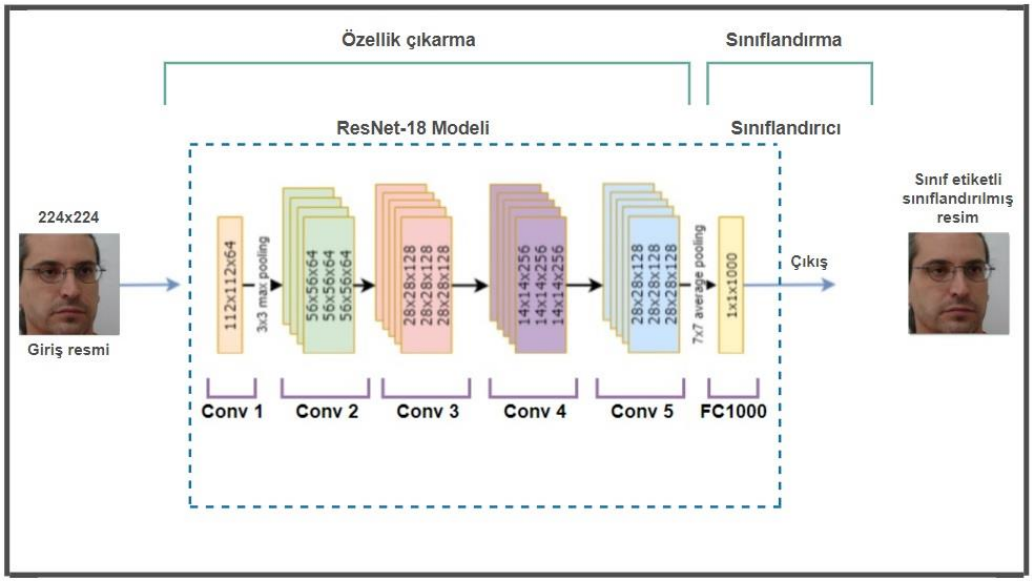
Epoch sayısı, daha yüksek doğruluk oranı elde edebilmek için örnek olarak 5 ayarlanmıştır. Özelliklere sahip katmanlar 25x1 boyutunda olup, ImageNet veri

tabanında doğruluk oranı orta yüz resmi için %94,23 olarak sonuç vermiştir. Tahmin edilen etiketlerle 25 örnek doğrulama resmin görüntülenmesi Şekil 49'daki gibidir.



Şekil 49. 25 örnek doğrulama görüntüleri

ResNet-18 mimarisi için elde edilen resmin boyutları 224 x 224 olarak düzenlenmiştir. Bu resimler ResNet-18 algoritmaları ile eğitilip örnek resimleri ve sınıflandırılmaları elde edilmiştir. ResNet-18 mimarisine dayanan özellikler Şekil 50'de gösterilmiştir. ResNet için 'resnet18' modülü seçilmiştir.



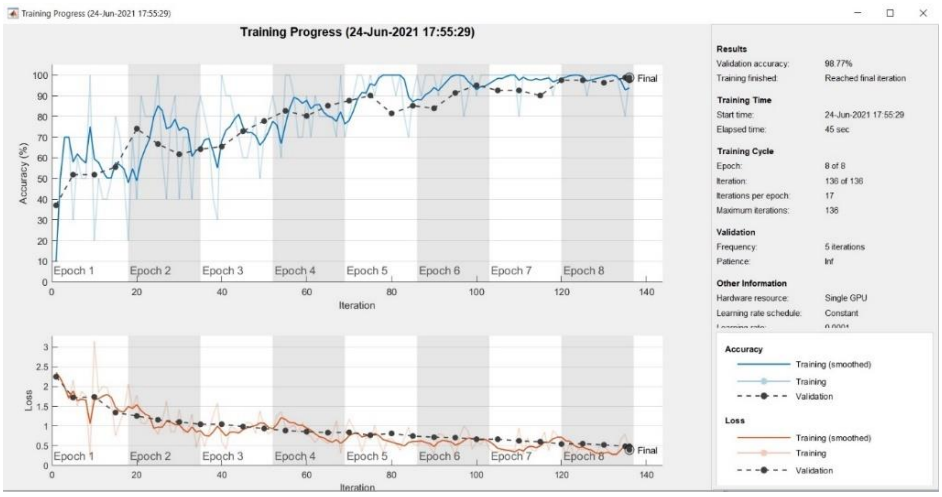
Şekil 50. ResNet-18 mimarisi özellikleri

ResNet-18 için 120, 462, 30 sağ poz, 30 sol poz ve 30 orta poz olarak yüz fotoğrafları kullanılmıştır. Veriler her bir kişi için ayrı klasörde ve orijinal resimlerin tamamı ayrı klasörde oluşturulmuştur. Toplam 72 katmandan oluşmaktadır. Ağın görüntü giriş katmanları 224 x 224 x 3 boyutundadır. Bazı örnek resimler Şekil 51'deki gibidir.



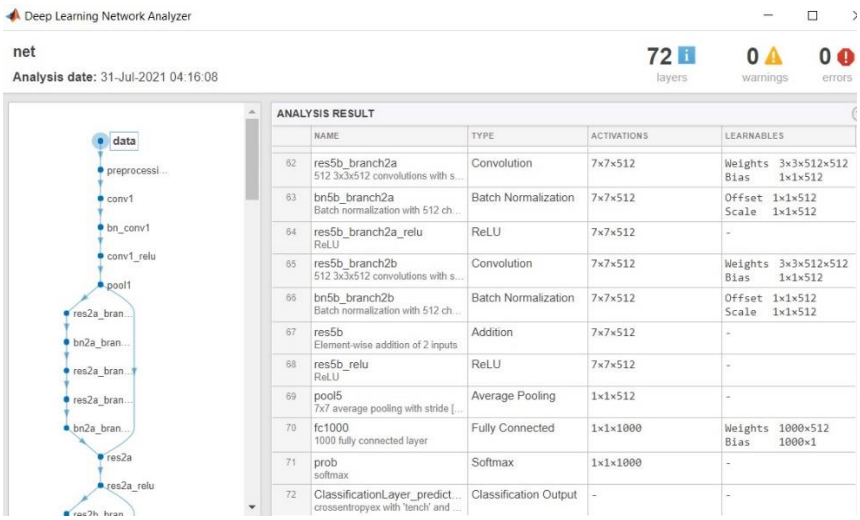
Şekil 51. Okuma görüntüsü

Önceden eğitilmiş ağın son bir katmanı net1000 sınıfı için yapılandırılmıştır. Önceden eğitilmiş ağdan son katman hariç tüm katmanlar çıkarılmıştır. Son katman tamamen bağlantılı bir katman, bir yumuşatma katmanı ve bir sınıflandırma çıktı katmanı ile değiştirerek yeni bir sınıflandırma görevine aktarılmıştır. Bu görüntüler yatay ve dikey olarak rastgele 30 piksele kadar çevrilmiştir. Aktarılan ve yeni katmanlardan oluşan ağ eğitilir. Eğitim ilerlemesindeki doğruluk eğrisi Şekil 52'deki gibidir.



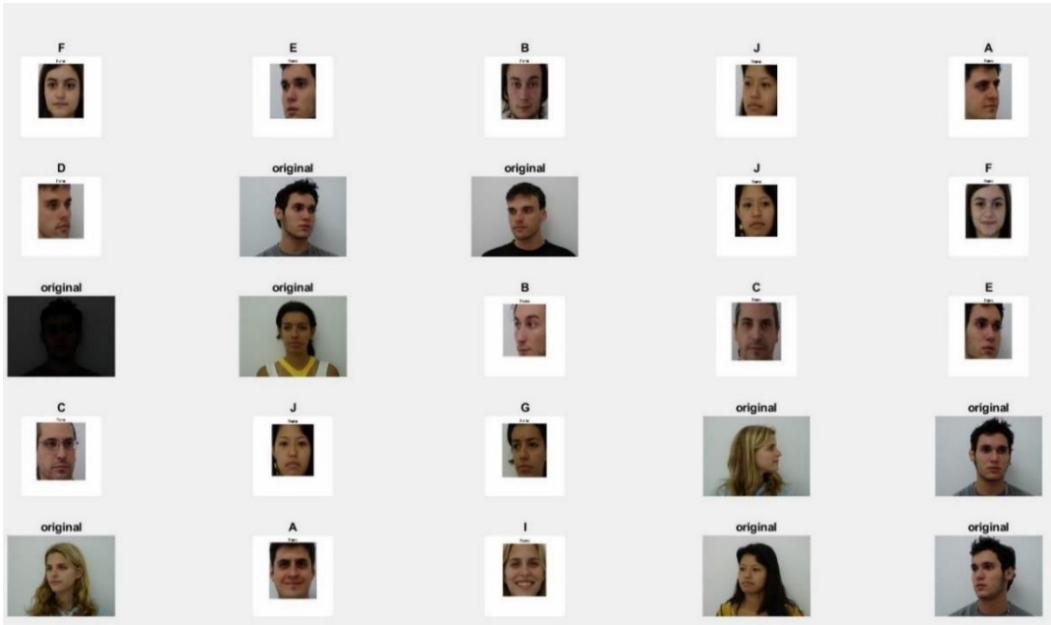
Şekil 52. ResNet-18 ağının ImageNet ile eğitimi

Epoch sayısı burada örnek olarak 8 seçilmiştir. Eğitim ilerlemesindeki doğruluk oranı görüldüğü gibi gerçekleşmektedir. Doğruluk oranı %98,77 olarak sonuç vermiştir. Özelliklere sahip katmanlar 72 x 1 boyutundadır. Katmanlar Şekil 53'te gösterilmiştir.



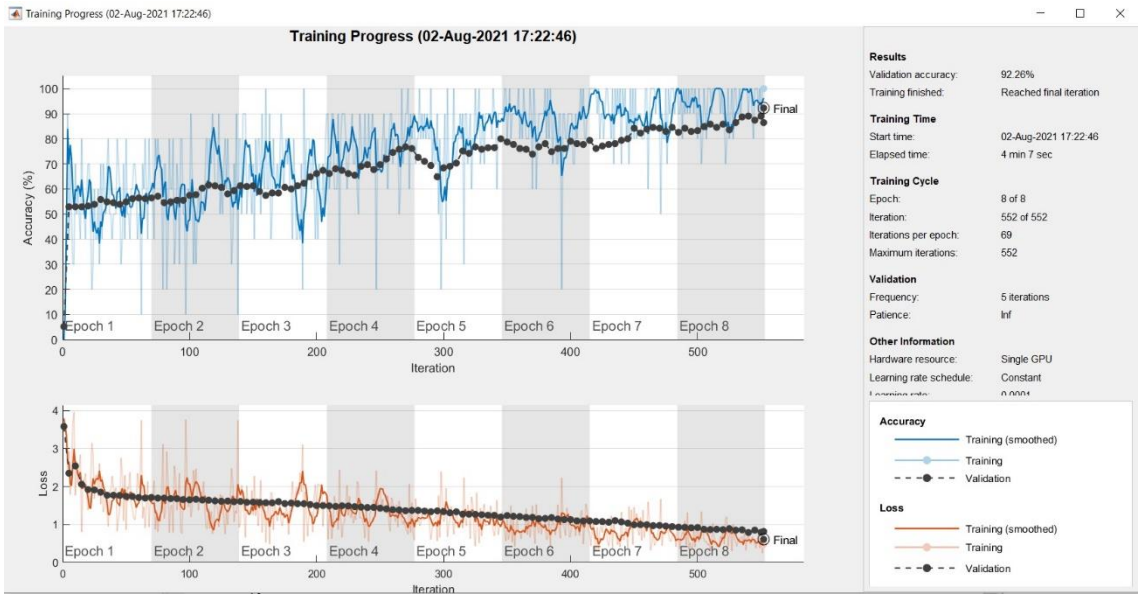
Şekil 53. Katmanlardaki işlemler

Tahmin edilen etiketlerle birlikte 25 örnek doğrulama resmin görüntülenmesi Şekil 54'teki gibi görülmektedir.



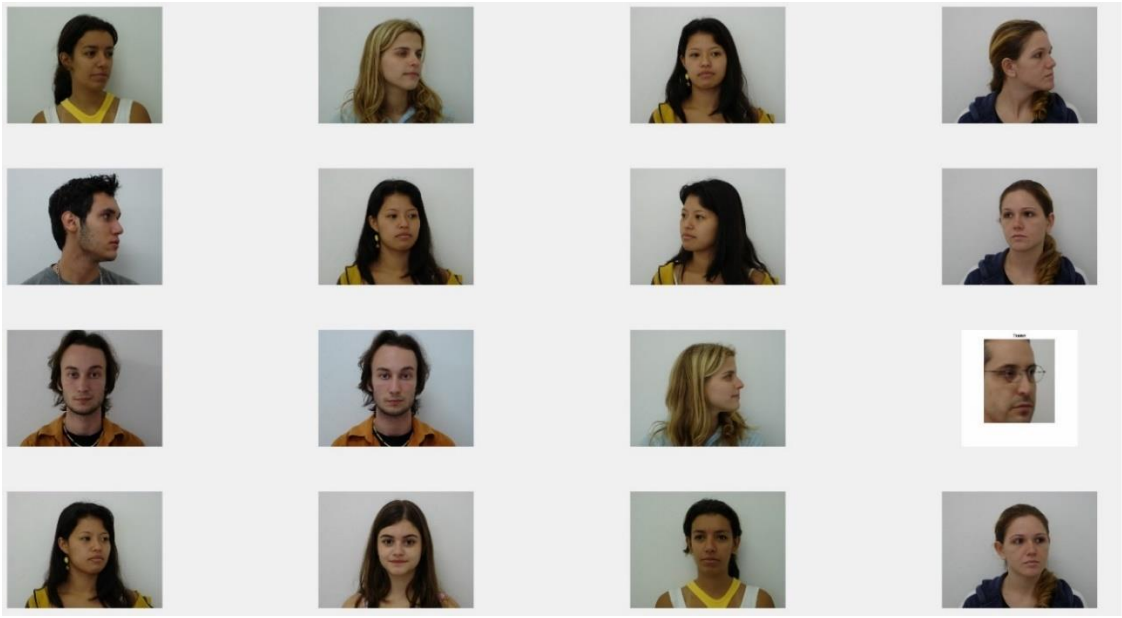
Şekil 54. 25 örnek doğrulama görüntüleri

39 farklı kişinin 462 yüz fotoğrafı ile elde edilen eğitim ağındaki doğruluk ilerlemesi Şekil 55'teki gibidir.



