



**T.C.  
BATMAN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**DERİN ÖĞRENME METOTLARI İLE YÜZ GÖRÜNTÜLERİNDEN  
YAŞ TESPİTİ**

**Emrah ALTUNER**

**Ocak-2025  
BATMAN**

**T.C.  
BATMAN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**DERİN ÖĞRENME METOTLARI İLE YÜZ GÖRÜNTÜLERİNDEN  
YAŞ TESPİTİ**

**Emrah ALTUNER**

**Danışman  
Doç. Dr. Yılmaz KAYA**

**Diğer Jüri Yeleri**

**Prof. Dr. Necmettin SEZGİN      Doç. Dr. Melih KUNCAN**

**Ocak-2025  
BATMAN**

## TEZ KABUL VE ONAYI

Emrah ALTUNER tarafından hazırlanan “Derin öğrenme metotları ile yüz görüntülerinden yaş tespiti” adlı tez çalışması 02/01/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgi Teknolojileri Ana Bilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. Necmettin SEZGİN

.....

#### Danışman

Doç. Dr. Yılmaz KAYA

.....

#### Üye

Doç. Dr. Melih KUNCAN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER  
Lisansüstü Eğitim Enstitüsü Müdürü

## **ETİK BEYANI**

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

## **ETHICAL DECLARATION**

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

İmza  
Emrah ALTUNER  
Tarih: 02.01.2025

## ÖZET

### YÜKSEK LİSANS TEZİ

## DERİN ÖĞRENME METOTLARI İLE YÜZ GÖRÜNTÜLERİNDEN YAŞ TESPİTİ

**Emrah ALTUNER**

**Batman Üniversitesi Lisansüstü Eğitim Enstitüsü**

**Bilgi Teknolojileri Ana Bilim Dalı**

**Danışman: Doç. Dr. Yılmaz KAYA**

**2025, 55 Sayfa**

Bu çalışmada, yüz görüntülerinden yaş tahmini gerçekleştirilmiş ve Hint Sineması Yüz Veri tabanı (IMFDB) üzerinde DenseNet modelleri kullanılmıştır. Yaş tespiti, güvenlik, sağlık ve pazarlama gibi çeşitli sektörlerde kritik bir öneme sahiptir. DenseNet mimarilerinin farklı versiyonları olan DenseNet-121, DenseNet-169, DenseNet-201 ve DenseNet-264, yaş tahmini için eğitilmiş ve doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru gibi performans metrikleri üzerinden değerlendirilmiştir. Veri seti, 19.906 yüz görüntüsünden oluşmakta olup yaş kategorileriyle etiketlenmiştir.

DenseNet-264 modeli, %89.8 doğruluk, 0.90 precision, 0.90 recall ve 0.90 F1 skoru ile en yüksek performansı göstermiştir. DenseNet-201 modeli, %89.2 doğruluk oranıyla iyi bir performans sergilemiş, DenseNet-169 modeli %87.1 doğruluk ve dengeli bir genelleme kapasitesi sunmuştur. DenseNet-121 modeli ise %85.3 doğruluk oranıyla daha hızlı ve düşük hesaplama maliyetine sahip bir seçenek olmuştur. ROC analizleri, tüm modellerin güçlü bir ayırım yeteneğine sahip olduğunu göstermiş, ancak en derin model olan DenseNet-264'te sınırlı genelleme kayıpları gözlemlenmiştir.

Sonuç olarak, DenseNet mimarileri yaş tahmini için etkili bir çözüm sunmuştur. Model seçimi, uygulamanın gereksinimlerine ve kaynaklarına bağlı olarak yapılabilir. DenseNet-264 en yüksek doğruluğu sağlarken, DenseNet-121 daha hızlı sonuçlar elde etmek için uygun bir alternatif olarak değerlendirilebilir.

**Anahtar Kelimeler:** Yaş Tahmini, Transfer Öğrenme, Derin Öğrenme, DenseNet Mimariler

**ABSTRACT**  
**MASTER THESIS**  
**AGE ESTIMATION FROM FACIAL IMAGES USING DEEP LEARNING**  
**METHODS**

**Emrah ALTUNER**

**Batman University Graduate Education Institute**

**Information Technologies Department of Science**

**Advisor: Assoc. Prof. Yılmaz KAYA**

**2024, 55 Pages**

This study focused on predicting age from facial images using DenseNet architectures and analyzed the Indian Movie Face Database (IMFDB). Age estimation is vital in sectors like security, healthcare, and marketing. Different DenseNet architectures, including DenseNet-121, DenseNet-169, DenseNet-201, and DenseNet-264, were trained and evaluated based on metrics such as accuracy, precision, recall, and F1 score. The dataset consisted of 19,906 facial images labeled with age categories.

DenseNet-264 achieved the highest performance with 89.8% accuracy, 0.90 precision, 0.90 recall, and 0.90 F1 score. DenseNet-201 followed with 89.2% accuracy, while DenseNet-169 demonstrated a balanced generalization with 87.1% accuracy. DenseNet-121 provided a faster and computationally efficient alternative with 85.3% accuracy. ROC analysis revealed strong classification capabilities across all models, with minor generalization losses observed in the deepest model, DenseNet-264.

In conclusion, DenseNet architectures proved to be effective solutions for age prediction. Model selection can be tailored to the application's requirements and resources. While DenseNet-264 offered the highest accuracy, DenseNet-121 served as a faster alternative with lower computational costs.

**Keywords:** Age Estimation, Transfer Learning, Deep Learning, DenseNet Architectures

## ÖN SÖZ

Tez çalışmam boyunca bana sürekli rehberlik eden, bilgi birikimini ve desteğini esirgemeyen, takılmış olduğum her soruya verdiği kıymetli cevaplarıyla yolumu aydınlatan, danışman hocam Doç. Dr. Yılmaz KAYA'ya derin şükranlarımı sunarım.

Bu süreçte her zaman sabırla yanımda olan, manevi desteklerini hiçbir zaman eksik etmeyen, sevgili eşim Nurcan YILMAZ ALTUNER ve oğlum Mert Aren'e ayrıca teşekkür ederim.

Emrah ALTUNER  
BATMAN-2025

## İÇİNDEKİLER

|                                                                            |      |
|----------------------------------------------------------------------------|------|
| ÖZET .....                                                                 | iv   |
| ABSTRACT.....                                                              | v    |
| ÖN SÖZ .....                                                               | vi   |
| İÇİNDEKİLER.....                                                           | vii  |
| ÇİZELGELER/TABLolar LİSTESİ.....                                           | viii |
| ŞEKİLLER LİSTESİ .....                                                     | ix   |
| SİMGELER VE KISALTMALAR.....                                               | x    |
| 1. GİRİŞ .....                                                             | 1    |
| 2. LİTERATÜR ÇALIŞMALARI.....                                              | 8    |
| 3. MATERYAL VE METOT.....                                                  | 17   |
| 3.1. Materyal.....                                                         | 17   |
| 3.2. Metot.....                                                            | 18   |
| 3.2.1. Derin öğrenme .....                                                 | 18   |
| 3.2.2. Transfer derin öğrenme yaklaşımı .....                              | 20   |
| 3.2.3. DenseNet mimarileri.....                                            | 21   |
| 3.2.4. DenseNet121 mimarisi .....                                          | 22   |
| 3.2.5. DenseNet169 mimarisi .....                                          | 24   |
| 3.2.6. DenseNet201 mimarisi .....                                          | 26   |
| 3.2.7. DenseNet264 mimarisi .....                                          | 28   |
| 3.2.8. Evrişimsel sinir ağları (Convolutional Neural Networks - CNN) ..... | 30   |
| 3.2.9. CNN katman mimarisi .....                                           | 32   |
| 3.2.9.1. Evrişim katmanı (Convolution Layer).....                          | 32   |
| 3.2.9.2. Aktivasyon katmanı .....                                          | 33   |
| 3.2.9.3. Havuzlama katmanı (Pooling Layer).....                            | 33   |
| 3.2.9.4. Tam bağlantılı katman (Fully Connected Layer).....                | 34   |
| 3.2.10. Performans ölçütleri.....                                          | 35   |
| 4. BULGULAR.....                                                           | 37   |
| 5. SONUÇLAR VE ÖNERİLER.....                                               | 49   |
| 5.1 Sonuçlar .....                                                         | 49   |
| 5.2 Öneriler .....                                                         | 50   |
| KAYNAKLAR .....                                                            | 52   |

## ÇİZELGELER/TABLolar LİSTESİ

|                                                                 |    |
|-----------------------------------------------------------------|----|
| <b>Tablo 4.1.</b> DenseNet Modelleri performans değerleri ..... | 38 |
|-----------------------------------------------------------------|----|