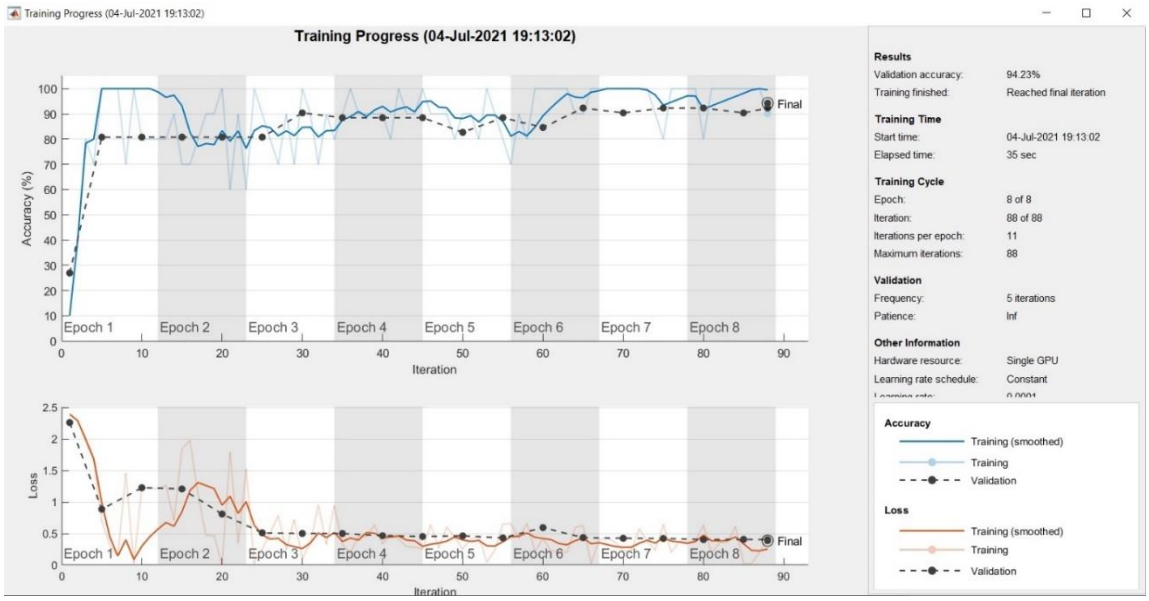
Şekil 55. ResNet-18 ağının ImageNet ile eğitimi

Eğitim sonucunda elde elde edilen doğruluk oranı %92,26'dır. ResNet-18 için sağ yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 56'daki gibidir.



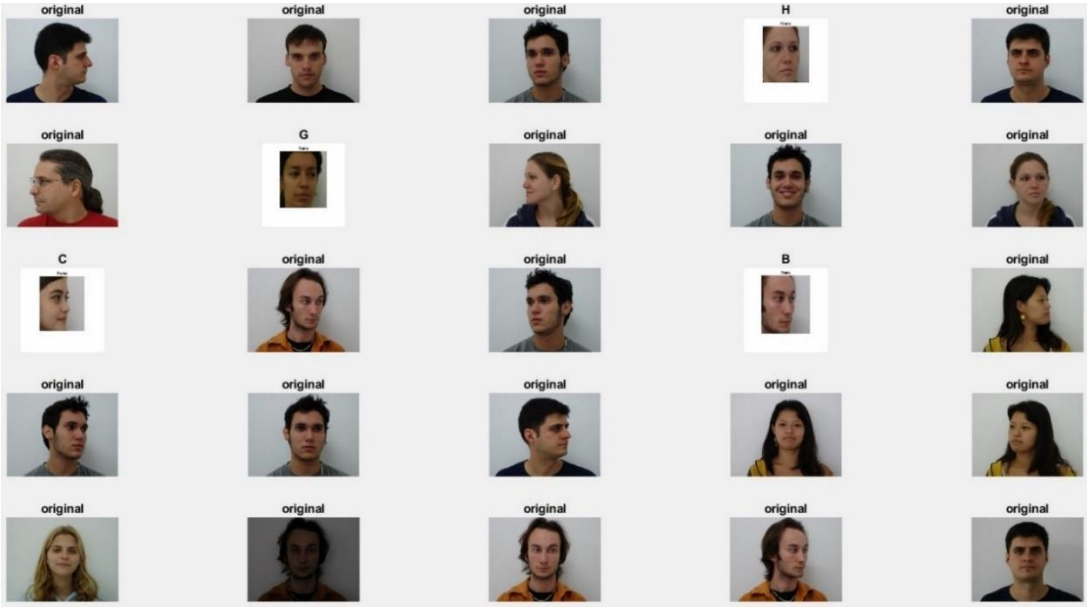
Şekil 56. Sağ yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 57'deki gibidir.



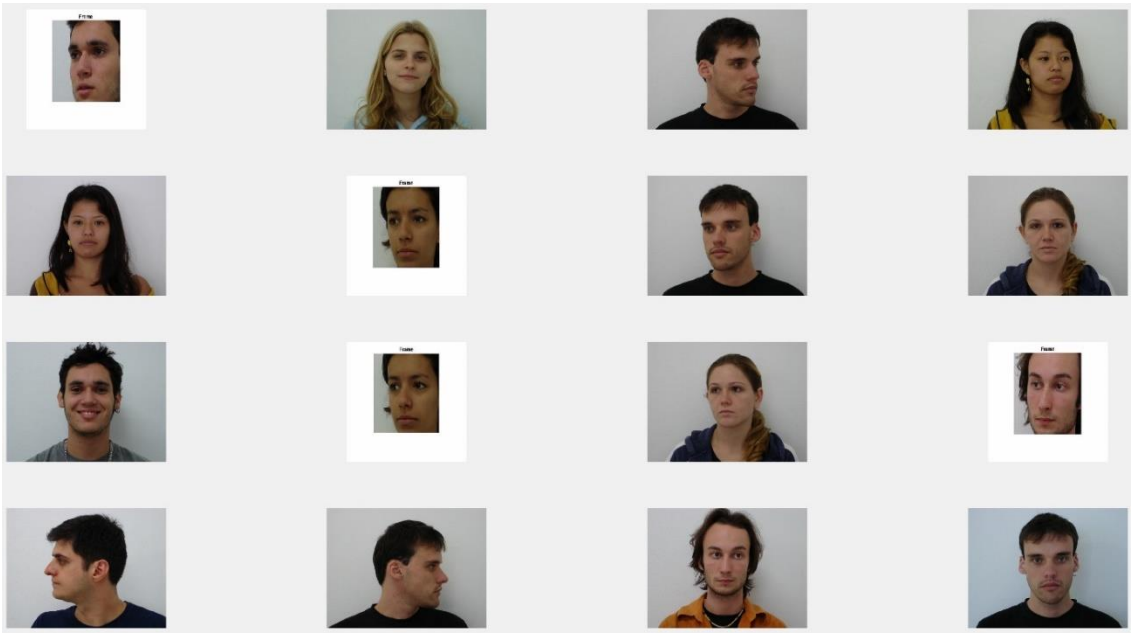
Şekil 57. ResNet-18 ağının ImageNet ile eğitimi

Epoch sayısı örnek olarak 8 değeri seçilmiştir. Özelliklere sahip katmanlar 72 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı sağ yüz resmi için %94,23 olarak sonuç vermiştir. Tahmin edilen etiketlerle birlikte 25 örnek doğrulama resmin görüntülenmesi Şekil 58'deki gibidir.



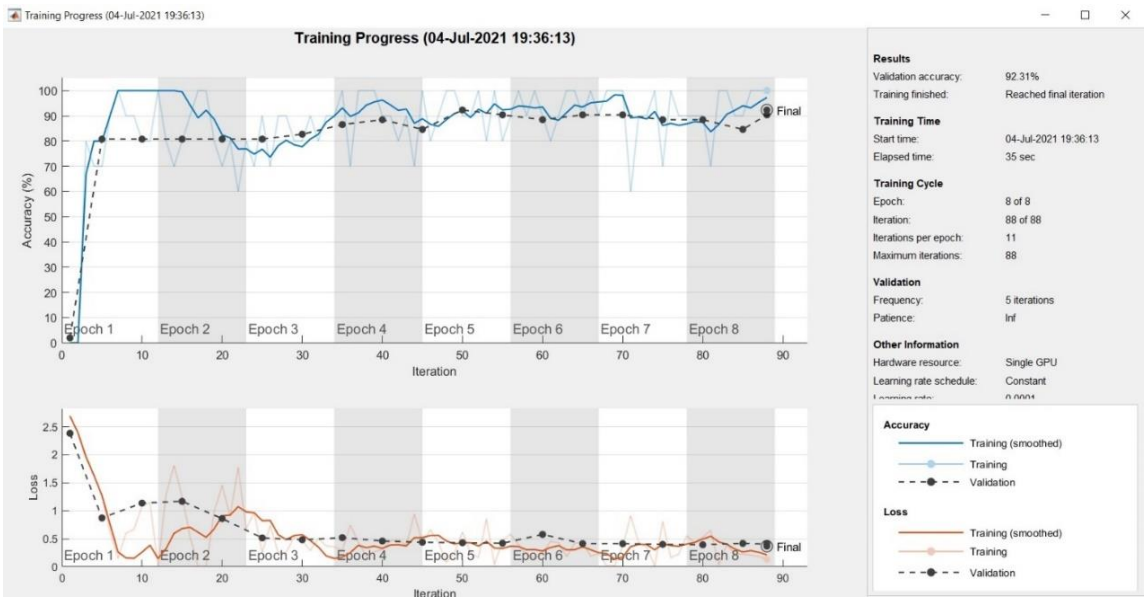
Şekil 58. 25 örnek doğrulama görüntüleri

ResNet-18 için sol yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 59'daki gibidir.



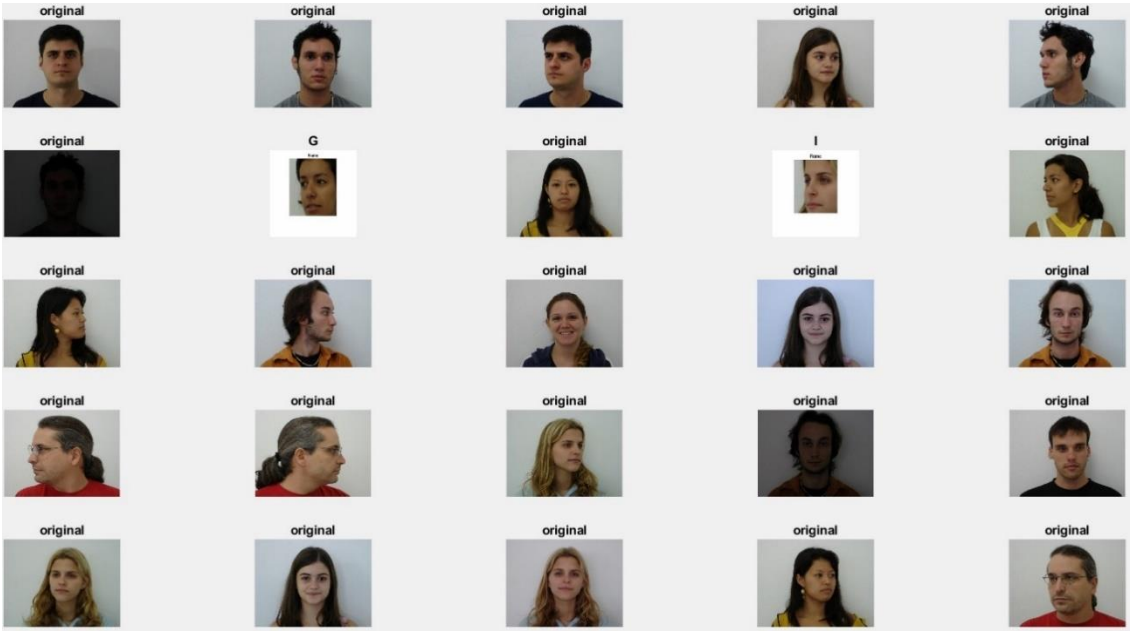
Şekil 59. Sol yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 60'taki gibidir.



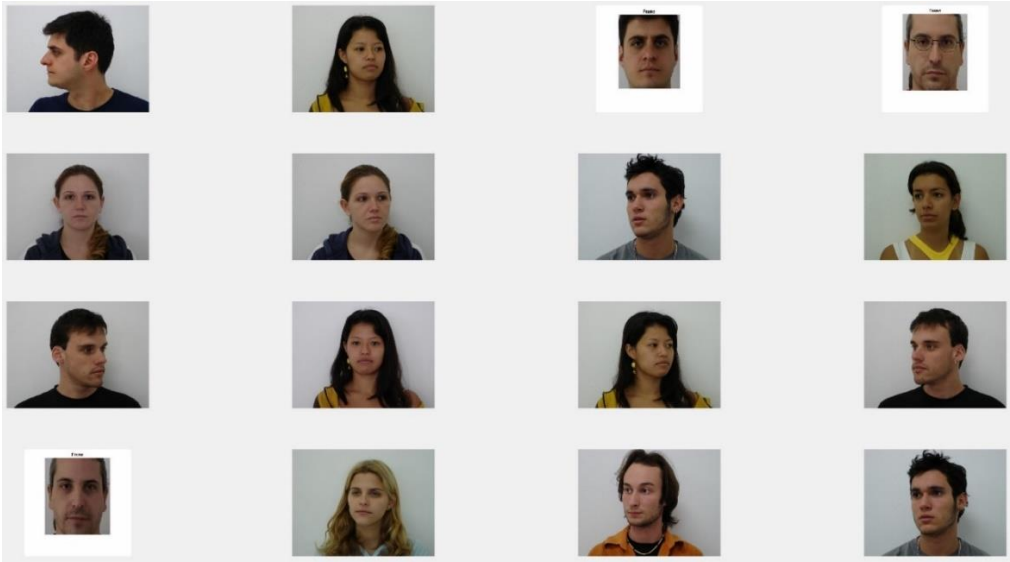
Şekil 60. ResNet-18 ağının ImageNet ile eğitimi

Epoch sayısı örnek olarak 8 alınmıştır. Özelliklere sahip katmanlar 72x1 boyutunda olup, ImageNet veri tabanında doğruluk oranı sol yüz resmi için %92,31 olarak sonuç vermiştir. Tahmin edilen etiketlerle birlikte 25 örnek doğrulama resmin görüntülenmesi Şekil 61'deki gibidir.



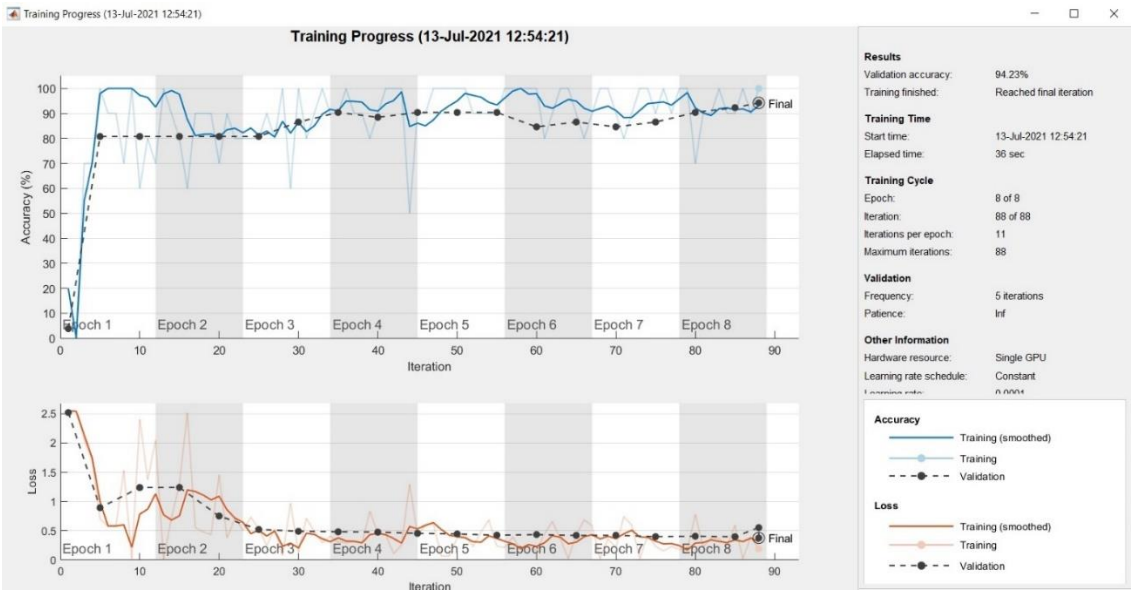
Şekil 61. 25 örnek doğrulama görüntüleri

ResNet-18 için orta yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 62'deki gibidir.



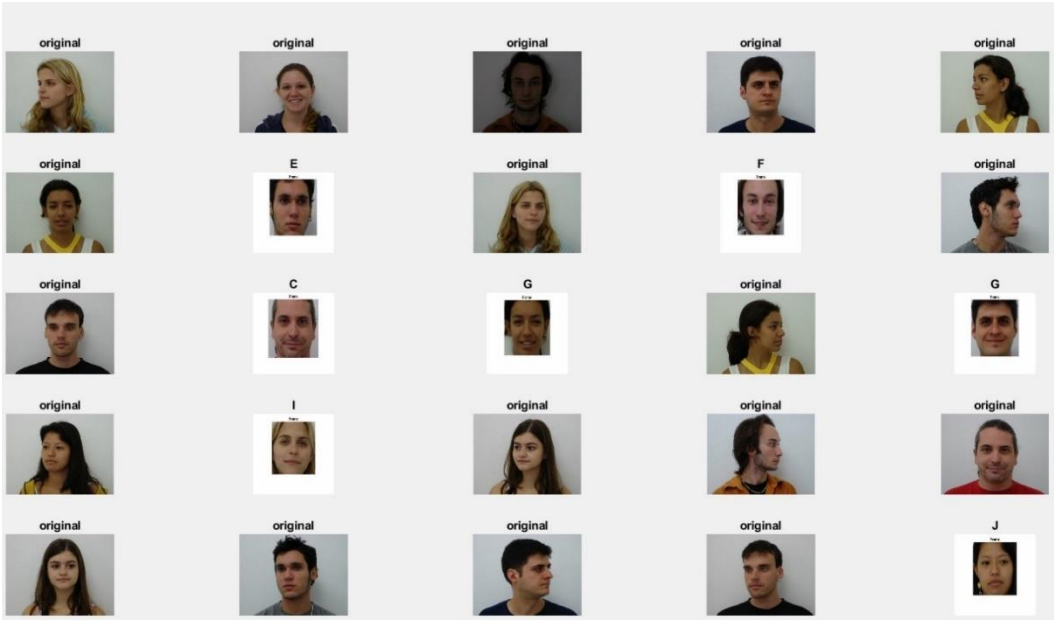
Şekil 62. Orta yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 63'teki gibidir.



Şekil 63. ResNet-18 ağının ImageNet ile eğitimi

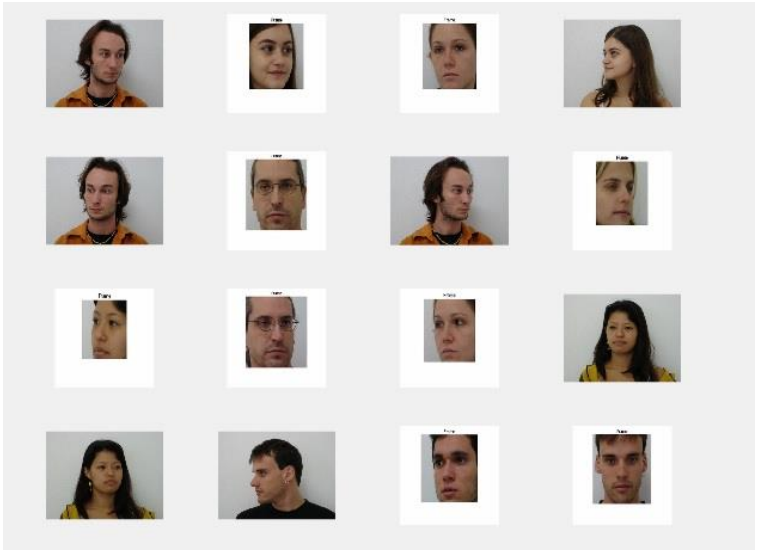
Epoch sayısı örnek olarak 8 alınmıştır. Özelliklere sahip katmanlar 72x1 boyutunda olup, ImageNet veri tabanında doğruluk oranı orta yüz resmi için %94,23 olarak sonuç vermiştir. Tahmin edilen etiketlerle birlikte 25 örnek doğrulama resmin görüntülenmesi Şekil 64'teki gibidir.



Şekil 64. 25 örnek doğrulama görüntüleri

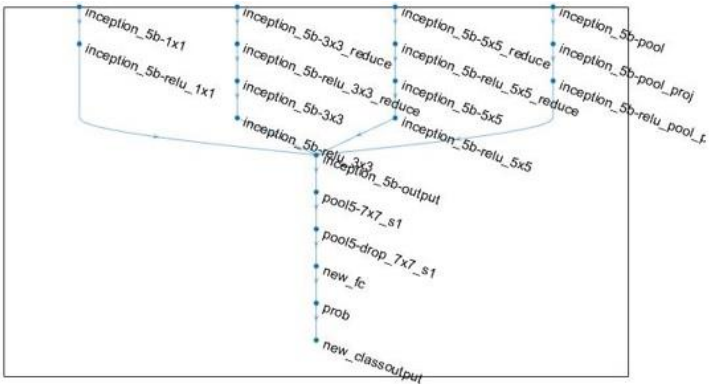
6.6. GoogleNet ve SquuezeNet Mimarisi ile Yüz Tanıma

GoogleNet için 120 tane yüz fotoğrafı kullanılmıştır. Veriler her bir kişi için ayrı klasörde ve orijinal resimlerin tamamı ayrı klasörde oluşturulmuştur. Görüntü giriş katmanı 224 x 224 x 3 boyutuna çevrilmiştir. Her kişinin görüntüleri için ayrı klasör oluşturulmuştur. Bu veri seti için bazı örnek resimler Şekil 65'teki gibidir.



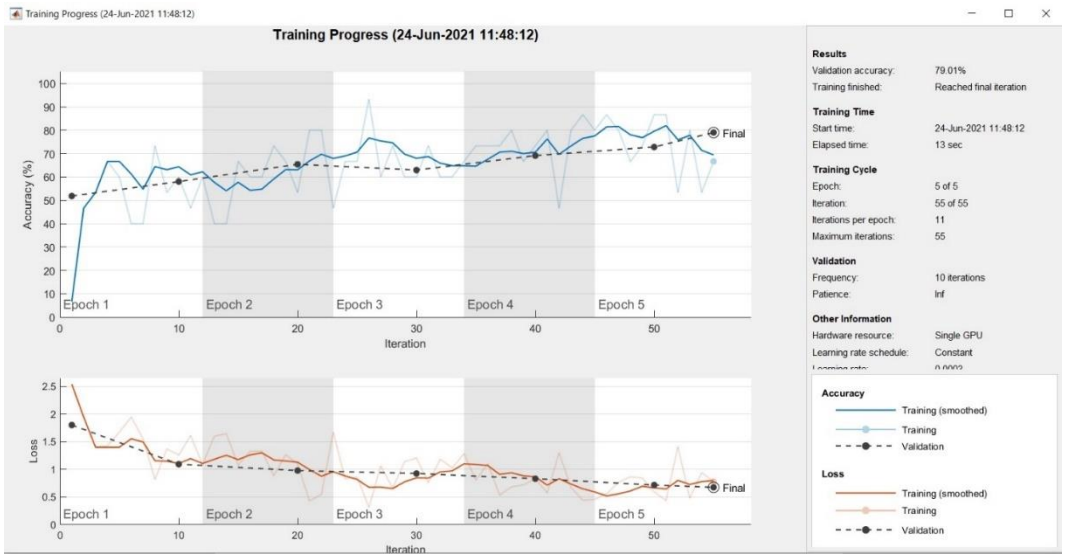
Şekil 65. Okuma görüntüsü

Ağın evrişimli katmanları, öğrenilebilir son katman ve sınıflandırma katmanının giriş görüntüsünü sınıflandırabilmek için kullandığı görüntünün özelliklerini çıkarır. Bu iki katman ağın çıkardığı özelliklerin sınıf olasılıklarına, kayıp değerine ve tahmin edilen etiketleri nasıl birleştireceği hakkında bilgiler içermektedir. Son bağlı katmanı yeni veri kümesine uyarlanmış yeni sınıflandırma katmanı ile değişmiştir. Bu transfer öğreniminden sonraki oluşan katmanlar Şekil 66'daki gibidir.



Şekil 66. Transfer öğreniminden sonra GoogleNet katmanları

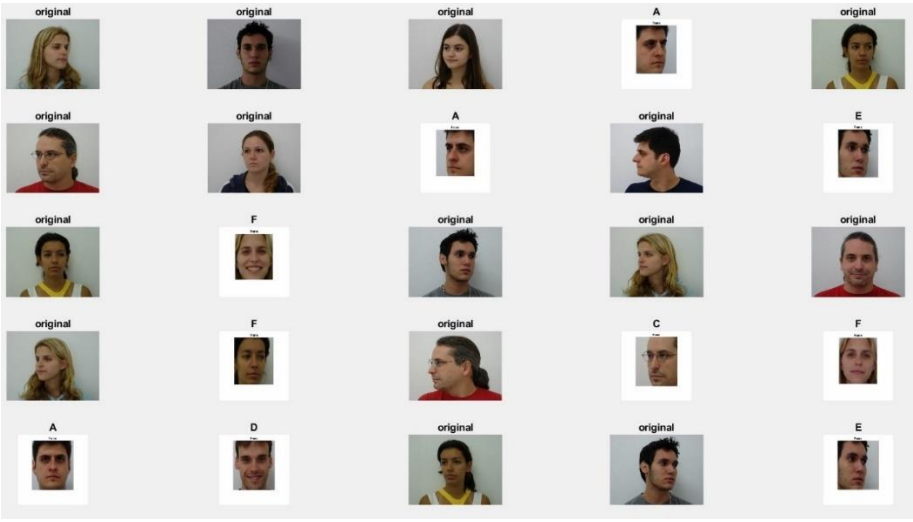
Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 67'teki gibi görülmektedir.



Şekil 67. GoogleNet ağının ImageNet ile eğitimi

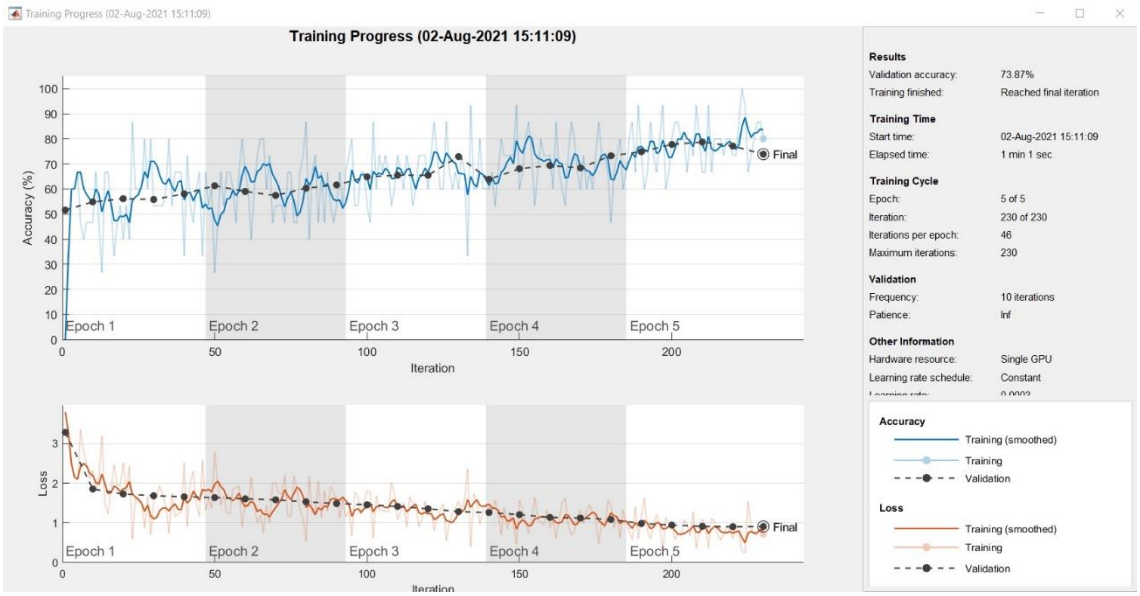
Epoch sayısı örnek olarak 5 seçilmiştir. Özelliklere sahip katmanlar 144 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı %79,01 olarak sonuç vermiştir.

GoogleNet'te ilk 10 katman, ağın ilk kökünü oluşturur. Eğitim görüntülerini otomatik olarak yeniden boyutlandırmak için genişletilmiş bir veri deposu kullanılmıştır. Bu görüntüler yatay ve dikey olarak %10'a kadar ölçeklendirip rastgele 30 piksele kadar çevrilmiştir. Tahmin edilen etiketlere sahip doğrulama görüntüsü Şekil 68'daki gibidir.



Şekil 68. 25 örnek doğrulama görüntüleri

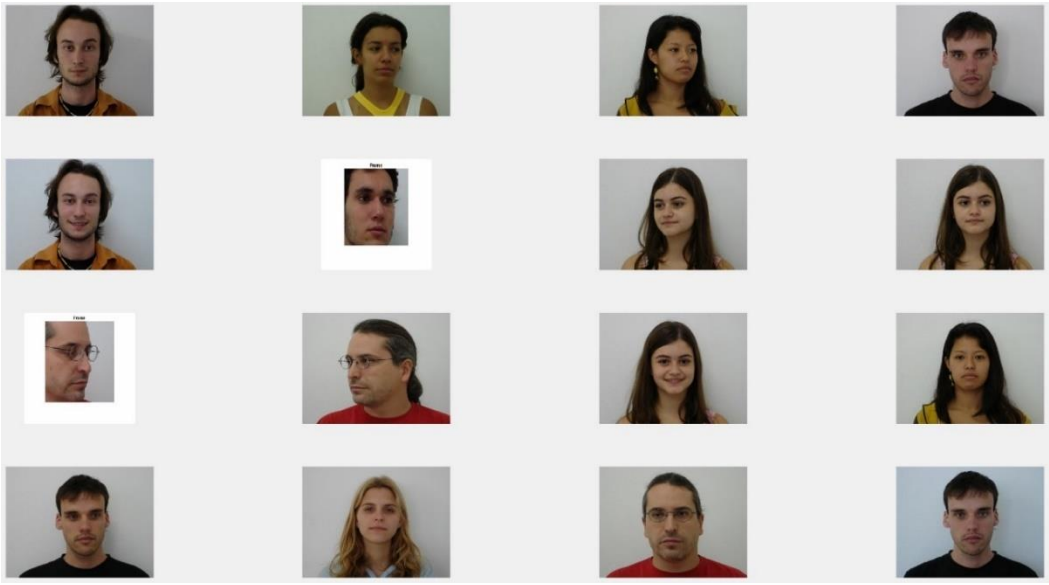
39 farklı kişinin 462 yüz fotoğrafı ile elde edilen eğitim ağındaki doğruluk ilerlemesi Şekil 69'daki gibidir.