## ŞEKİLLER LİSTESİ

|                                                                                                                                                   |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 3.1.</b> Veri setindeki Örnek Görüntüler .....                                                                                           | 18 |
| <b>Şekil 3.2.</b> DenseNet121 Mimarisi Tareq vd. (2022).....                                                                                      | 24 |
| <b>Şekil 3.3.</b> DenseNet169 Mimarisi Abdalla vd. (2022) .....                                                                                   | 26 |
| <b>Şekil 3.4.</b> DenseNet201 Mimarisi Akhtar vd. (2022).....                                                                                     | 27 |
| <b>Şekil 3.4.</b> DenseNet264 Mimarisi Narmatha (2023) .....                                                                                      | 30 |
| <b>Şekil 4.1.</b> DenseNet modeller kayıp ve başarı grafikleri. (A) DenseNet121, (B) DenseNet169, (C) DenseNet201, (D) DenseNet264 modeller ..... | 41 |
| <b>Şekil 4.2.</b> DenseNet modeller karışıklık matrisleri. (A) DenseNet121, (B) DenseNet169, (C) DenseNet201, (D) DenseNet264 modeller .....      | 44 |
| <b>Şekil 4.3.</b> DenseNet modellere ait ROC eğrileri. (A) DenseNet121, (B) DenseNet169, (C) DenseNet201, (D) DenseNet264 modeller .....          | 46 |

## SİMGELER VE KISALTMALAR

### Simgeler

|                       |                                                           |
|-----------------------|-----------------------------------------------------------|
| $X[i, j]:$            | Giriş görüntüsündeki piksel değeri                        |
| $K[m, n]: k \times k$ | $k \times k$ Boyutundaki çekirdek (kernel) matrisi        |
| $Y[i, j]:$            | Çıkış özellik haritasındaki değer                         |
| $b:$                  | Biaslık (bias)                                            |
| $k:$                  | Çekirdek boyutu (örneğin $3 \times 3$ veya $5 \times 5$ ) |
| $W \times H :$        | Giriş görüntüsü boyutu,                                   |
| $k :$                 | Çekirdek boyutu                                           |
| $s:$                  | Adım sayısı                                               |
| $p:$                  | Sıfır dolgusu                                             |
| $x:$                  | Giriş Vektörü                                             |
| $W:$                  | Ağırlık Matrisi                                           |
| $b:$                  | Biaslık (bias) terimi                                     |
| $f:$                  | Aktivasyon fonksiyonu                                     |
| $z_i:$                | $i$ -inci sınıfa ait skor                                 |
| $P(y_i):$             | $i$ - inci sınıfa ait olasılık                            |
| TP:                   | Doğru Pozitif (True Positive)                             |
| TN:                   | Doğru Negatif (True Negative)                             |
| FP:                   | Yanlış Pozitif (False Positive)                           |
| FN:                   | Yanlış Negatif (False Negative)                           |

### Kısaltmalar

### Açıklama

|          |                                                           |
|----------|-----------------------------------------------------------|
| CNN      | Convolutional Neural Networks, Evrişimli Sinir Ağları     |
| RNN      | Tekrarlayan sinir ağları                                  |
| NLP      | Natural Language Processing; Doğal Dil İşleme             |
| VGG-16   | Visual Geometry Group, Görsel Geometri Grubu              |
| DenseNet | Dense Convolutional Network                               |
| YZ       | Yapay Zeka                                                |
| ResNet   | Residual Network, Artık Bağlantılı Ağ                     |
| IMFDB    | Indian Movie Face Database                                |
| GPU      | Graphics Processing Unit, Grafik İşleme Birimi            |
| TPU      | Tensor Processing Unit, Tensör İşleme Birimi              |
| MRI      | manyetik rezonans görüntüleme; Magnetic Resonance Imaging |
| CT       | Computed Tomography; Bilgisayarlı Tomografi               |
| ReLU     | Rectified Linear Unit; Doğrultulmuş Lineer Birim          |
| TPR      | True Positive Rate; Doğru Pozitif Oranı                   |

|          |                                                                 |
|----------|-----------------------------------------------------------------|
| ROC      | Receiver Operating Characteristic; Alıcı İşletim Karakteristiği |
| AUC      | Area Under the Curve, Eğri Altındaki Alan                       |
| SGD      | Stochastic Gradient Descent, Stokastik Gradyan İnişi            |
| RMSPProp | Root Mean Square Propagation, Kök Ortalamalı Yayılma            |
| SGD      | Stochastic Gradient Descent                                     |
| DRF      | Dynamic Random Forest, Rastgele Ormanlara                       |
| MWPCA    | Çok Doğrusal Beyazlatılmış Temel Bileşenler Analizi             |
| TEDA     | Tensor Üstel Ayırt Edici Analiz                                 |
| DDIL     | Derin Alanlar-Arası Öğrenme                                     |
| OOD      | Dağılım Dışı                                                    |
| HCI      | İnsan-Bilgisayar Etkileşiminin                                  |
| MAE      | Ortalama Mutlak Hata                                            |
| PAD      | Panda Yaş Veri Seti                                             |
| LBP      | Yerel İkili Desenler                                            |
| LPP      | Yerel Koruma Projeksiyonu                                       |
| MFA      | Marjinal Fisher Analizi ()                                      |
| KNN-SVR  | K-en Yakın Komşular Destek Vektör Regresyonu                    |
| IFDB     | İran Yüz Veritabanı                                             |
| JREAE    | Birleşik İlişki Keşif ve Yaş Tahmin Modeli                      |
| MIMO     | Çoklu Giriş ve Çoklu Çıkış                                      |

## 1. GİRİŞ

Yüz tanıma teknolojileri, son yıllarda hızla gelişmiş ve çok çeşitli alanlarda kullanılmaya başlanmıştır. Özellikle biyometrik tanımlama, güvenlik, sağlık, eğlence ve daha birçok sektörde önemli bir yer edinmiştir. Bu teknolojilerin gelişmesiyle birlikte, yüz görüntülerinden yaş tespiti gibi daha spesifik ve karmaşık uygulamalar da araştırılmakta ve geliştirilmektedir. Yüz görüntülerinden yaş tespiti, yüz tanıma teknolojisinin bir alt başlığı olarak karşımıza çıkmakta olup, insan yüzlerinin yaşa bağlı özelliklerinden yararlanarak bireylerin yaşlarını tahmin etmeyi amaçlamaktadır. Yaş tespiti, biyometrik bir analiz aracılığıyla bir bireyin yaşının belirlenmesi işlemidir. Yüz görüntülerinden yaş tespiti, insan yüzündeki yaşa bağlı değişimlerin incelenerek kişinin yaşının tahmin edilmesidir. Yüzdeki yaşa bağlı özellikler, deri altı yapı, cilt elastikiyeti, kırışıklıklar, göz çevresi, dudak yapısı, yüz hatlarının belirginliği gibi faktörlerden kaynaklanır. Yaş ilerledikçe bu özelliklerde değişiklikler meydana gelir ve bu değişiklikler, yüz tanıma sistemleri tarafından analiz edilerek yaş tahmini yapılabilir. Yüz görüntülerinden yaş tespiti, diğer biyometrik ölçümlerle (parmak izi, iris tanıma vb.) karşılaştırıldığında, daha az invaziv ve kullanıcı dostu bir yöntem olarak öne çıkmaktadır.

İnsan yüzü, yaşın görsel olarak en belirgin şekilde ifade edildiği ve analiz edildiği alanlardan biridir. Yıllar içinde yüz hatlarında meydana gelen değişiklikler, yaşlanma sürecinin doğal bir yansıması olarak karşımıza çıkar. Ancak bu süreç, bireyler arasında genetik, çevresel faktörler ve yaşam tarzına bağlı olarak büyük farklılıklar gösterebilir Huerta vd. (2015). Yaş tahminini daha da karmaşık hale getiren bu çeşitlilik, aynı yaş grubundaki bireylerin görünüşlerinin büyük ölçüde farklılık göstermesi, yüz aksesuarları ve makyaj gibi unsurların algılanan yaşı değiştirmesi gibi faktörlerle birleşir Li vd. (2016). Bu tür zorluklar, geleneksel yöntemlerle yaş tahmini yapmayı oldukça zorlaştırmakta ve insan yüzündeki bu eşsiz çeşitliliği anlamlandırabilmek için daha gelişmiş yaklaşımlara duyulan ihtiyacı ortaya koymaktadır. Özellikle, farklı ışık koşulları, yüz ifadeleri ve etnik farklılıklar gibi unsurlar, geleneksel yaş tahmini yöntemlerinin doğruluğunu daha da sınırlamaktadır Han vd. (2013). Bu sınırlamalar, yapay zeka tabanlı yaş tahmini çalışmalarının önemini artırmakta ve insan yüzündeki bu eşsiz çeşitliliği doğru bir şekilde anlamlandırabilecek modeller geliştirme ihtiyacını ortaya koymaktadır

Yaş tahmini, çeşitli alanlarda büyük öneme sahiptir. Örneğin, güvenlik ve erişim kontrolü sistemlerinde, yalnızca belirli bir yaş grubuna izin verilen içerik veya alanlara erişimi sınırlamak için kullanılabilir. Pazarlama ve reklamcılık alanında, yaş tahmini teknolojileri, hedef kitlenin demografik özelliklerine göre kişiselleştirilmiş kampanyalar oluşturulmasına yardımcı olabilir. Pazarlama ve reklamcılık sektöründe, yaş tespiti teknolojisi daha hedeflenmiş, kişiselleştirilmiş reklamcılık stratejilerinin geliştirilmesine olanak tanımaktadır. Yaş, kullanıcıların tüketim alışkanlıkları, ilgi alanları ve ürün tercihleriyle doğrudan ilişkili olduğu için, yaşa göre özelleştirilmiş içerikler sunmak, reklamcılığın etkinliğini artırmaktadır. Reklam verenler, yaş tespitiyle elde edilen verilerle daha doğru hedefleme yaparak, tüketici davranışlarını daha etkili bir şekilde anlayabilir ve kişiselleştirilmiş deneyimler sunabilirler. Bu bağlamda, yaş tespiti yalnızca yaş sınırlı ürünlerin pazarlanmasında değil, aynı zamanda markaların müşteri deneyimini geliştirmelerinde de önemli bir araçtır.

Bir diğer önemli kullanım alanı ise sağlık sektörüdür. Yaş tespiti, yaşa bağlı hastalıkların erken teşhisinde, kişisel sağlık takibinde, yaşa uygun tedavi planlarının belirlenmesinde etkili olabilir. Sağlık alanında ise yaş tespiti, bireylerin yaşa bağlı sağlık sorunlarını izlemek ve kişisel sağlık takibini yapmak için kullanışlı bir teknoloji sunmaktadır. İnsan yüzündeki yaşa bağlı değişiklikler, genellikle yaşla ilgili sağlık koşullarının erken belirtileri olabileceği için, yaş tespiti sistemleri, bu tür sağlık durumlarının izlenmesinde faydalı olabilir. Örneğin, yaşla birlikte ciltteki elastikiyet kaybı ve kırışıklıkların artması, yaşa bağlı hastalıkların (örneğin, kardiyovasküler hastalıklar, diyabet vb.) erken belirtisi olabilir. Bu tür sağlık verileri, kişisel sağlık planlarının oluşturulmasında veya erken teşhis süreçlerinde önemli bir rol oynayabilir. Ayrıca, yaş tespiti teknolojisi, adli bilimlerde de kullanılmaktadır. Özellikle kayıp kişilerin bulunmasında ve adli davalarda yaş belirleme konusunda, doğru yaş tahmini yapmak, hukuki süreçlerin doğru işlemesi açısından kritik bir öneme sahiptir.

Ayrıca, sosyal medya platformlarında yaş doğrulama ve çocukların çevrimiçi güvenliğini sağlama gibi etik gereklilikleri yerine getirmek için de yaygın bir şekilde değerlendirilmektedir. Yaş tahmini, aynı zamanda insan-bilgisayar etkileşiminde daha sezgisel ve bireye özel deneyimler sunmak için kullanılacak güçlü bir araçtır Al-Shannaq ve Elrefaei (2019). Yaş tespiti teknolojisinin bir diğer önemli avantajı, genellikle kişisel verilerin toplanmasında diğer biyometrik verilere göre daha az hassas olmasıdır. Bu da, verilerin gizliliği konusunda daha az endişe yaratır ve kullanıcılar tarafından daha yaygın şekilde kabul edilmesini sağlar.

Yaş tespiti, göçmenlik, adli süreçler ve sosyal hizmetler gibi alanlarda ciddi uygulama sorunlarına neden olmaktadır. Özellikle kitlesel göç hareketlerinde, kimlik belgelerinin kaybı, eksikliği veya kasıtlı yanlış beyanlar, bireylerin yaşlarının doğru bir şekilde belirlenmesini zorlaştırmaktadır. Bu durum, çocuk koruma sistemlerine erişimden sorumlu tutulma ve barınma koşullarına kadar birçok kritik hizmetin yanlış bir şekilde sunulmasına yol açabilir. Adli tıpta ise yaş tespiti, suç işleyen bireylerin cezai ehliyetlerinin belirlenmesinde önemli bir rol oynar. Yanlış yaş tahminleri, reşit olmayan bireylerin yetişkin mahkemelerinde yargılanmasına ya da cezai sorumluluğu olmayan bireylerin hukuki yaptırımlara maruz kalmasına neden olabilir. Benzer şekilde, spor müsabakalarında yaş sınırlamalarının ihlali veya yaş hileciliği, rekabetin adil olmasını engelleyebilir. Bu tür vakalar, yaş tespitinin doğru ve güvenilir yöntemlerle yapılmasının hem bireysel haklar hem de sistematik işleyiş açısından vazgeçilmez olduğunu ortaya koymaktadır.

Son yıllarda, yaş tahmini birçok uygulama için kritik bir gereklilik haline gelmiştir. Yaşa dayalı analizler, özellikle hizmetlerin müşteri yaşına göre şekillendiği erişim kontrol sistemlerinde büyük önem taşımaktadır. Örneğin, Japonya'da bütün otomatları, 20 yaşın altındaki bireylerin sigara satın almasını engellemek amacıyla yaş tahmini teknolojisi kullanmaktadır Angulu vd. (2018). Yaşa dayalı bilgisayar etkileşim sistemleri, güvenlik uygulamalarında da önemli bir rol oynamaktadır. Örneğin, bir çocuğun araçta yalnız bırakıldığında alarm sistemiyle fark edilmesini sağlayabilir veya eğlence parklarında güvenli yaş sınırının altındaki çocukların tehlikeli oyunlara erişimini engelleyebilir. Ayrıca, yaş kontrolü yaparak reşit olmayan bireylerin alkol tüketimini önlemekte de kullanılabilir. Sağlık sistemlerinde ise robotik hemşireler, acil müdahalelerde yaş analizi yaparak daha etkili hizmet sunabilir. Tüm bu örnekler, yaş tahmini teknolojisinin farklı sektörlerde sunduğu geniş uygulama yelpazesini göstermektedir Badr vd. (2019).

Yüz görüntülerinden yaş tespiti yapmak için kullanılan veriler, genellikle dijital fotoğraflar veya videolar şeklinde alınan yüz görüntüleridir. Bu görüntülerde, kişinin yüz hatları, cilt yapısı ve diğer biyometrik özellikler analiz edilir. Günümüzde, yapay zeka (YZ) ve derin öğrenme teknikleri, yaş tespiti sürecinde önemli bir rol oynamaktadır.

Derin öğrenme algoritmaları, özellikle konvolüsyonel sinir ağları (CNN) gibi derin öğrenme modelleri, yüz görüntülerindeki yaşa dayalı özellikleri öğrenebilmekte ve bu özelliklere dayanarak bir yaş tahmini yapabilmektedir. Yüzdeki kırışıklıklar, cilt

tonu deęişiklikleri, göz çevresi ve dudak yapısı gibi yaşa özgü görsel özelliklerin çıkarılması, bu tür bir analizde en önemli adımlardır. Bunun yanı sıra, yüz tanıma yazılımları, farklı yaş gruplarına ait geniş veri setleri üzerinde eğitilerek daha yüksek doğruluk oranlarına ulaşabilmektedir. Ayrıca, yaş tespiti için sadece görsel veriler deęil, bazen ek biyometrik veriler (örneğin, kişinin saęlık geçmişı, biyolojik yaş bilgisi) de kullanılabilir. Bununla birlikte, yüz verisi kullanılarak yapılan yaş tespiti, genellikle daha hızlı ve invaziv olmayan bir yöntem olarak tercih edilmektedir. Görüntülerden yaş tahmininde yapay zeka, geleneksel yöntemlere kıyasla daha hızlı, doğru ve ölçeklenebilir çözümler sunarak kritik bir rol oynamaktadır Hu vd. (2016). Özellikle yüz analizi, kemik yapısı veya biyometrik veriler üzerinden yaş tahmini yapmak için derin öğrenme algoritmaları ve büyük veri setleri kullanılarak son derece hassas sonuçlar elde edilebilmektedir. Bu, göçmenlik süreçlerinde kimlik doğrulama, adli tıpta yaş tayini ve sosyal hizmetlerde bireylerin yaş gruplarına uygun hizmetlere erişimini saęlama gibi birçok alanda hayati öneme sahiptir. Örneğin, derin öğrenme tabanlı modeller, manuel yöntemlerin sınırlamalarını aşarak hem çocuk hem yetişkin bireylerin yaşını daha kesin bir şekilde tahmin edebilir ve bu da hukuki ve idari süreçlerde hataları en aza indirir. Bunun yanı sıra, yapay zeka, sahte kimlik kullanımını tespit etmede veya spor müsabakalarında yaş sınırlamalarına uyumu denetlemede etkili bir araç olarak kullanılmaktadır. Bu bağlamda, yapay zekanın yaş tespiti konusundaki potansiyeli, hem teknolojik yeniliklerin hem de toplumsal ihtiyaçların kesişimin de önemli bir çözüm sunmaktadır.