Şekil 69. GoogleNet ağının ImageNet ile eğitimi

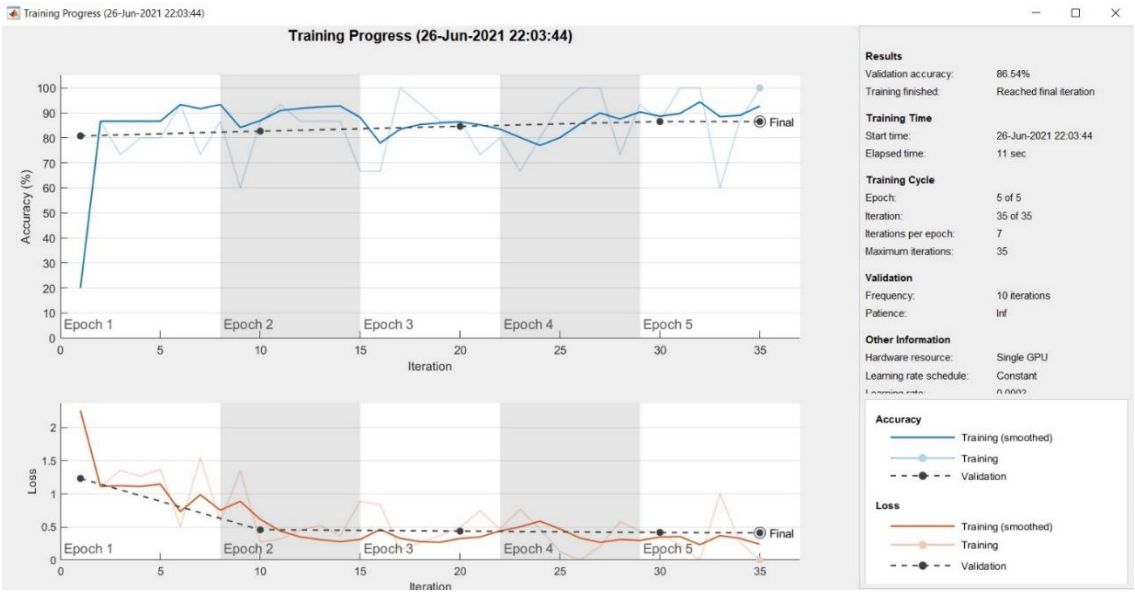
Eğitim ilerlemesinde oluşan doğruluk oranı %73,87 olarak sonuç vermiştir.

GoogleNet için sağ yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 70'teki gibidir.



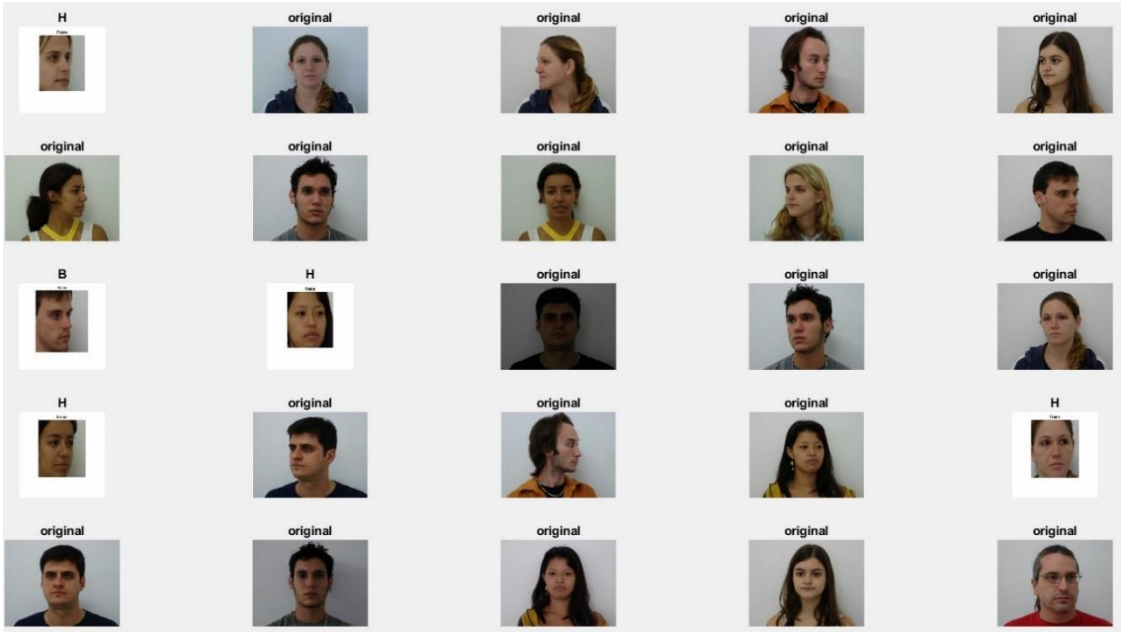
Şekil 70. Sağ yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 71'deki gibidir.



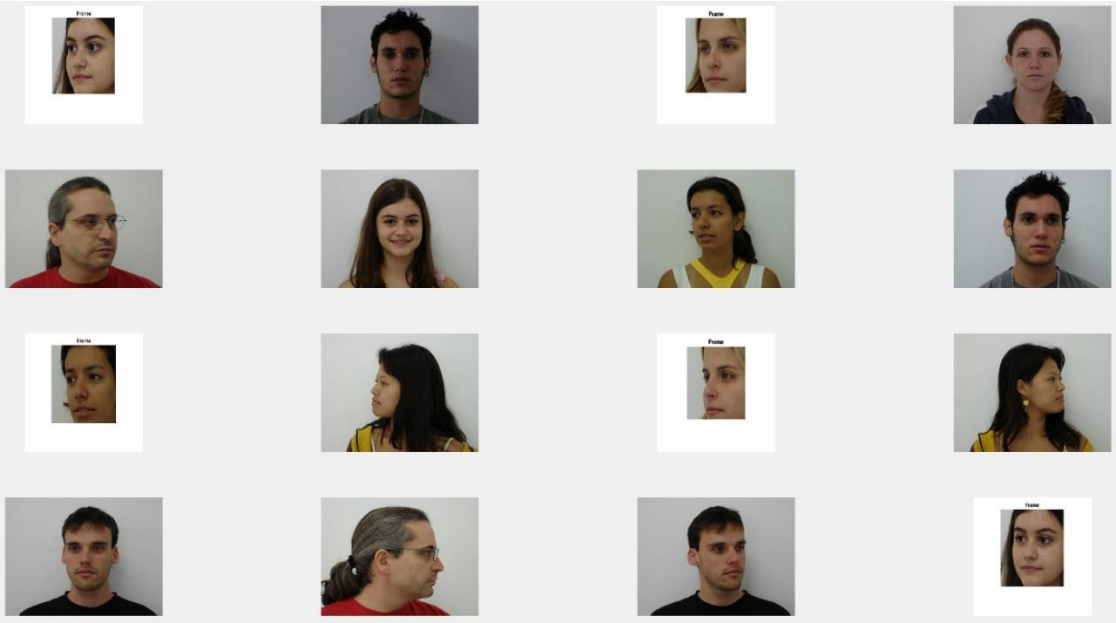
Şekil 71. GoogleNet ağının ImageNet ile eğitimi

Epoch sayısı örnek olarak 5 alınmıştır. Özelliklere sahip katmanlar 144 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı sağ yüz resmi için %86,54 olarak sonuç vermiştir. Tahmin edilen etiketlere ve bu etiketlere sahip görüntülerin tahmin edilen olasılıklara sahip 25 örnek doğrulama görüntüsü Şekil 72'deki gibidir.



Şekil 72. 25 örnek doğrulama görüntüleri

GoogleNet için sol yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 73'teki gibidir.



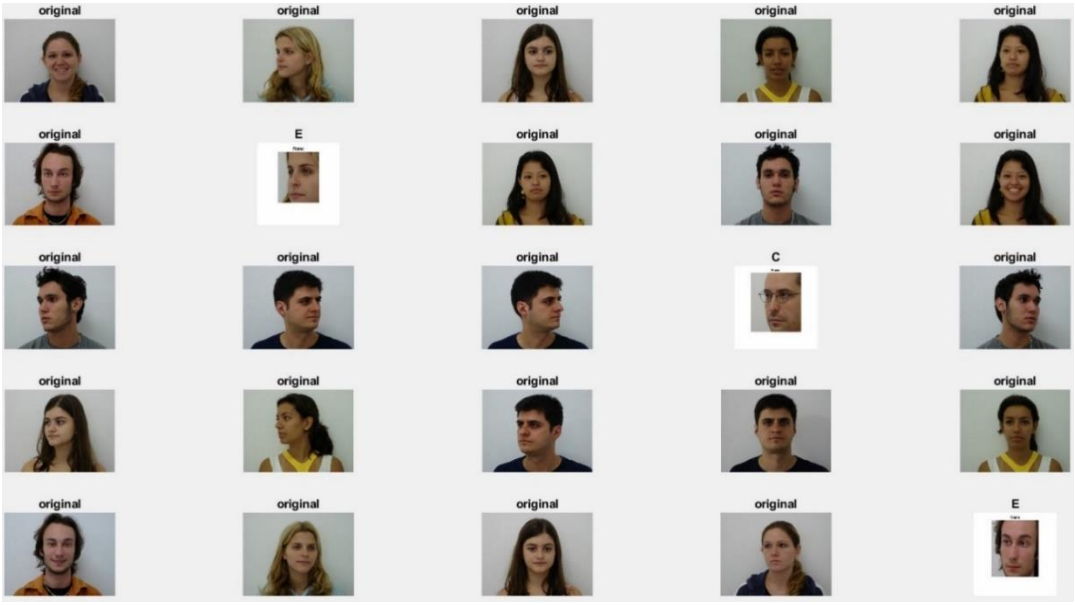
Şekil 73. Sol yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 74'teki gibidir.



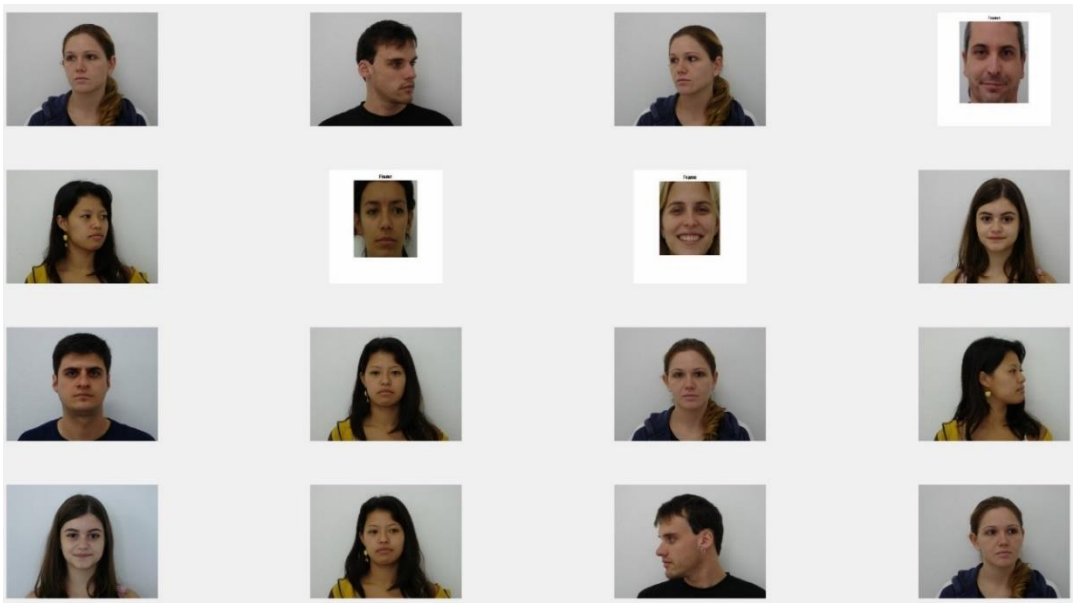
Şekil 74. GoogleNet ağının ImageNet ile eğitimi

Epoch sayısı örnek olarak 5 alınmıştır. Özelliklere sahip katmanlar 144 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı sol yüz resmi için %86,54 olarak sonuç vermiştir. Tahmin edilen etiketlere ve bu etiketlere sahip görüntülerin tahmin edilen olasılıklara sahip 25 örnek doğrulama görüntüsü Şekil 75'teki gibidir.



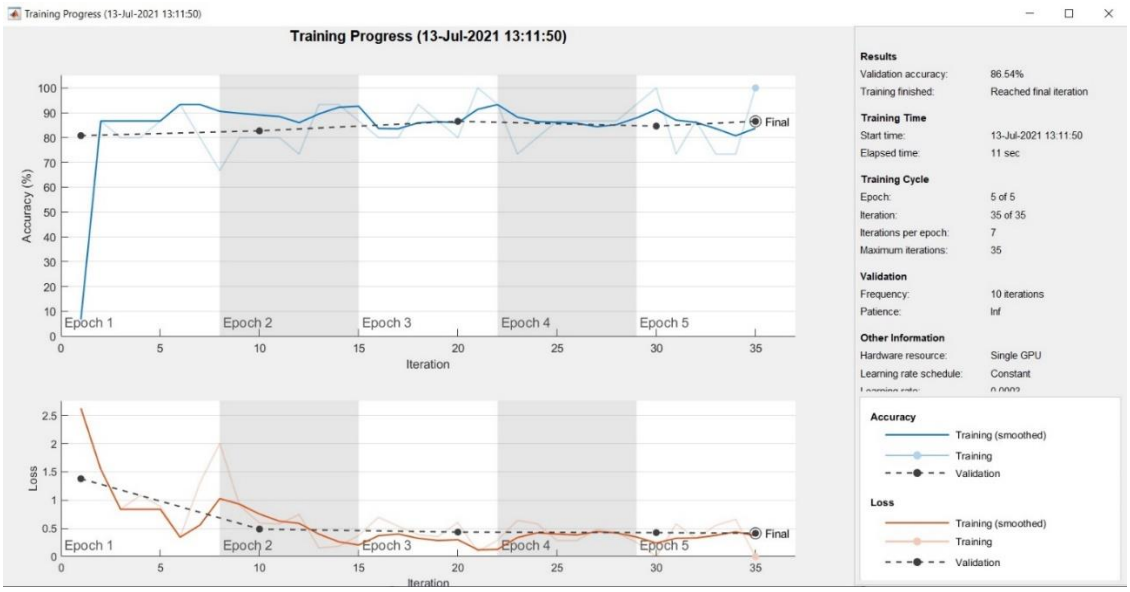
Şekil 75. 25 örnek doğrulama görüntüleri

GoogleNet için orta yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 76'daki gibi görülmektedir.