Yüz görsellerinden yaş tahmini, video izleme, demografik analiz, müşteri profillemeye ve büyük veri sistemlerinde arama iyileştirmeleri gibi birçok alanda giderek daha fazla önem kazanmıştır. Ancak, yaş tahmininin doğruluęu, eksik veya yetersiz eğitim verilerinin bulunması, bireysel farklılıkların güçlü etkisi ve aynı yaş grubundaki bireylerin görünüşlerindeki geniş çeşitlilik gibi zorluklarla karşılaşmaktadır. Bu tür zorluklarla başa çıkmak için genellikle araştırmacıların manuel olarak belirledikleri özellikler veya parametreler vardır. Yani, veri setlerinde yer alan yüz görüntülerinden, yaş tahminini yapabilmek için belirli yüz özelliklerini örneğin, kırışıklıklar, deri dokusu, çene yapısı gibi elle seçerek modelin eğitimine dahil etmektedir. Bu tür tanımlayıcılar genellikle daha fazla zaman ve çaba gerektirirken, sonrasında yüksek doğruluk oranları saęlanamayabilir. Bu nedenle, daha yeni ve verimli yöntemler, otomatik öğrenmeye dayalı yaklaşımlar örneğin, derin öğrenme geliştirilmiştir. Son yıllarda, daha basit ve etkili yaklaşımlar ortaya çıkmış olup, özellikle doku ve yerel özelliklere dayalı yeni

kombinasyonlar ile derin öğrenme teknikleri, yaş tahmini konusunda önemli ilerlemeler kaydetmiştir. Bu yeni yöntemler, çeşitli veri setlerinde yapılan kapsamlı testlerle daha doğru ve güvenilir sonuçlar elde edilmesini sağlamıştır Huerta vd. (2015).

Yaş tahmini, son yıllarda yoğun bir akademik ilgi görmüş, bu alanda birçok dergi makalesi, konferans bildirisi ve lisansüstü tez çalışması yayımlanmıştır. İnsan yüzünü belirli bir yaş veya yaş grubuyla eşleştirme süreci olan yaş tahmini, gerçek yaş, görünüm yaşı, algılanan yaş veya makine tarafından tahmin edilen yaş gibi farklı kavramlarla ilişkilidir Fu vd. (2010). Gerçek yaş, bireyin doğumundan itibaren geçen süreyi ifade ederken, görünüm yaşı ve algılanan yaş, yüzün görsel özelliklerine dayalı olarak belirlenir. Tahmini yaş ise makine öğrenimi algoritmaları tarafından yüz görüntüsünden çıkarılan yaş bilgisidir. Görünüm yaşı genellikle gerçek yaşla uyumlu kabul edilse de bireyler arasındaki yaşlanma sürecinin rastlantısal ve kişisel doğası bu uyumu zorlaştırabilir. Yaş tahmini, bir yandan çok sınıflı bir sınıflandırma veya regresyon problemi olarak ele alınabilirken, diğer yandan sınıflandırma ve regresyonun bir arada kullanıldığı hiyerarşik yaklaşımlar gerektirebilir. Ancak bu alandaki araştırmaları sınırlayan faktörler bulunmaktadır. Örneğin, bireylerin kronolojik fotoğraflarını içeren geniş kapsamlı veri tabanlarının oluşturulması oldukça zordur. Ayrıca, yüzün farklı varyasyonları, yaşlanma sürecine özgü belirleyici niteliklerin yeterince yakalanamamasına neden olabilir. Yüzlerdeki kontrol edilemeyen ve bireye özgü yaşlanma özellikleri ise yaş tahminini daha da karmaşık hale getiren bir diğer önemli etkidir Angulu vd. (2018).

Yüz görüntülerinden yaş tespiti, yalnızca bir biyometrik tanımlama aracı olmanın ötesinde, toplumda ve endüstrilerde birçok farklı alanda önemli kullanımlar sunmaktadır. Özellikle güvenlik ve kimlik doğrulama alanında, yüz tanıma ve yaş tespiti, insanların kimliklerini doğrulamak için etkili bir yöntem olarak öne çıkmaktadır. Özellikle yaş sınırlı ürünlerin satışı veya hizmetlerin sunulması gereken durumlarda, yüz tanıma sistemleriyle yapılan yaş tespiti, hızlı ve güvenilir bir doğrulama yöntemi sunmaktadır. Yaş tespiti teknolojisi, dijital ortamda yaşa dayalı içerik sınırlamalarının uygulanması, sosyal medya platformlarında kullanıcı güvenliğinin artırılması gibi sosyal alanlarda da önemli bir rol oynamaktadır. Yaş tespiti teknolojilerinin gelişmesiyle birlikte, bu teknolojilerin etik ve güvenlik sorunları da önemli bir gündem maddesi haline gelmiştir. Yüz tanıma sistemlerinin güvenliği ve kişisel verilerin gizliliği, özellikle biyometrik verilerin toplanması ve işlenmesi aşamasında ciddi endişelere yol açmaktadır. Yüz tanıma teknolojisinin kötüye kullanılması, bireylerin

özel verilerinin izinsiz bir şekilde toplanmasına ve işlenmesine neden olabilir. Ayrıca, yanlış yaş tespiti yapılması, bireylerin yaşlarına bağlı olarak ayrımcılığa uğramasına veya yanlış kimlik doğrulama işlemlerine tabi tutulmasına yol açabilir. Bu nedenle, yaş tespiti teknolojilerinin etik ve yasal çerçeveler içinde kullanılması büyük bir önem taşır. Biyometrik verilerin toplanması ve işlenmesi konusunda kullanıcıların rızası alınmalı ve gizlilik haklarına saygı gösterilmelidir. Teknolojideki ilerlemeler ve derin öğrenmenin kullanımı, geleneksel yaş tahmin yöntemlerinin yerini yapay zeka yaklaşımlarına bırakmıştır. Derin öğrenme, çok katmanlı hesaplama ağlarıyla verileri analiz ederek yapay zekanın doğruluğunu artırır. Özellikle evrimsel sinir ağları(CNN), görüntü işleme görevlerinde oldukça etkilidir ve yüz görüntülerinden yaş tahmini gibi karmaşık görevlerde yüksek doğruluk oranları sağlar Alzahrani vd. (2021). 2012 yılında ImageNet Görsel Tanıma Yarışması'nı kazanan AlexNet, derin öğrenme alanında büyük bir adım atılmasını sağladı Abood (2023). VGG-16, sade bir tasarıma sahipken çok fazla parametre gerektirir ve uzun eğitim süreleri gerektirir. GoogLeNet, Inception yapı taşlarını kullanarak verimli ve genelleyici bir model sunar, Normal bir evrim katmanında, giriş verileri, filtrelerin tüm kanalında örneğin renkli bir resimde kırmızı, yeşil, mavi kanallarda aynı anda işlenir. Bu, daha fazla işlem gücü ve parametre gerektirir. Xception, derinlikli ayırık evrimi kullanarak, daha hızlı öğrenme süreci ve daha düşük donanım gereksinimleriyle yüksek doğruluk sağlayan bir model sunar Hu vd. (2023). DenseNet, katmanlar arasındaki çıktıları birleştirerek daha yoğun bilgi akışı sağlar ve daha derin ağlarda eğitim sorunlarını azaltır. DenseNet, derin öğrenme alanında önemli bir yenilik sunan, her katman çıktısının bir sonraki katmanla birleştirildiği bir mimaridir. Bu sayede ağın daha verimli bir şekilde öğrenme yapabilmesi sağlanır ve önceki katmanlardan gelen bilgilerin kaybolması engellenir Zhong vd. (2020). ResNet gibi modellerle karşılaştırıldığında, DenseNet daha verimli öğrenme sağlar ve daha az parametre ile yüksek performans elde edilir.