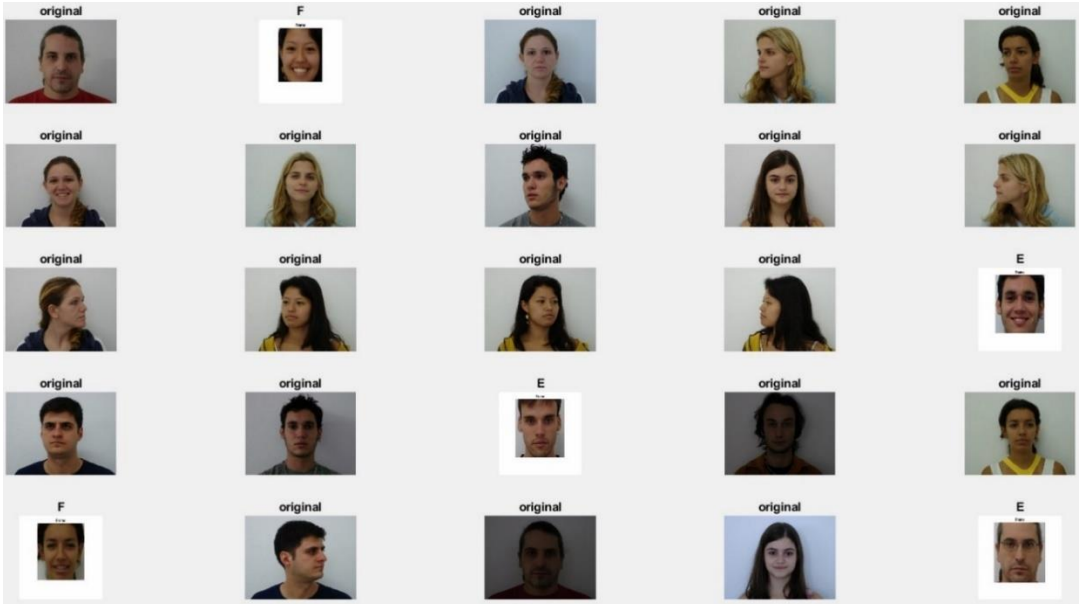
Şekil 76. Orta yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 77'teki gibidir.



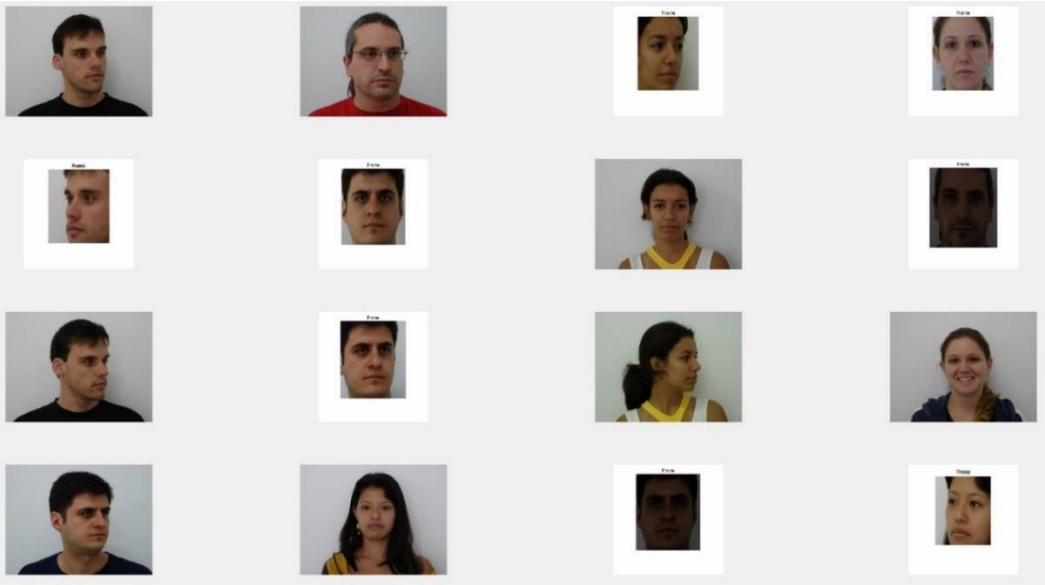
Şekil 77. GoogleNet ağının ImageNet ile eğitimi

Epoch sayısı örnek olarak 5 alınmıştır. Özelliklere sahip katmanlar 144 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı orta yüz resmi için %86,54 olarak sonuç vermiştir. Tahmin edilen etiketlere ve bu etiketlere sahip görüntülerin tahmin edilen olasılıklara sahip 25 örnek doğrulama görüntüsü Şekil 78'deki gibidir.



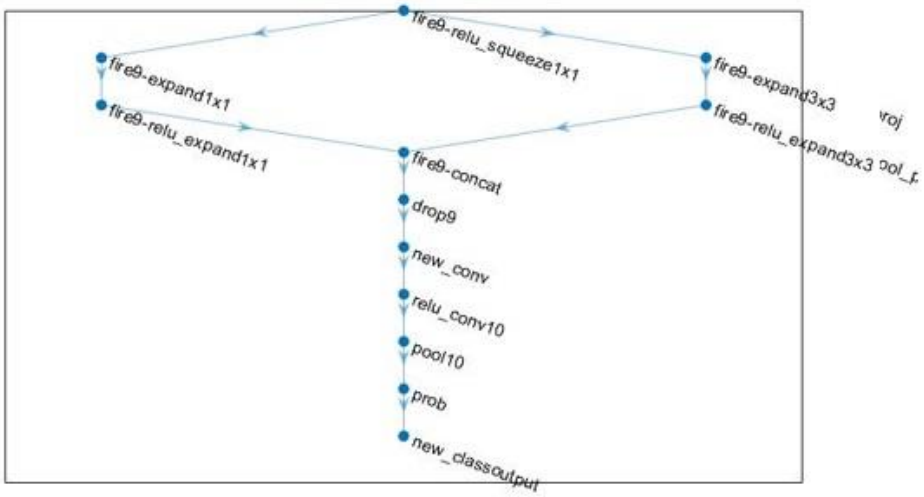
Şekil 78. 25 örnek doğrulama görüntüleri

SqueezeNet mimarisi için 120 tane yüz fotoğrafı kullanılmıştır. Görüntü giriş katmanı 227 x 227 x 3 boyutundadır. Veriler her bir kişi için ayrı klasörde ve orijinal resimlerin tamamı ayrı klasörde oluşturulmuştur. Bu veri seti için bazı örnek resimler Şekil 79'daki gibidir.



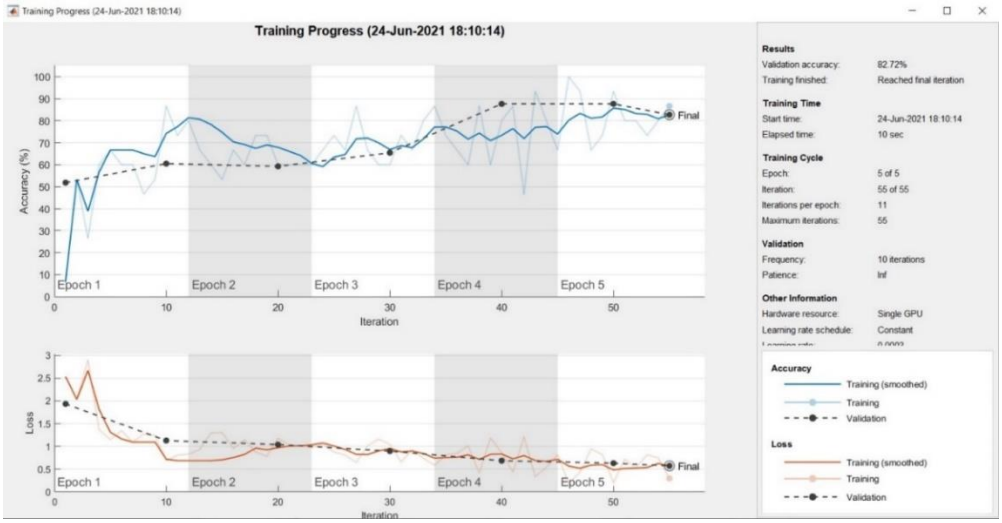
Şekil 79. Okuma görüntüsü

Yeni görüntüleri sınıflandırabilmek için önceden eğitilmiş bir ağı yeniden eğitmek için, son katmanı yeni veri kümesine uyarlanmış yeni katmanla değiştirilmiştir. Bu transfer öğreniminden sonraki oluşan katmanlar Şekil 80'deki gibidir.



Şekil 80. Transfer öğreniminden sonra SqueezeNet katmanları

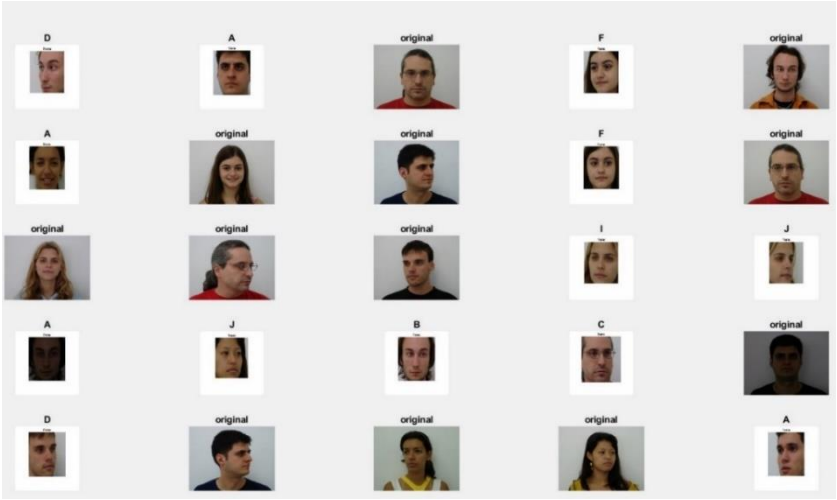
Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 81'deki gibidir.



Şekil 81. SqueezeNet ağının ImageNet ile eğitimi

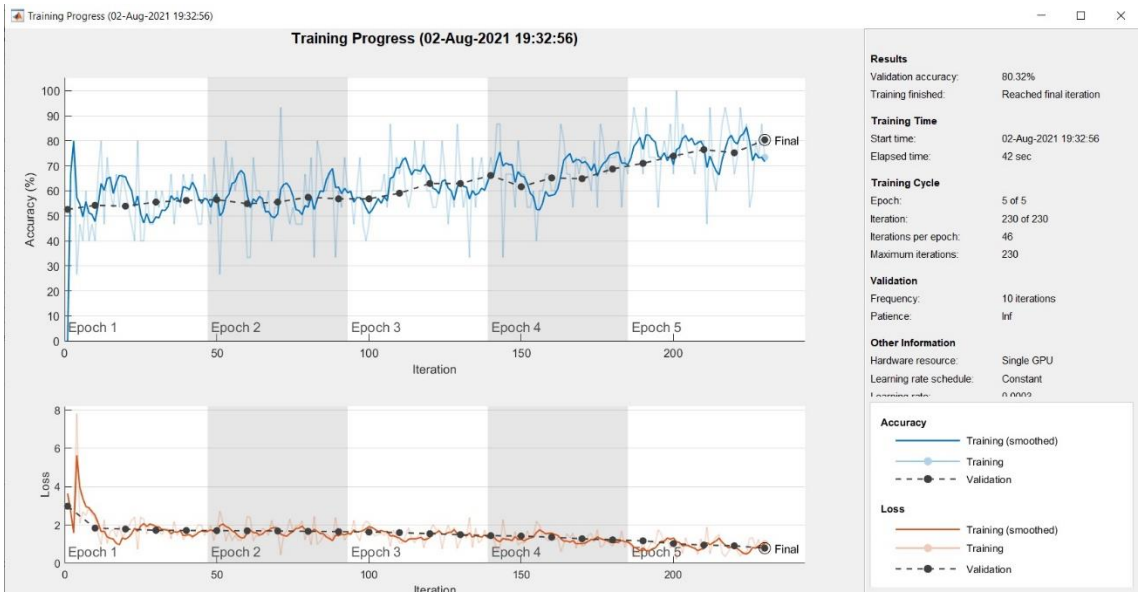
Epoch sayısı örnek olarak 5 alınmıştır. Özelliklere sahip katmanlar 68 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı %82,72 olarak sonuç vermiştir.

SqueezeNet'te ilk 10 katman, ağın ilk kökünü oluşturur. Eğitim görüntülerini otomatik olarak yeniden boyutlandırmak için genişletilmiş bir veri deposu kullanılmıştır. Bu görüntüler yatay ve dikey olarak %10'a kadar ölçeklendirip rastgele 30 piksele kadar çevrilmiştir. Eğitim verileri kullanılarak ağ eğitildiğinde 25 örnek doğrulama görüntüsü Şekil 82'deki gibidir.



Şekil 82. 25 örnek doğrulama görüntüleri

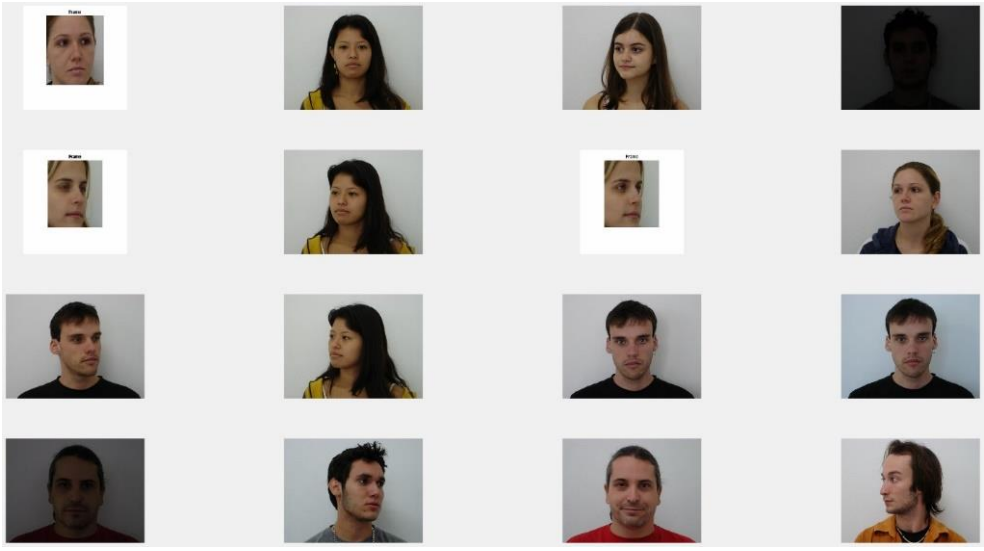
39 farklı kişinin 462 yüz fotoğrafı ile elde edilen eğitim ağındaki doğruluk ilerlemesi Şekil 83'teki gibidir.