Bu çalışmamızda, yaş tespitin kullanılabileceği alanlar ve insanlığa sağlayabileceği faydaları, geleneksel yöntemlerle yaş tespitin karşılaştığı zorluklar ve bu zorlukların üstesinden gelmek için yapay zekayı kullanarak bu sorunlara çözüm bulmayı amaçladık. Çalışmamızda evrimsel sinir ağlarından (CNN) DenseNet kullanarak Kaggle platformu üzerinden elde ettiğimiz Hindistan Sineması Yüz Veritabanı (IMFDB) üzerinde yaş tahmini yapmayı amaçladık. Veri setimizde toplamda 19,906 fotoğraf bulunmaktadır. Çalışmamızda, DenseNet'in farklı versiyonları olan DenseNet121, DenseNet169, DenseNet201 ve DenseNet264'ü kullanarak, yüz

görselleri üzerinden yaş tahminini gerçekleştirdik. Bu modellerin her biri farklı derinliklere ve katman sayısına sahip olup, veri setindeki resimlerin sınıflandırılmasında farklı doğruluk oranları sunmaktadır. DenseNet'in her katman arasındaki bilgi aktarımını optimize etme yeteneği, yaş tahmini gibi karmaşık problemlerde yüksek doğruluk sağlamak için ideal bir çözüm sunduk. Farklı modellerle karşılaştırıldığında DenseNet'in daha yüksek performans ve yüksek başarı oranı gösterdiğini gözlemledik.

Sonuç olarak, yüz görüntülerinden yaş tespiti teknolojisi, biyometrik analizlerin bulunduğu olanaklar doğrultusunda, çok çeşitli sektörlerde önemli bir yere sahiptir. Güvenlik, sağlık, pazarlama, eğlence ve adli bilimler gibi birçok alanda kullanımı yaygınlaşan bu teknoloji, gelecekte daha da gelişerek daha yüksek doğruluk oranlarına ulaşacaktır. Ancak, bu teknolojilerin etik kullanımı, veri güvenliği ve gizlilik gibi konuların da dikkate alınması gerekmektedir. Yüz tanıma ve yaş tespiti teknolojilerinin hayatımızdaki rolü giderek artarken, bu alanda yapılacak araştırmaların, toplumsal etkilerini de göz önünde bulundurması önemlidir.

## 2. LİTERATÜR ÇALIŞMALARI

Guehairia ve arkadaşlarının (2022) çalışması, insan yüzünden yaş tahmini konusunun büyük bir ilgi gördüğünü ortaya koymuştur. Bu çalışma, birden fazla derin yüz özelliğini birleştirmek için geliştirilmiş yeni bir yöntemi iyileştirerek sunmuştur. Söz konusu yöntem, derin rastgele ormanlar (DRF) tabanlı bir yaklaşıma dayanmaktadır. DRF'lerin uygulanmasından önce, tensor tabanlı alt alan öğrenimini entegre eden yenilikçi bir çalışma önerilmiştir. Bu kapsamda, bir eğitim setinin derin yüz özellikleri 3 boyutlu bir tensor olarak temsil edilmiş ve en ayırt edici bilgileri elde etmek için Çok Doğrusal Beyazlatılmış Temel Bileşenler Analizi (MWPCA) ile Tensor Üstel Ayırt Edici Analiz (TEDA) kullanılmıştır. Tensor tabanlı alt alan özellikleri, yaş tahmini için DRF'lere girdi olarak verilmiştir. Kamuya açık 5 yüz veri tabanında gerçekleştirilen deneyler, önerilen yöntemin birçok son teknoloji yöntemle rekabet edebileceğini göstermiştir. Önceki DRF yöntemi, yüz görüntülerinden yaş tahmini için geliştirilmiştir. Ancak bu çalışma, tamamen farklı iki yöntemi birleştirerek önemli bir yenilik sunmaktadır: biri tensor tabanlı alt alan öğrenimine, diğeri ise hem sınıflandırma hem de regresyon yöntemlerini bir arada sunan derin rastgele ormanlara dayanmaktadır. Beş kamuya açık yüz veri tabanı ile elde edilen performans son derece umut verici bulunmuştur Guehairia vd. (2022).

Bir diğer çalışmada Zenghao Bao ve arkadaşları (2021), yüz ifadelerinden yaş tahmini amacıyla yapılan önceki araştırmaların, eğitim ve test veri setlerinin benzer koşullara sahip olması durumunda umut verici performanslar sergilediği belirtilmiştir. Ancak bu yöntemlerin, yeni ve farklı alanlarla karşılaşıldığında performansı korumakta zorlandıkları ve önemli ölçüde düşüş gösterdikleri rapor edilmiştir. Bu sorunun üstesinden gelmek amacıyla, yüz yaşı tahmini için Dağılım Dışı (OOD) genelleme sorununu ele alan Derin Alanlar-Arası Öğrenme (DDIL) adlı yeni bir yöntem önerilmiştir. Önerilen DDIL yöntemi, alanlar-arası ve tarzlar-arası olmak üzere iki modülden oluşmaktadır. Alanlar-arası modül, farklı alanlardan gelen özellikler arasındaki kovaryans uyumsuzluğunu azaltarak alanlar-arası özellik çıkarımını gerçekleştirmektedir. Tarzlar-arası modül ise, CNN'nin farklı tarzlara daha iyi uyum sağlamasını desteklemek amacıyla belirli parametreleri veya özellikleri rastgele değiştirilerek önyargıyı en aza indirmeyi hedeflemektedir. Bu iki modülün entegrasyonu sayesinde DDIL, alan uyumsuzluğunun etkisini etkin bir şekilde azaltabilmektedir.

Çeşitli veri setleri üzerinde gerçekleştirilen kapsamlı deneyler, önerilen yöntemin Bir Alan Dışında Çapraz Doğrulama (Leave-One-Domain-Out Cross-Validation) senaryolarında yaş tahmini genellemesi açısından üstün performans sergilediğini ortaya koymuştur. Yapılan bu çalışmada, yüz ifadelerinden yaş tahmininde çapraz alan senaryolarına yönelik olarak DDIL yöntemi sunulmuş ve alanlar arası kovaryans uyumsuzluğu ile tarz önyargısının azaltılması sayesinde elde edilen modelin, değerlendirme sürecinde alanlara özgü tarzlardan ziyade görüntünün içeriğine odaklanması gerektiği vurgulanmıştır Bao vd. (2021).

Marie Jandová ve arkadaşlarının (2020) gerçekleştirdiği çalışmada, 3D yüz verileri kullanılarak yasal yaş sınırlarının (15 ve 18 yaş) sınıflandırılması amacıyla rastgele ormanlar (random forests) yöntemi önerilmiştir. Araştırma, 10-25 yaş aralığında bulunan 394 Çek bireyine ait üç boyutlu yüz taramaları üzerinde yürütülmüş ve üç temel veri türü kullanılmıştır: 3D yüz işaretçilerinin şekil (boyut bağımsız) koordinatları, 3D yüz işaretçilerinin boyut ve şekil koordinatları ile işaretçiler arasındaki mesafeler, açılar ve indeksler. Elde edilen sonuçlar, kullanılan değişkenlerin ve yaş sınırlarının kombinasyonlarına göre doğruluk oranlarının %71,4 ile %91,5 arasında değiştiğini ortaya koymuştur. Çalışmada, 18 yaş sınırına ilişkin doğruluk oranlarının daha yüksek olduğu belirlenirken, 15 yaş sınırında boyut değişkenlerinin daha iyi sonuçlar verdiği tespit edilmiştir. Boyut bağımsız değişkenlerin (şekil değişkenleri), 18 yaş altındaki bireylerin sınıflandırılmasında daha etkili olduğu gözlemlenmiştir. Ayrıca, geleneksel değişkenler (mesafeler, açılar, indeksler) kullanılarak oluşturulan modellerin kadınlarda erkeklere kıyasla daha yüksek doğruluk sağladığı; buna karşın, 3D koordinatlar kullanılarak oluşturulan modellerin erkeklerde daha iyi performans gösterdiği belirlenmiştir. Çalışma, 3D yüz verileri kullanılarak gerçekleştirilen yaş doğrulama yöntemlerinin adli ve biyometrik uygulamalar açısından önemli bir potansiyele sahip olduğunu ve rastgele ormanlar yönteminin özellikle genç bireylerin yaş doğrulamasında güçlü sonuçlar sağlayabileceğini ortaya koymuştur Jandová vd. (2020).