Şekil 83. SqueezeNet ağının ImageNet ile eğitimi

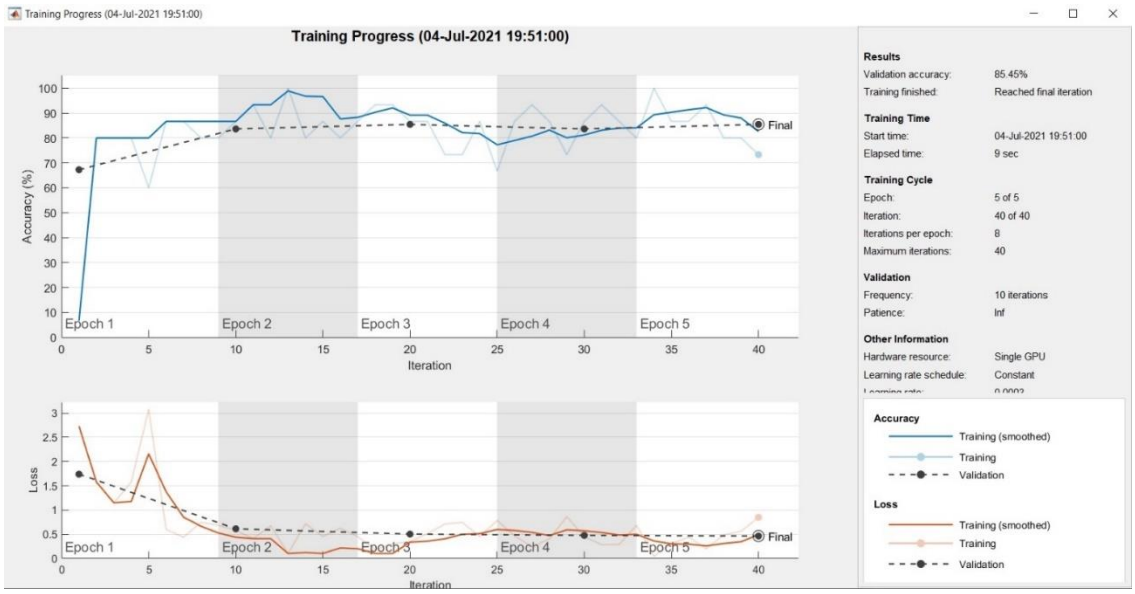
Eğitim ilerlemesinde oluşan doğruluk oranı %80,32 olarak sonuç vermiştir.

SqueezeNet için sağ yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 84'teki gibidir.



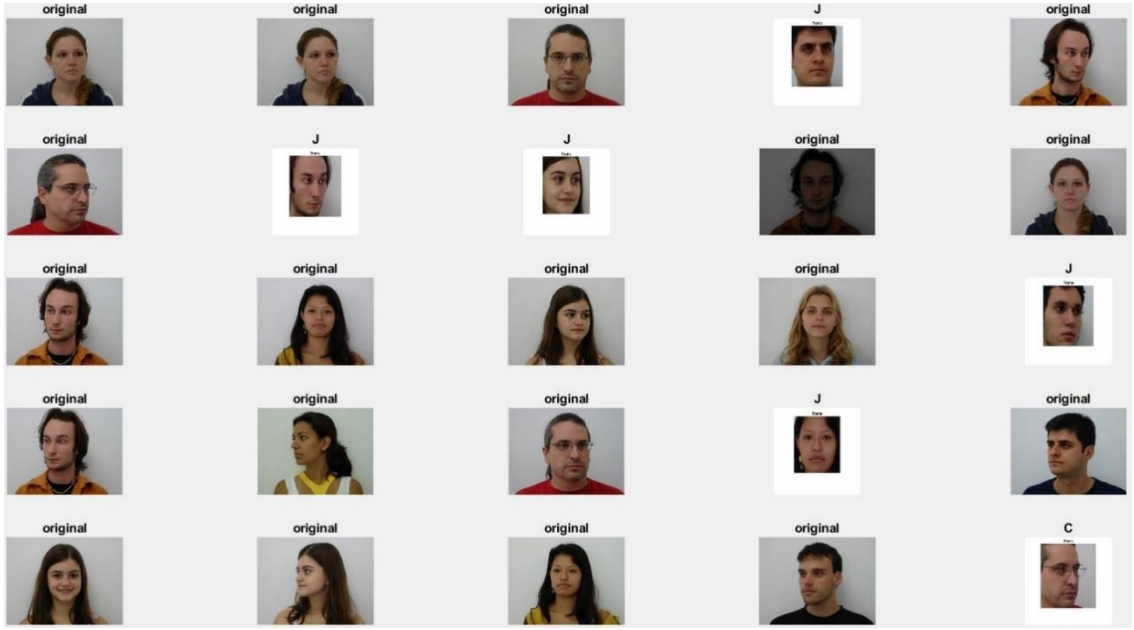
Şekil 84. Sağ yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 85'teki gibidir.



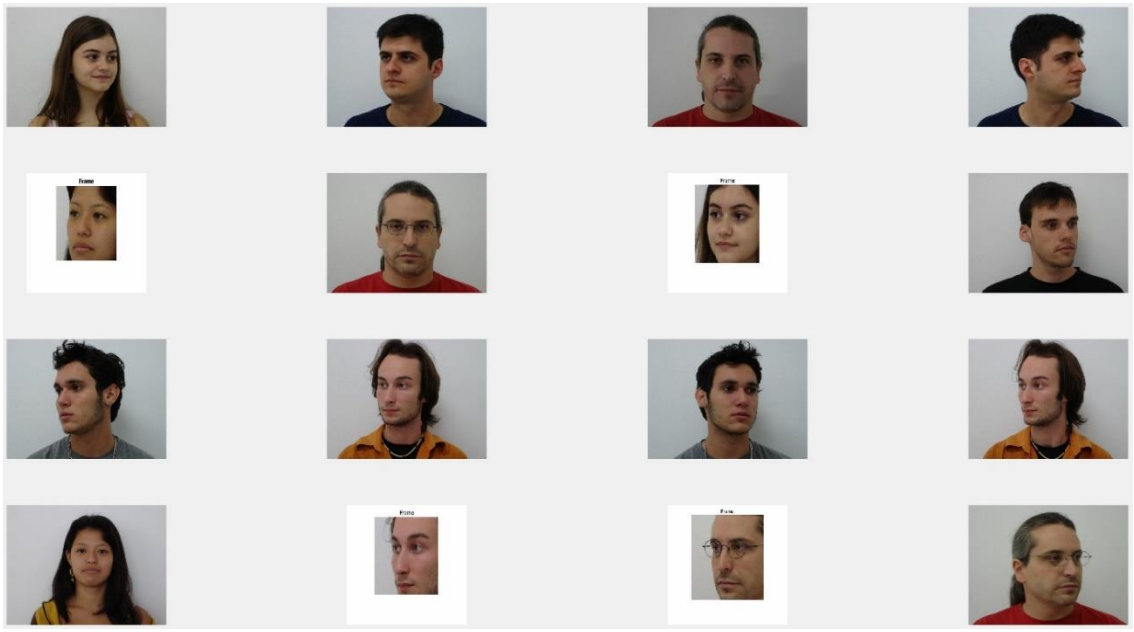
Şekil 85. SqueezeNet ağının ImageNet ile eğitimi

Epoch sayısı örnek olarak 5 alınmıştır. Özelliklere sahip katmanlar 68 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı sağ yüz resmi için %85,45 olarak sonuç vermiştir. Tahmin edilen etiketlere ve bu etiketlere sahip görüntülerin tahmin edilen olasılıklara sahip 25 örnek doğrulama görüntüsü Şekil 86'daki gibidir.



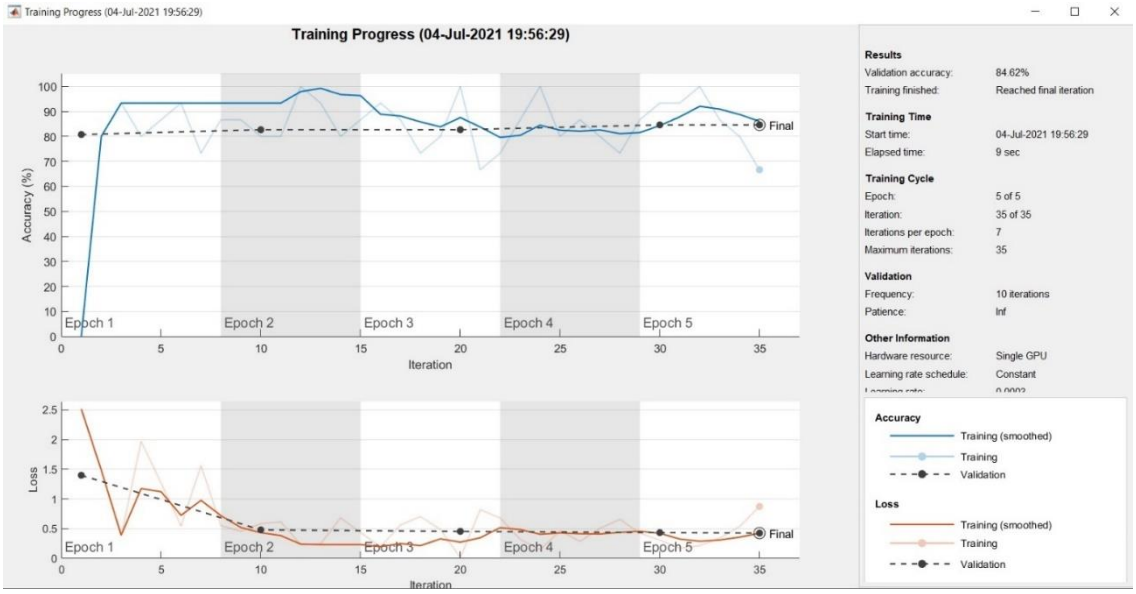
Şekil 86. 25 örnek doğrulama görüntüleri

SqueezeNet için sol yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 87'deki gibidir.



Şekil 87. Sol yüz resmi okuma görüntüsü

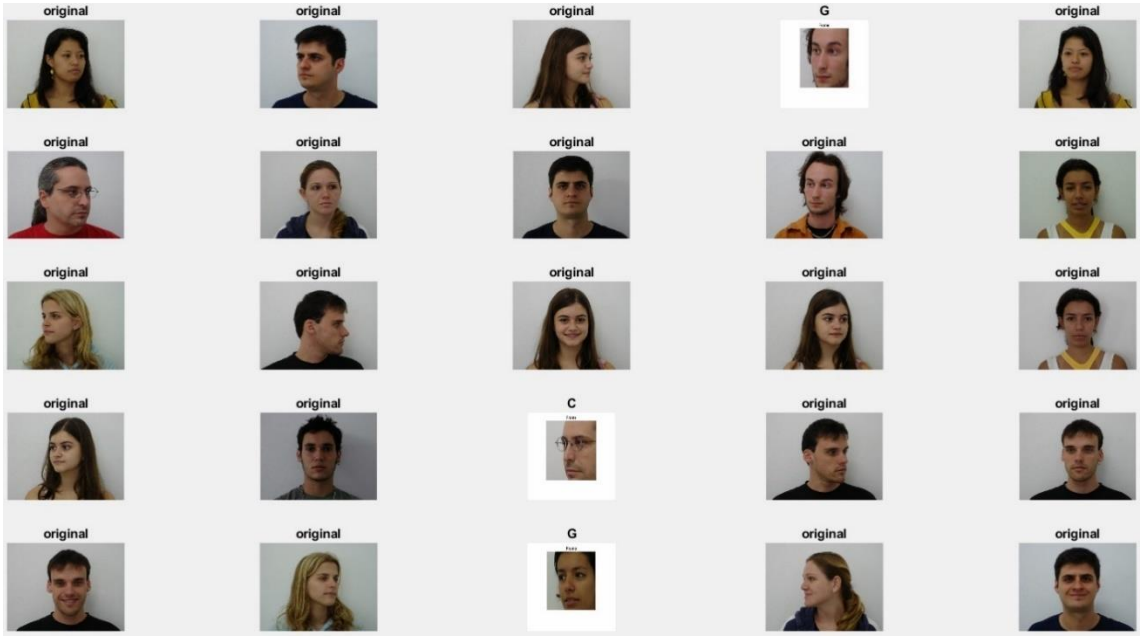
Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 88'deki gibidir.



Şekil 88. SqueezeNet ağının ImageNet ile eğitimi

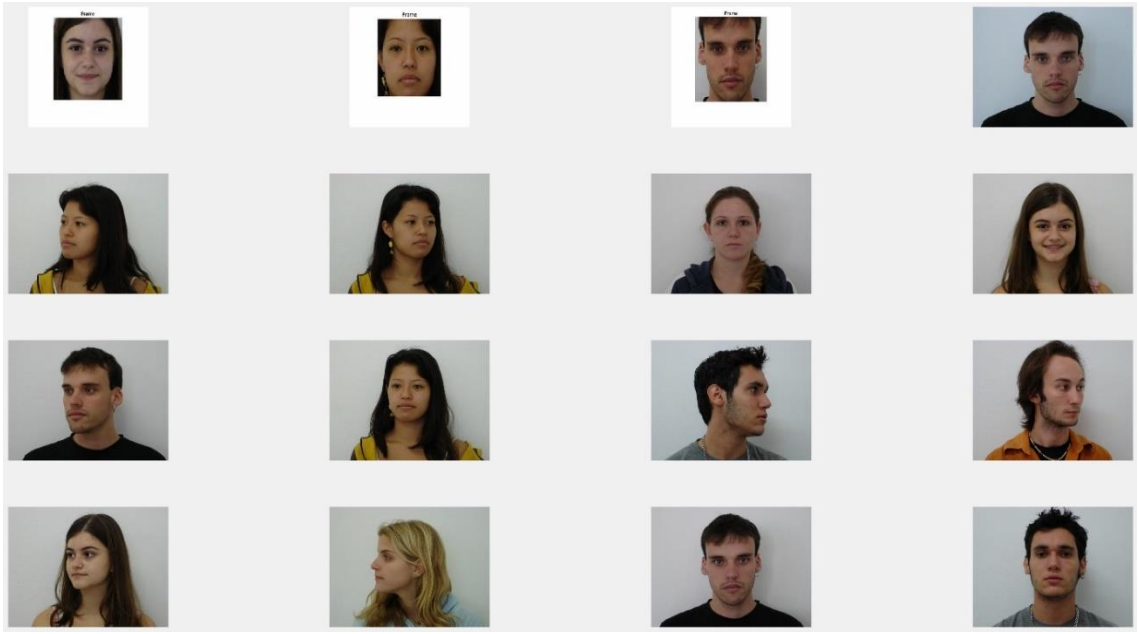
Epoch sayısı örnek olarak 5 alınmıştır. Özelliklere sahip katmanlar 68 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı sol yüz resmi için %84,62 olarak sonuç

vermiştir. Tahmin edilen etiketlere ve bu etiketlere sahip görüntülerin tahmin edilen olasılıklara sahip 25 örnek doğrulama görüntüsü Şekil 89'daki gibidir.