Arisa Takeda ve arkadaşlarının (2021) gerçekleştirdiği bu çalışmada, yüz görüntüleme teknolojisinin, adli uzmanların yerini alarak cesetlerin yaşını tahmin etme potansiyeli incelenmiştir. Yaş tahmini amacıyla FieldAnalyst for Signage adlı yazılım kullanılmıştır. Yazılımın canlı bireylerde yaş tahminindeki etkinliğini doğrulamak için, 28 bireyin üç farklı açıdan (+30°, 0°, -30°), gözleri açık ve kapalı olacak şekilde fotoğrafları çekilmiştir. Yapılan analizler sonucunda, bireylerin gözleri kapalı ve

fotoğrafın 0° açıyla çekildiği durumlarda en yüksek pozitif etkinin elde edildiği belirlenmiştir ( $y = 1.02x - 0.35$ , Spearman'ın sıralama korelasyon katsayısı 0.78,  $P < 0.001$ ). Bireylerin %93'ünün yaşları, gerçek yaşlarının  $\pm 10$  yıllık sapma aralığında tahmin edilmiştir. Bu prosedür, 61 cesede uygulanarak cesetlerin gözleri kapalı ve 0° açıyla fotoğrafları çekilmiştir. Yapılan analizlerde, gerçek yaş ile tahmin edilen yaş arasında pozitif bir korelasyon elde edilmiştir ( $y = 1.28x + 0.43$ , Pearson'ın korelasyon katsayısı 0.69,  $P < 0.001$ ). Ancak, cesetlerin yalnızca %39.3'ünün yaşları  $\pm 10$  yıllık sapma aralığında doğru tahmin edilebilmiştir. Bu sonuçlar, teknolojinin cesetlerin yaşını belirlemek için yeterli doğrulukta olmadığını göstermektedir. Sonuç olarak, adli tıp uzmanlarının sahip olduğu bilgi ve deneyime alternatif bir yöntem olarak değerlendirilemeyeceği sonucuna varılmıştır Takeda vd. (2021).

Bu çalışmada Abdelkrim Ouafi ve arkadaşları (2019), yüz görüntülerine dayalı otomatik yaş tahmini için yeni bir yaklaşım önermektedir. Önerilen yaklaşım, üç temel aşamadan oluşmaktadır. İlk aşamada, yüz tespiti ve hizalama işlemi gerçekleştirilmekte olup, bu sayede yalnızca ilgilenilen bölgeler çıkarılmakta ve yüzün konumu ile boyutu düzeltilmektedir. İkinci aşamada, Multi-level yüz temsili kullanılarak yüz bölgesindeki özellikler doku tanımlayıcıları aracılığıyla çıkarılmaktadır. Son aşamada ise, yaş tahmini için İki Aşamalı Yaş Tahmini (TSE) yöntemi önerilmektedir. Bu yöntemde, ilk aşamada yüz görüntüsü demografik sınıflara ayrılmakta, ardından ikinci aşamada ilgili sınıf içerisinde yaş tahmini gerçekleştirilmektedir. Gerçekleştirilen deneyler, önerilen yaklaşımın mevcut yöntemlere kıyasla daha iyi performans sergilediğini göstermiştir. Önerilen yöntemin, aynı cinsiyet, ırk ve yaş aralığındaki bireyler için daha düşük hata payı ile yaş tahmini yapabildiği tespit edilmiştir. Ayrıca, bu yaklaşımın, mobil cihazlarda düşük bellek kullanımı ve işlem gücü gereksinimi ile çalışabilecek şekilde basit ve verimli olduğu belirtilmiştir. Gelecekte, daha etkili özellik seçim yöntemleri kullanılarak gereksiz ve/veya tekrarlayan demografik özelliklerin çıkarılması yoluyla eğitim ve test sürelerinin azaltılabileceği öngörülmektedir. Bunun yanı sıra, ırk ve cinsiyet faktörlerinin yaş tahmini üzerindeki etkilerinin daha ayrıntılı bir şekilde incelenebileceği ifade edilmiştir. Yazarlar, bu yöntemin özellikle yüz tanıma ve biyometrik uygulamalarda daha etkili sonuçlar sağlama potansiyeline sahip olduğunu vurgulamaktadır Ouafi vd. (2019).

Surya Teja Chavali ve arkadaşları (2023) tarafından gerçekleştirilen bir diğer çalışmada, insan-bilgisayar etkileşiminin (HCI) akıllı, ölçeklenebilir ve esnek çözümler üretme kapasitesine odaklanıldığı belirtilmiştir. Araştırmada, büyük teknoloji şirketleri

ve işletmelerin, bilgiye dayalı uygulamalarda esnek ve talebe uygun şekilde teknoloji ve altyapıyı kullanma imkânına sahip olduklarına inanıldığı ifade edilmektedir. Bu süreçte, kamuya açık bulut hizmetleri (örneğin, Amazon Web Services gibi üçüncü taraf sağlayıcıların altyapısı) kullanılmadan, kendi özel çözümleriyle kâr elde etme potansiyeline sahip oldukları vurgulanmaktadır. HCI'nin doğru bir şekilde uygulanmasının, şirketlerin kendi iç sistemleri üzerinden bağımsız bir şekilde yüksek verimlilik ve gelir elde etmelerine katkı sağlayabileceği ifade edilmiştir. Çalışmada, yüz ifadesi tanıma ve yazılım tabanlı yüz ifadesi tanımlama sistemlerinin, insan kodlama yeteneklerini taklit edebilme kapasiteleri nedeniyle önemli bir yer tuttuğu belirtilmiştir. Araştırmada, insanların duygusal durumlarını tanıyabilen bir sistem önerilmiş olup, yaş ve cinsiyet tahmininin sosyal hayatta görsel gözetim, klinik teşhis ve ürün pazarlaması gibi alanlarda önemli bir rol oynadığı vurgulanmıştır. Çalışmada elde edilen bulgulara göre, yüz ifadesi tanıma, cinsiyet ve yaş tahmini konularında başarılı sonuçlar elde edilmiştir; yaş tespiti için 0.83, yüz ifadesi tanıma için ise 0.46 F1 skoru ile en iyi performansın SVM modeli tarafından sağlandığı belirlenmiştir. Ayrıca, VGG-16 modeli ile doğrulama aşamasında %95.31 gibi yüksek bir doğruluk oranına ulaşıldığı kaydedilmiştir. Araştırmada, geleneksel makine öğrenimi ile derin öğrenme algoritmalarının kullanımı arasındaki farklılıklar ele alınmış ve cinsiyetin yüz ifadeleri üzerindeki etkileri detaylandırılmıştır. Çalışmada, AlexNet, ResNet-50 ve GoogleNet gibi önceden eğitilmiş modellerin uygulanmasıyla genişletilebileceği ve cinsiyet ile yaşın yüz ifadelerini belirleme üzerindeki etkilerinin daha kapsamlı bir şekilde anlaşılabilmesi için gerçek zamanlı kullanım senaryolarında değerlendirilebileceği ifade edilmiştir Chavali vd. (2023).

Abirami ve arkadaşları (2020) tarafından gerçekleştirilen bu çalışmada, yüz görüntülerinin erişim kontrolü, insan-bilgisayar etkileşimi ve görsel gözetim gibi akıllı uygulamalar için yaş ve cinsiyet bilgilerini sağlayan önemli bir kaynak olduğu vurgulanmaktadır. Sosyal medyanın yaygın kullanımıyla birlikte, gerçek zamanlı otomatik yaş ve cinsiyet tespitine duyulan ihtiyacın arttığı belirtilmiştir. Yüz tanıma alanında yapılan çeşitli araştırmalara rağmen, mevcut yöntemlerin gerçek dünya görüntülerinde sergilediği performansta hala eksiklikler bulunduğu ifade edilmiştir. Bu çalışmada, tek bir yüz görüntüsünden gerçek zamanlı olarak yaş ve cinsiyet tahmin edilmesi amaçlanmıştır. Yüz tespiti Haar Cascade yöntemi kullanılarak gerçekleştirilmiş; yaş ve cinsiyet sınıflandırmaları ise Caffenet CNN modeli aracılığıyla yapılmıştır. Yaş tahmini için kullanılan CNN modelinin çıkış katmanında, sekiz farklı

yaş grubuna karşılık gelen değerler yer almakta olup, cinsiyet tahmini için "Erkek" ve "Kadın" sınıflarını içeren bir yapı benimsenmiştir. Elde edilen sonuçlar, sistemin %68.89 doğruluk oranıyla başarılı bir performans sergilediğini göstermektedir. Çalışma, geliştirilen yöntemin yaş ve cinsiyet tahmininde gerçek zamanlı uygulamalar için etkili bir çözüm sunduğu ortaya koyulmuştur Abirami vd. (2020).