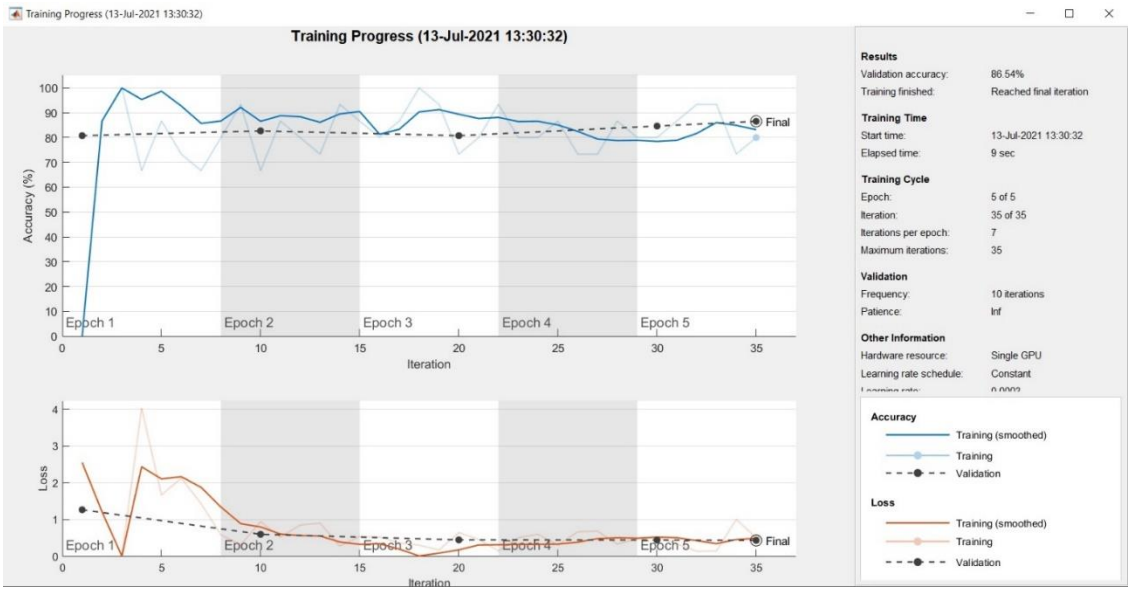
Şekil 89. 25 örnek doğrulama görüntüleri

SqueezeNet için orta yüz resimleri kullanıldığında elde edilen bu örnek veri seti için bazı örnek resimler Şekil 90'daki gibidir.



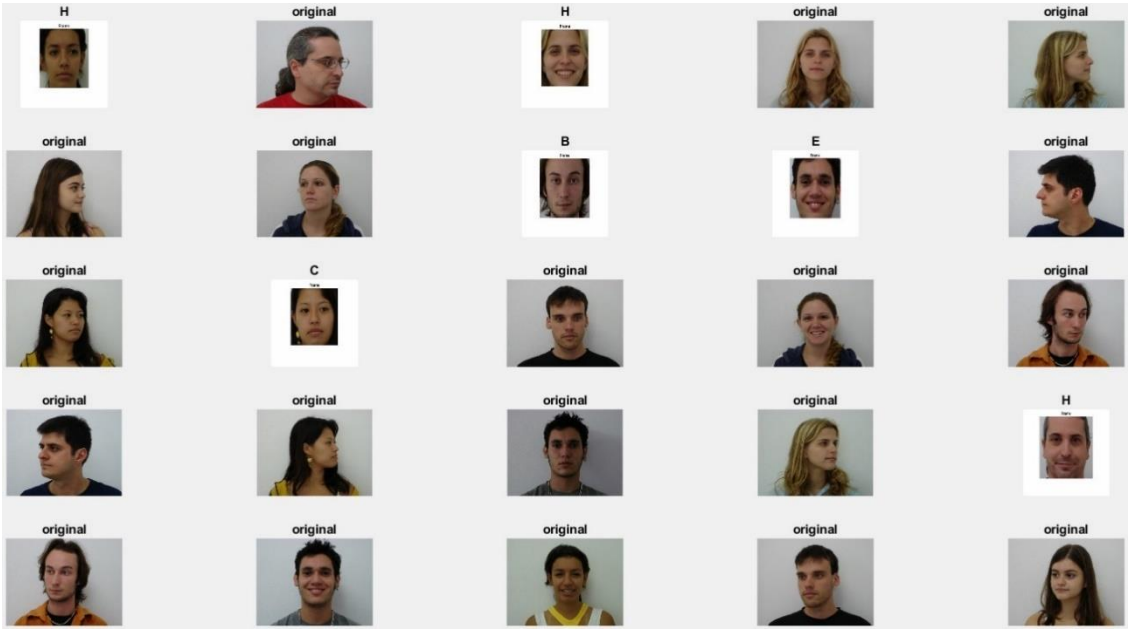
Şekil 90. Orta yüz resmi okuma görüntüsü

Eğitim ilerlemesinde oluşan doğruluk eğrisi Şekil 91'deki gibi görülmektedir.



Şekil 91. SqueezeNet ağının ImageNet ile eğitimi

Epoch sayısı örnek olarak 5 seçilmiştir. Özelliklere sahip katmanlar 68 x 1 boyutunda olup, ImageNet veri tabanında doğruluk oranı orta yüz resmi için %86,54 olarak sonuç vermiştir. Tahmin edilen etiketlere ve bu etiketlere sahip görüntülerin tahmin edilen olasılıklara sahip 25 örnek doğrulama görüntüsü Şekil 92'deki gibidir.



Şekil 92. 25 örnek doğrulama görüntüleri

Viola-Jones algoritması ile yüz bulma için elde edilen doğruluk oranı Tablo 5'te gösterildiği gibi sonuçlar vermiştir.

Tablo 5. Viola-Jones ile yüz bulma görüntülerinin doğruluk oranı

	Toplam yüz görüntüsü	Bulunan yüz görüntüsü	Bulunamayan yüz görüntüsü	Doğruluk oranı (%)
Viola-Jones	140	120	20	85,71
Viola-Jones	546	462	84	84,61

Özyüzler ve Fisherfaces yöntemi ile yüz tanıma için kullanılan veri setinde bulunan görüntülerin sayılarına ve pozlarına göre elde edilen başarı oranları Tablo 6 ve Tablo 7'deki gibidir.

Tablo 6. Özyüzler ile yüz tanıma doğruluk oranı

	Toplam yüz görüntüsü	Toplam test görüntüsü	Toplam eğitim görüntüsü	Doğru yüz görüntüsü	Yanlış yüz görüntüsü	Doğruluk oranı (%)
Özyüzler sağ poz	120	30	90	13	17	43,33
Özyüzler sol poz	120	30	90	6	24	20
Özyüzler orta poz	120	30	90	23	7	76,66

Tablo 7. Fisherfaces ile yüz tanıma doğruluk oranı

	Toplam yüz görüntüsü	Toplam test görüntüsü	Toplam eğitim görüntüsü	Doğru yüz görüntüsü	Yanlış yüz görüntüsü	Doğruluk oranı (%)
Fisherfaces sağ poz	120	30	90	18	12	60
Fisherfaces sol poz	120	30	90	6	24	20
Fisherfaces orta poz	120	30	90	22	8	73,33

Tablo 6 ve Tablo 7'de görüldüğü üzere hem özyüzler hem de fisherfaces için sol poz için yapılan denemelerde elde edilen başarım oranı çok düşük çıkmıştır. Ancak sağ kısımda daha iyi sonuçlar elde edilmiştir. Karşıdan çekilen, yani yüzün bütün alanının görüldüğü resimler hem özyüzler hem de fisherfaces algoritmaları için daha başarılı sonuçlar elde edilmiştir.

Derin öğrenme mimarileri ile yüz tanıma için epoch sayıları ile çalışmalar yapılmıştır. AlexNet mimarisi ile yüz tanıma yönteminde yapılan denemelerde epoch sayısının belirlenebilmesi için 3–10 aralığında denemeler yapılmıştır. Yapılan çalışmalar için elde edilen doğruluk oranları Tablo 8'deki gibi bulunmuştur.

Tablo 8. AlexNet ile yüz tanımada epoch sayısına göre doğruluk oranı

AlexNet		**Epoch değeri**							
Görüntü sayısı		**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
120	**Doğruluk oranı (%)**	77,78	83,95	91,36	83,95	86,42	79,01	90,12	90,12
462	**Doğruluk oranı (%)**	76,45	81,61	87,10	88,06	89,68	92,26	92,90	92,58
30 sağ poz	**Doğruluk oranı (%)**	87,27	90,91	90,91	94,55	92,73	90,91	90,91	96,36
30 sol poz	**Doğruluk oranı (%)**	88,46	88,46	92,31	90,38	90,38	92,31	88,46	94,23
30 orta poz	**Doğruluk oranı (%)**	82,69	88,46	86,54	92,31	90,38	88,46	92,31	96,15

Epoch sayısı eğitime girecek olan ağ üzerinde ne kadar döngüde çalışacağını belirlemektedir. Veri setinin hangi sayıda daha iyi çalışacağı önemlidir. Bu yüzden epoch sayısının seçiminin belirlenmesinde yapılan denemelerde elde edilen sonuçlar baz alınmıştır. En yüksek doğruluk oranına sahip olan epoch sayıları seçilmiştir.

AlexNet mimarisi ile elde edilen sonuçlarda 120 görüntü için epoch sayısı 5 seçildiğinde %91,36, 462 görüntü için epoch sayısı 9 seçildiğinde %92,90, 30 sağ poz için epoch sayısı 10 seçildiğinde %96,36, 30 sol poz için epoch sayısı 8 seçildiğinde 92,31 ve 30 orta poz için epoch sayısı 10 seçildiğinde %96,15 ile en yüksek doğruluk oranlarına sahip olduğu gözlenmiştir. Bu mimarideki en yüksek doğruluk oranı %96,36 ile sağ pozda elde edilmiştir.

Yapılan çalışmalardaki eğitim süreleri yaklaşık olarak 462 görüntü için 11,2 dk, 120 görüntü için 2,6 dk, sağ poz için 2,4 dk, sol poz için 2 dk ve orta poz için 2,13 dk, kadar sürmüştür. Görüntü sayısı arttıkça eğitim sürelerinin uzadığı gözlenmiştir.

ResNet-18 mimarisi ile yüz tanıma yönteminde epoch sayısının belirlenebilmesi için 3–10 aralığında denemeler yapılmıştır.

Yapılan çalışmalar için elde edilen doğruluk oranları Tablo 9'daki gibi bulunmuştur.

Tablo 9. ResNet-18 ile yüz tanımada epoch sayısına göre doğruluk oranı

ResNet-18		**Epoch değeri**							
Görüntü sayısı		**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
120	**Doğruluk oranı (%)**	86,42	93,83	88,89	96,30	98,77	96,30	97,53	97,53
462	**Doğruluk oranı (%)**	91,61	72,26	81,29	88,39	92,26	92,90	98,71	95,81
30 sağ poz	**Doğruluk oranı (%)**	84,62	86,54	92,31	90,38	98,08	94,23	94,23	92,31
30 sol poz	**Doğruluk oranı (%)**	84,62	86,54	88,46	92,31	92,31	94,23	94,23	92,31
30 orta poz	**Doğruluk oranı (%)**	86,54	96,15	86,54	92,31	96,15	100	98,08	96,15

Eğitime girecek olan ağ üzerinde ne kadar döngüde çalışacağı epoch sayısı ile belirlenmektedir. Epoch sayısının seçiminin belirlenmesinde yapılan denemelerde elde edilen sonuçlar baz alınmıştır. En yüksek doğruluk oranına sahip olan epoch sayısı seçilmiştir.

ResNet-18 mimarisi ile yüz tanımada elde edilen sonuçlar 120 görüntü için epoch sayısı 7 seçildiğinde %98,77, 462 görüntü için epoch sayısı 10 seçildiğinde %95,81, 30 sağ poz için epoch sayısı 7 seçildiğinde %98,08, 30 sol poz için epoch sayısı 8 seçildiğinde %94,23 ve 30 orta poz için epoch sayısı 8 olarak seçildiğinde %100 en yüksek doğruluk oranlarına sahip olduğu görülmüştür. ResNet-18 mimarisindeki en yüksek doğruluk oranı %100 ile 30 orta pozda elde edilmiştir.

Yapılan çalışmalardaki eğitim süreleri yaklaşık olarak 462 görüntü için 12,6 dk, 120 görüntü için 2,53 dk, sağ poz için 1,86 dk, sol poz için 1,86 dk, ve orta poz için 1,86 dk kadar sürmüştür. Görüntü sayısı arttıkça eğitim sürelerinin uzadığı görülmüştür.

GoogleNet-18 mimarisi ile yüz tanıma yönteminde epoch sayısının belirlenebilmesi için 3–10 aralığında denemeler yapılmıştır. Eğitime girecek olan ağ üzerinde ne kadar döngüde çalışacağı epoch sayısı ile belirlenmektedir.

Yapılan çalışmalar için elde edilen doğruluk oranları Tablo 10'daki gibi bulunmuştur.

Tablo 10. GoogleNet ile yüz tanımada epoch sayısına göre doğruluk oranı

GoogleNet		**Epoch değeri**							
Görüntü sayısı		**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
120	**Doğruluk oranı (%)**	71,60	71,60	76,54	79,01	86,42	86,42	90,12	93,83
462	**Doğruluk oranı (%)**	69,03	76,77	75,81	86,15	87,74	86,45	90,97	89,35
30 sağ poz	**Doğruluk oranı (%)**	80,77	88,46	88,46	88,46	86,54	88,46	94,23	92,31
30 sol poz	**Doğruluk oranı (%)**	84,62	88,46	88,46	88,46	88,46	92,31	84,62	94,23
30 orta poz	**Doğruluk oranı (%)**	84,62	86,54	82,69	84,62	86,54	90,38	92,31	90,38

Epoch sayısının seçiminin belirlenmesinde yapılan denemelerde elde edilen sonuçlar baz alınmıştır. En yüksek doğruluk oranına sahip olan epoch sayısı seçilmiştir.

GoogleNet mimarisi ile yüz tanımada elde edilen sonuçlar 120 görüntü için epoch sayısı 10 seçildiğinde %93,83, 462 görüntü için epoch sayısı 9 seçildiğinde %90,97, 30 sağ poz için epoch sayısı 9 seçildiğinde %90,97, 30 sol poz için epoch sayısı 10 seçildiğinde %94,23 ve 30 orta poz için epoch sayısı 9 olarak seçildiğinde %92,31 en yüksek doğruluk oranlarına sahip olduğu görülmüştür. GoogleNet mimarisindeki en yüksek doğruluk oranı %94,23 ile 30 sol pozda elde edilmiştir.

Yapılan çalışmalarındaki eğitim süreleri yaklaşık olarak 462 görüntü için 4,6 dk, 120 görüntü için 1,46 dk, sağ poz için 1,2 dk, sol poz için 1,6 dk, ve orta poz için 1,6 dk kadar sürmüştür. Görüntü sayısı arttıkça eğitim sürelerinin uzadığı görülmüştür.

SqueezeNet mimarisi ile yüz tanıma yönteminde epoch sayısının belirlenebilmesi için 3–10 aralığında denemeler yapılmıştır. Genellikle bu mimarilerde yüksek doğruluk oranları birbirinden farklı hiper parametreler içermektedir. Bu yüzden en uygun değerin seçilmesi gerekmektedir. Yüksek çıkan sonuçlar diğer denemelerde de tekrar ediyorsa bulunan ilk epoch sayısı baz alınacaktır.

Yapılan çalışmalar için elde edilen doğruluk oranları Tablo 11'deki gibidir.