Bir başka çalışmada Hang-Xing Zang ve arkadaşları (2022), dev panda (*Ailuropoda melanoleuca*) popülasyon dinamiklerinin anlaşılmasında yaş dağılımının önemine dikkat çekmiştir. Geleneksel yaş tahmin yöntemlerinin yüksek maliyetli, zaman alıcı ve sıklıkla hatalı olduğu belirtilmiş; bu yöntemlerin yalnızca yaş gruplarını tahmin etmekle sınırlı kaldığı ve standart bir yaklaşımdan yoksun olduğu ifade edilmiştir. Ancak, derin öğrenme ve bilgisayarla görme alanındaki ilerlemeler, bu soruna yenilikçi çözümler sunmaktadır. Araştırma kapsamında, yaşları 0 ile 38 arasında değişen 272 pandaya ait toplam 8002 görüntü toplanmış ve ordinal regresyon kullanan yedi farklı CNN tabanlı model, beş katmanlı özne-dışı (SE) protokolüyle eğitilmiştir. Deneyler, Panda Yaş Veri Seti (PAD Full) ve Lite Panda Yaş Veri Seti (PAD Lite) üzerinde gerçekleştirilmiş ve sırasıyla 2.51 ve 2.41 Ortalama Mutlak Hata (MAE) değerleri elde edilmiştir. Elde edilen sonuçlar, önerilen yöntemin hem esaret altındaki hem de doğal yaşam alanlarındaki pandaların yaşlarını invaziv olmayan bir şekilde tahmin edebildiğini göstermektedir. Bu yöntemin yalnızca pandaların doğru yaşta serbest bırakılarak popülasyon düşüşlerinin önlenmesine ve genetik çeşitliliğin korunmasına katkı sağlamakla kalmayıp, aynı zamanda diğer türler için de uygulanabilir bir çözüm sunduğu vurgulanmıştır. Sonuç olarak, makine öğrenmesi ve derin öğrenme tekniklerinin biyoloji ve ekoloji alanındaki koruma hedeflerini destekleyerek önemli bir potansiyel taşıdığı ifade edilmiştir Zang vd. (2022).

Yaş tespiti, hukuki ve insani bağlamlarda kritik bir öneme sahip olduğunu söyleyen Nicole Prata Damascena ve arkadaşları (2024); bu çalışmada yaş tespiti alanının hukuki ve insani bağlamda taşıdığı kritik önemini vurgulamaktadır. Çalışmada, yüz geometrik morfometri (Facial Geometric Morphometrics) yöntemi kullanılarak yaş tahmini yapılmasının olanakları incelenmiş ve bu yöntemin yaş tahmininde umut vaat eden bir araç olduğu sonucuna varılmıştır. Araştırma, Brezilya Federal Polisi veri tabanından alınan ve dört farklı yaş grubunu (6, 10, 14 ve 18 yaş) temsil eden toplam 4000 fotoğraf üzerinde gerçekleştirilmiştir. Fotoğraflarda, yaş ve cinsiyete bağlı olarak yüz şekillerini belirlemek amacıyla 28 fotogrametrik nokta işaretlenmiş ve bu veriler, yüz geometrik morfometri yöntemiyle analiz edilmiştir. Analiz sonuçları, yöntemin

genel doğruluk oranını %69,3 olarak belirlemiştir. Bu oran, erkeklerde (%74,7) kadınlara (%65,8) göre daha yüksek bir başarı göstermektedir. Özellikle 6 yaş grubunda, yöntem yüksek bir doğruluk sergileyerek %87,3 duyarlılık ve %95,6 özgüllük oranlarına ulaşmıştır. Ancak 14 yaş grubunda, diğer yaş gruplarına göre daha düşük bir performans gözlemlenmiştir. Yaş farklarının daha belirgin olduğu gruplar arasında, yöntemin doğruluk oranında önemli bir artış gözlemlenmiş ve bazı yaş grupları arasında doğruluk oranı %99,5'e kadar çıkmıştır. Örneğin, 6 ve 10 yaş arasındaki kız çocukları ile 10, 14 ve 18 yaş arasındaki erkek çocuklarının ayırt edilmesinde oldukça yüksek doğruluk oranları elde edilmiştir. Sonuç olarak, yüz geometrik morfometri yöntemi, özellikle çocuklar ve ergenler arasında yaş tahmininde adli bağlamda kullanılabilecek güçlü bir araç olarak değerlendirilmektedir. Bu yöntemin, görsel materyallerin yargısal süreçlerde daha güvenilir bir şekilde kullanılmasına katkı sağlayarak, özellikle Brezilya'daki kritik yasal yaşların belirlenmesinde önemli bir potansiyele sahip olduğu sonucuna varılmıştır Damascena vd. (2024).

Qilu Zhao ve arkadaşları (2024), çalışmalarında, yaş etiketleri arasındaki sıralı ilişkileri öğrenmek ve durağan olmayan yaşlanma sürecinden kaynaklanan heterojen veri sorunlarını çözmek amacıyla gelişmiş bir derin karışım modeli önermektedirler. Model, yaşlanma sürecinin farklı alt süreçlere ayrılabilceği fikrine dayanmaktadır ve bu doğrultuda yaş spektrumunu gruplara ayırarak her grup için bir "uzman" ağ eğitilmiştir. Uzman ağlar, gruplar arası örtüşme ve ek yaş sınıflarının tanımlanması gibi özel tasarımlar ve ortak bir eğitim mekanizmasıyla birleştirilmiştir. Bu sayede, tüm yaş etiketleri arasındaki sıralı ilişkiler korunmuş ve hiyerarşik sınıflandırma yöntemi kullanılarak nihai yaş tahmini yapılmıştır. Önerilen model, yaş tahmini amacıyla kullanılan çeşitli veri setlerinde test edilmiştir ve mevcut yöntemlere göre üstün sonuçlar elde edilmiştir. Eğitim süreci, iki aşamalı bir yapı ile tasarlanmış ve uzmanlar arasında sıralı ortak eğitim uygulanmıştır. Çalışma, dengesiz veri dağılımı, ırk ve cinsiyetin yaşlanma süreçlerine etkisi ve doğal ortamlarda yaş tahmini gibi önemli sorunlara dikkat çekmekte ve bu zorlukların entegre bir model çerçevesinde ele alınmasının gerekliliğini vurgulamaktadır Zhao vd. (2024).

Diğer bir çalışmada Fares Alnajjar ve arkadaşları (2012), zorlu görüntüleme koşullarında yaş tahmini için öğrenmeye dayalı bir kodlama yöntemi önermektedirler. Geleneksel yaklaşımlar, yüzün tamamından elde edilen özelliklerle tek bir kodlama modeli oluşturarak her bir özelliği bir kod ile eşleştirirken, bu çalışmada yüz farklı

bölgelere ayrılmış ve her bölgeye özel kodlama modelleri geliştirilmiştir. Ayrıca, bu yöntemle her piksel birden fazla koda atanmış ve atamalar, ağırlıklı bir sistemle gerçekleştirilmiştir. Yöntemin bir diğer yeniliği, yerel gradyanların yönelimleriyle ilgili bilgilerin kodlama sürecinde kullanılmasında yatmaktadır. Araştırmacılar, bu yöntemi gerçek dünyada çekilmiş 2744 yüz fotoğrafı içeren geniş bir veri setinde test etmiş ve mevcut yöntemlere kıyasla %3,6'lık mutlak (%6,5'lik göreceli) bir performans artışı elde etmişlerdir. Ayrıca, yöntemin Gallagher veri setinde yaş gruplarını sınıflandırmada üstün performans sergilediği ve yüz doğrulama gibi diğer görevlerde de fayda sağladığı gözlemlenmiştir. Sonuç olarak, bu çalışma, önerilen yöntemin yalnızca yaş tahmini değil, aynı zamanda yüzle ilgili diğer problemlerin çözümünde de etkili bir şekilde kullanılabileceğini ortaya koymaktadır Alnajar vd. (2012).