Tablo 11. SqueezeNet ile yüz tanımada epoch sayısına göre doğruluk oranı

SqueezeNet		**Epoch değeri**							
Görüntü sayısı		**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
120	**Doğruluk oranı (%)**	61,73	69,14	75,31	80,25	81,48	77,78	91,36	97,53
462	**Doğruluk oranı (%)**	63,87	75,48	79,35	82,58	88,39	88,06	90	85,16
30 sağ poz	**Doğruluk oranı (%)**	83,64	83,64	83,64	85,45	87,27	89,09	87,27	94,55
30 sol poz	**Doğruluk oranı (%)**	84,62	84,62	86,54	86,54	92,31	92,31	82,69	84,62
30 orta poz	**Doğruluk oranı (%)**	82,69	84,62	82,69	86,54	90,38	88,46	84,62	84,62

Eğitime girecek olan ağ üzerinde ne kadar döngüde çalışacağı epoch sayısı ile belirlenmiştir. Yüksek çıkan doğruluk oranının bir sonraki epoch değerinde de aynı sonucu verdiği görülmüştür. En yüksek doğruluk oranına sahip olan ilk epoch sayısı seçilmiştir.

SqueezeNet mimarisi ile yüz tanımada elde edilen sonuçlar 120 görüntü için epoch sayısı 10 seçildiğinde %97,53, 462 görüntü için epoch sayısı 9 seçildiğinde %90, 30 sağ poz için epoch sayısı 10 seçildiğinde %94,55, 30 sol poz için epoch sayısı 7 seçildiğinde %92,31 ve 30 orta poz için epoch sayısı 7 olarak seçildiğinde %90,38 en yüksek doğruluk oranlarına sahip olduğu görülmüştür. SqueezeNet mimarisindeki en yüksek doğruluk oranı %97,53 ile 120 görüntü sayısında elde edilmiştir.

Yapılan çalışmalardaki eğitim süreleri yaklaşık olarak 462 görüntü için 5,6 dk, 120 görüntü için 1,33 dk, sağ poz için 1,2 dk, sol poz için 1,6 dk, ve orta poz için 1,6 dk kadar sürmüştür. Görüntü sayısı arttıkça eğitim sürelerinin uzadığı görülmüştür.

Özyüzler yöntemi kullanılarak sağ poz için yedi dakika, sol poz için yedi dakika ve orta poz için yedi dakika olmak üzere veri seti eğitimi tamamlamıştır. Fisherfaces yöntemi içinde toplam 21 dakika sürmüştür. Derin öğrenme tekniği için bu süreler toplamda yaklaşık olarak AlexNet 20,4 dakikada, ResNet-18 için 20,8 dakikada, GoogleNet için 9,46 dakika ve SqueezeNet için 10,2 dakikada veri seti eğitimini tamamlamıştır.

7. SONUÇLAR

Bu tez çalışmasında, görüntü işleme çalışmalarında yüz bulma için yaygın olarak kullanılan Viola-Jones algoritması kullanılmıştır. Yüz tanıma sistemlerinden Özyüzler ve Fisherfaces algoritmaları üzerinde durulmuştur. Derin öğrenme mimarilerinin yapısı, özellikleri ve en çok tercih edilen yöntemlerden bahsedilmiştir. Genel hatları ile yüz bulma, yüz tanıma aşamaları ve kullanılan yöntemlerin açıklamaları verilmiştir.

Yüz tanımanın yapılabilmesi için öncelikle yüz bulma adımı gerçekleştirilir. Viola-Jones ile yüz bulma adımını geçen yüz resimleri veri tabanını oluşturmaktadır.

Tez kapsamında, görüntü tabanlı yöntemler ve derin öğrenme yöntemleri kullanılarak yüz tanıma algoritması eğitilmiş olup bu iki yöntemin doğruluk oranları karşılaştırılmıştır. İlk olarak, görüntü tabanlı yöntemlerden Özyüzler algoritması ile yüz resimlerinin sağdan, soldan ve karşıdan olmak üzere üç farklı poz varyasyonları incelenmiştir. Karşıdan çekilen pozlarda yüz tanınma oranının arttığı gözlenmiştir.

İkinci kısımda, Fisherfaces algoritması ile yüz resimlerinin sağdan, soldan ve karşıdan olmak üzere üç farklı poz varyasyonları incelendiğinde ise karşıdan çekilen pozların yüz tanıma oranı en iyi sonuçları vermiştir. Her iki algoritma kendi aralarında incelendiğinde Özyüzler algoritması Fisherfaces algoritmasına göre daha yüksek doğruluk oranı elde etmiştir.

Derin öğrenme yöntemlerinden AlexNet, Resnet-18, GoogleNet ve SqueezeNet mimarileri ile yüz tanıma incelenmiştir. Resimler sağdan, soldan, karşıdan ve tümü olmak üzere dört grupta incelenmiştir. Epoch sayılarının belirlenmesinde doğruluk oranı yüksek olan değer seçilmiştir. Derin öğrenme mimarileri ile yapılan çalışmalar incelendiğinde, ResNet-18, SqueezeNet, AlexNet ve GoogleNet mimarilerinin iyi sonuçlar verdiği gözlenmiştir. Bu algoritmalar kendi aralarında kıyaslandığında ResNet-18 mimarisinin diğer mimarilerden daha yüksek doğruluk oranlarına sahip olduğu görülmüştür.

Bu iki yöntem birbiri ile kıyaslandığında en yüksek doğruluk oranına sahip yöntemler derin öğrenme ile yüz tanıma yöntemleri olarak bulunmuştur. Görüntü işleme tabanlı yöntemler ile yüz tanımada resimler siyah beyaza çevrilmiştir. Yüz tanıma için Viola-

Jones algoritması ile kutucuk içerisine alınmış ve kesilmiştir. Oluşturulan yeni resimlerin boyutları düzenlendikten sonra eğitim ve test klasörü olarak iki ayrı klasöre aktarılmıştır. Daha sonra vektörel işlemlerle iki resmin öklid mesafe uzaklığı ile karşılaştırılarak yüz tanınma sisteminde sonuçlar vermiştir. Görüntü işleme tabanlı yöntemler daha uzun sürede sonuçlar vermekte ve daha az başarım oranına sahip olduğu görülmektedir. Özyüzler ve Fisherfaces yöntemleri için poz varyasyonları, ışık miktarı gibi özellikler büyük oranda yüz tanımayı etkilemektedir.

Derin öğrenme ile yüz tanıma yöntemlerinde resimler mimarinin özelliğine göre boyutlandırılmış olup siyah beyaza çevrilmeden işleme girmiştir. Yüz tanıma için Viola-Jones algoritması ile kutucuk içerisine alınmış ve kesilmiştir. Burada bütün orijinal resimler ayrı bir klasörde tutulmuştur. Her bir mimarinin kendine ait katmanları mevcuttur. Bu yüzden işlemler çok kısa sürmüştür ve daha yüksek doğruluk oranları elde edilmiştir. Derin öğrenme mimarileri ile yüz tanıma için yapılan işlemler görüntü işleme tabanlı yüz tanıma ile yapılan işlemlerden daha kısa sürede sonuçlar vermiştir.

Sonuç olarak bu tez kapsamında derin öğrenme mimarilerinin görüntü işleme tabanlı yöntemlerden daha iyi olduğu gözlenmiştir. En muazzam sonuç ise ResNet-18 mimarisine aittir. Günümüzde oldukça popüler olan bu yöntemlerin ileride daha iyi sonuçlar vereceği düşünülmektedir.

KAYNAKLAR

Aksoy B., Halis H. D., & Salman O. K. M., Elma Bitkisindeki Hastalıkların Yapay Zekâ Yöntemleri ile Tespiti ve Yapay Zekâ Yöntemlerinin Performanslarının Karşılaştırılması, International Journal of Engineering and Innovative Research, 2(3), 200,2020.

Ayyüce Kızrak M., & Bolat Bülent (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11 (3), 263-286.

Belhumeur P.N., Hespanha J.P. & Kriegman D.J., Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, IEEE Transaction on Pattern Analysis and Machine Intelligence, 19(7), 711-719,1997.

Britz D. (2015, 7 Kasım). Understanding Convolutional Neural Networks for NLP [Blog yazısı]. Erişim adresi: http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp/

Çınar U. K., (2021, 24 Mayıs). cv2 ile Yüz Tanıma ve Belirleme [Blog yazısı]. Erişim adresi: https://www.miuul.com/not-defteri/icerik/cv2

Doğan F., & Türkoğlu İ., Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, Sakarya University Journal of Computer and Information Sciences, *SAUCIS-1*, 15-17,2018.

Doğan F., & Türkoğlu İ., Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme, DÜMF Mühendislik Dergisi, 10(2), 416-419,2019.

Erdoğan A. Y., (2010). *Yüz Tanımada Özyüz ve Fisher Yüz Algoritmalarının İncelenmesi*, Yüksek Lisans tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.

FEI Face Database, (2012). Erişim adresi: https://fei.edu.br/~cet/facedatabase.html Erişim tarihi: 14 Mart 2021.

Holat R. & Kulaç S., (2014). *Yüz Bulma ve Tanıma Sistemleri Kullanarak Kimlik Tespitinin Yapılması*, Yüksek Lisans tezi, Düzce Üniversitesi, Fen Bilimleri Enstitüsü, Düzce.

Iandola F. N., Han S., Moskewicz M. W., Ashraf K., Dally W. J., & Keutzer K., SqueezeNet: AlexNet-Level Accuracy with 50x Fewer Parameters and <1MB Model Size, ArXiv, 5,2016.

Jones M., Viola P., Fast Multi-view Face Detection, Mitsubishi Electric Research Laboratories, TR-20003-96,2003.

Kaplan A., (2018). *Gerçek ve Yarı Gerçek Zamanlı Yüz Tespit Etme,* Yüksek Lisans tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elâzığ.

Kekül H., Bircan H. & Arslan H., Yüz Tanıma Uygulamalarında Özyüzler ve Yapay Sinir Ağlarının Karşılaştırılması, Uluslarası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi, 2(1), 51-59,2018.

Krizhevsky A., Sutskever I., & Hinton G. E., (2012). ImageNet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, 25(2),1097-1105.

Lal M., & Kumar K., (2018). Study of Face Recognition Techniques: A Survey, International Journey of Advanced Computer Science and Applications, 9, 42-43, Erişim adresi: https://webcache.googleusercontent.com/search?q=cache:_eyq7UDhFZAJ:https://thesai.org/Downloads/Volume9No6/Paper_6-Study_of_Face_Recognition_Techniques.pdf+&cd=3&hl=tr&ct=clnk&gl=tr

Lan Q. & Zhiyong X., Adaboost multi-view face detection based on YCgCr skin color model, 8th International Symposium on Advanced Optical Manufacturing and Testing Technologies: Optical Test, Measurement Technology, and Equipment, 96842D, 598-602,2016.

Lucena O., Oliveira İ.D.P., Veloso L. & Pereira E., Improving Face Detection Performance by Skin Detection Post-Processing, 2017 30th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI), 300-307,2017.

Mamak U., Konyar M. Z., Solak S., & Uçar M. H. B., (2020). Gerçek Yüz Tanıma Tabanlı Personel Kontrol ve Takip Sistemi Tasarımı, Avrupa Bilim ve Teknoloji Dergisi, 19, 498. doi: 10.31590/ejosat.727768

Omert, (2020, 8 Ocak). Viola Jones Algoritması ile Yüz Tespiti [Türkçe] [Blog yazısı]. Erişim adresi: https://medium.com/patron-ai/viola-jones-algoritmas%C4%B1-ile-y%C3%BCz-tespiti-t%C3%BCrk%C3%A7e-38ea73c910e3

Q. Li, U. Niaz & B. Merialdo, An improved algorithm on Viola-Jones object detector, in Content-Based Multimedia Indexing (CBMI), IEEE, 1-6, Annecy, France, Haziran 2012.

Raghu S., Sriraam N., Temel Y., Rao S. V., & Kubben P. L., *EEG based multi-class seizure type classification using convolutional neural network and transfer learning*, *Neural Networks*, 206,2020.

Rondahl T., (2011). *Face Detection in Digital Imagery Using Computer Vision and Image Processing*, Bachelor's Thesis in Computing Science, Umeå University, Department of Computing Science, Sweden.

Sert Z., (2020, 27 Aralık). ESA (Evrişimsel Sinir Ağları) [Blog yazısı]. Erişim adresi: https://zeysert.medium.com/esa-evri%C5%9Fimsel-sinir-a%C4%9Flar%C4%B1-87d9bd986579

Sirovich L., & Kirby M., (1987). Low-dimensional procedure for the characterization of human faces, *Journal of the Optical Society of America A, Optics and image sicence*, 4(3), 519-524.

Suma S. L., & Raga S., (2018). Real Time Face Recognition of Human Faces by using LBPH and Viola Jones Algorithm, International Journal of Scientific Research in Computer Science and Engineering, 6(5), 6-10. Erişim adresi: https://www.isroset.org/pdf_paper_view.php?paper_id=852&2-IJSRCSE-01348.pdf

Sütçüler E., (2006). *Gerçek Zamanlı Video Görüntülerinden Yüz Bulma ve Tanıma Sistemi*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

Szegedy C., Liu W., Jia Y., Sermanent P., Reed S., Anguelov D., Erhan D., Vanhoucke V. & Rabinovich A., (2015). Going deeper with convolutions, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, içinde (ss 1-9). Boston, Amerika.

Tetik Y. E., & Bolat B., *Gürültülü Ortamarda Konuşma Tespiti İçin Yeni Bir Öznitelik Çıkarım Yöntemi*, Elektrik-Elektronik ve Bilgisayar Sempozyumu, Fırat Üniversitesi, Elâzığ, 87, 2011.

Thomaz C. E., (2012). *FEI face database*, Erişim adresi: https://fei.edu.br/~cet/facedatabase.html Erişim tarihi: 14 Mart 2021.

Topkaya İ. S., (2008). *Video Görüntülerinden Yüz Tanıma*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

Turk M.A. and A.P. Pentland, Eigenfaces for Recognition, Journal of Cognitive Neuroscience, 3(1), 71-86,1991.

Wang Y.Q., An Analysis of the Viola-Jones Face Detection Algorithm, Image Processing On Line, 4, 128-148,2014.

Yang M. H., Kriegman D. J., & Ahuja N., Detecting Faces in Images: A Survey, IEEE Transaction on Pattern Analysis and Machine Intelligence, 24(1), 34-36,2002.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Ayşe Merve BÜYÜKBAŞ

EĞİTİM DURUMU

Ön Lisans Öğrenimi : 2010, Süleyman Demirel Üniversitesi, Teknik Bilimler Meslek Yüksek Okulu, Endüstriyel Elektronik

Lisans Öğrenimi : 2017, KTO Karatay Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği

Yüksek Lisans Öğrenimi : 2021 KTO Karatay Üniversitesi, Elektrik ve Bilgisayar Anabilim Dalı, Elektrik ve Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

Bildiği Yabancı Diller : İngilizce, İspanyolca.

İŞ DENEYİMİ

Stajlar : 2010, Stajyer, SDÜ Araştırma ve Uygulama Hastanesi

2015-2016, Stajyer, Çağrı Elektrik Proje Taah. San. Tic. A.Ş.

Çalıştığı Kurumlar : Temmuz 2020-Ekim 2020, Elektrik Mühendisi, Proted Enerji Elektrik San. Tic. Ltd. Şti.

Tarih: 7 Eylül 2021