Sung Eun Choi ve arkadaşları (2012), yüz görüntülerinden yaş tahmini yapmak amacıyla hibrit özellikler ve hiyerarşik sınıflandırıcıları bir araya getiren yenilikçi bir yöntem önermektedirler. Hibrit özellikler kullanarak, küresel ve yerel yüz özelliklerinin avantajlarını birleştirerek her iki yöntemin eksikliklerini gidermeyi amaçlamışlardır. Yerel özelliklerin çıkarılmasında, kırıksıklıklar için Gabor filtreleri, cilt dokusu detayları için ise Yerel İkili Desenler (LBP) yöntemi kullanılmıştır. Bu iki yöntemin birleşimi, yaş tahmininde doğruluğu önemli ölçüde artırmıştır. Hiyerarşik sınıflandırıcı yaklaşımında, önce yaş grupları (örneğin, 20 yaş altı, 20-39 yaş arası) sınıflandırılmış, ardından daha detaylı yaş tahminleri gerçekleştirilmiştir. Ayrıca, hata oranlarını azaltmak amacıyla yaş sınıfları, birbiriyle örtüşecek şekilde yapılandırılmıştır. Çalışmanın sonuçları, önerilen yöntemin üç farklı veri setinde test edildiğinde, önceden kullanılan yöntemlere kıyasla daha iyi performans sergilediğini ortaya koymuştur. Bu çalışma, hibrit özellikler ve hiyerarşik sınıflandırıcıların yaş tahmininde etkili bir şekilde kullanılabileceğini göstermiş ve gelecekte, ifade, ışık, yaş ve cinsiyet gibi koşullarda yerel özelliklerin daha iyi çıkarılmasına yönelik araştırmalar yapılması gerektiğine dikkat çekmişlerdir Choi vd. (2012).

Bir diğer çalışmada ise Wei-Lun Chao ve arkadaşları (2013), yüz görüntülerinden yaş tahmini yapmak amacıyla, insan yaşlarının doğasında bulunan faktörleri dikkate alan yenilikçi bir yöntem önermektedirler. Bu çalışmada, yüz özellikleri ile yaş etiketleri arasındaki bağlantıları daha iyi keşfetmek amacıyla Yerel Koruma Projeksiyonu (LPP) ve Marjinal Fisher Analizi (MFA) algoritmalarından yararlanılmıştır. Bu süreçte, yaş etiketleri arasındaki ilişkiyi göz önünde bulunduran "etiket duyarlılığı" kavramı geliştirilmiş ve boyut azaltma ile veri dengesizliği

problemlerini gidermek için çeşitli dengeleme yöntemleri önerilmiştir. Ayrıca, karmaşık yüz yaşlanma süreçlerini yakalayabilmek için KNN-SVR (K-en Yakın Komşular Destek Vektör Regresyonu) adı verilen yaş odaklı bir yerel regresyon algoritması tasarlanmıştır. Önerilen yöntemde, boyut azaltma öncesinde uygun bir komşuluk arama alanı oluşturmak amacıyla mesafe metriği uyarlaması yapılmış ve etiket duyarlılığı bu adımda da uygulanmıştır. FG-NET yaşlanma veri tabanı üzerinde yapılan simülasyon sonuçları, önerilen yöntemin mevcut state-of-the-art algoritmalarla karşılaştırıldığında en düşük ortalama mutlak hata (MAE) değerine ulaştığını ortaya koymuştur. Bu bulgular, önerilen yaklaşımın hem etkin hem de verimli bir çözüm sunduğunu göstermektedir Chao vd. (2013).

Mohammad Mahdi Dehshibi ve Azam Bastanfard (2010) beraber yaptığı çalışmada, önden çekilmiş yüz görüntülerinden yaş grubu tanıma amacıyla yeni bir algoritma geliştirmişlerdir. Bu algoritma, bireyleri dört yaş kategorisine ayırmayı amaçlayan dört aşamalı bir süreçle işlemektedir: ön işleme, yüz özelliklerinin yenilikçi bir geometrik yöntemle çıkarılması, özelliklerin analizi ve yaş sınıflandırması. Araştırma sırasında, yaş bilgisine odaklanan bir yüz görüntü veri tabanının eksikliği önemli bir sorun olarak belirlenmiş ve bu eksiklik, 1 ila 85 yaş arasındaki bireylerin dijital görüntülerini içeren İran Yüz Veritabanı (IFDB) oluşturularak giderilmiştir. Algoritma, yüzlerdeki temel özellik oranları ve kırıksıklık yoğunluklarını kullanarak bir sinir ağı aracılığıyla yaş grubu sınıflandırması yapmaktadır ve %86.64 doğruluk oranı elde edilmiştir. Yüz özellik noktalarının oranlarını kullanması sayesinde algoritma, farklı nesillere de uygulanabilir hale gelmiştir. Sınırlı sayıda parametre ile insan yargısına yakın bir doğruluk sağlayan bu sistemin, ses, yüz özellikleri arasındaki açığı ve saç rengi gibi ek verilerle daha da geliştirilebileceği öngörülmektedir Dehshibi ve Bastanfard (2010).

Bu çalışmada, Qing Tian ve arkadaşları (2021), akıllı şehirler bağlamında insan yüzünden yaş tahmininin geniş uygulama alanları nedeniyle önemli bir araştırma konusu haline geldiğinden bahsetmektedirler. Bu çalışmada, yüz görünümü ile biyolojik yaşlanma süreci arasındaki ilişkileri aynı anda modellemek amacıyla Birleşik İlişki Keşif ve Yaş Tahmin Modeli (JREAE) önerilmiştir. JREAE, yüz özellikleri ve yaş etiketleri arasındaki gizli ilişkileri yakalamak için simetrik olarak iki kovaryans matrisi kullanmaktadır. Bu yaklaşım, özellikler ve etiketler arasındaki ilişkileri manuel olarak tanımlamak yerine, eğitim verilerinden adaptif bir şekilde öğrenerek daha etkili bir modelleme sağlamaktadır. Daha güçlü bir ayırt etme yeteneği elde etmek için model,


derin bir evrişimsel mimariyle (deep-JREAE) genişletilmiştir. Ayrıca, önerilen modelin en uygun biçime sokulabilmesi için teorik olarak kanıtlanmış algoritmalar geliştirilmiştir. Yapılan kapsamlı deneyler, yöntemin üstün performansını doğrulamış ve ilişkileri görselleştirerek analiz etmiştir. Bu yöntem, yüz özellikleri ve yaş etiketleri arasındaki düzenlilikleri ve komşuluk benzerliklerini kümülatif öznel kodlamasıyla otomatik olarak keşfederek projeksiyon matrisi üzerinde modelleme yapmaktadır. Gelecekte, bu çalışmanın daha güçlü derin öğrenme mimarileriyle geliştirilmesi planlanmaktadır Tian vd. (2021).

Liu ve arkadaşları (2023), yaş tahmini yapmak amacıyla daha etkili bir yöntem önermektedirler. Yüzdeki yaşla ilgili özelliklerin elde edilmesi genellikle zorlu bir süreç olduğundan, önceki birçok çalışmada yaşla ilişkili özelliklerin çıkarılmasına odaklanılmış, ancak hangi yerel bölgelerin daha önemli olduğu yeterince araştırılmamıştır. Bu çalışmada, her birey için yerel ilgi bölgelerinin kişiselleştirilmiş bir şekilde segmentasyonu gerçekleştirilmiş ve bu bölgelerin çıkarılmasıyla hiyerarşik yaş özellikleri oluşturulmuştur. Ayrıca, yaş sınıflandırması ve regresyon görevleri için çoklu giriş ve çoklu çıkış (MIMO) ağı kullanılarak yerel ve küresel yüz özellikleri birleştirilmiştir. Yapılan deneyler, önerilen yöntemin üç farklı veri kümesinde mevcut en iyi yöntemlerden daha başarılı olduğunu ve aynı zamanda cinsiyet ve ırk tahmininde de yüksek performans gösterdiğini ortaya koymuştur. Bununla birlikte, bu yöntemin bazı sınırlamaları da bulunmaktadır. Özellikle ağın eğitilmesi, çok adımlı bir süreç gerektirdiğinden, ilgi bölgelerinin çıkarılması ve silinmesi gibi ön işleme adımlarına ihtiyaç duyulmaktadır. Gelecekte, bu yöntemin daha hafif mimarilerle uygulanması ve yüzün kişiselleştirilmiş yerel ve küresel özelliklerini çıkaran bütünsel bir modelin geliştirilmesi hedeflenmektedir. Liu vd. (2023).

### 3. MATERYAL VE METOT

#### 3.1. Materyal

Bu tez çalışmasında Hindistan aktörlerine ait yüz ifadelerinden yaş tespiti gerçekleştirilmiştir. Veri seti Kaggle platformundan indirilmiştir. Veri seti 19906 görüntüden oluşmaktadır. Görüntüler 100 Hintli oyuncuya ait videolardan toplanmıştır. Indian Movie Face Database (IMFDB) veri setinde görüntüler Genç, Orta ve Yaşlı şeklinde etiketlenmiştir. Tüm görüntüler, video karelerinden manuel olarak seçilmiş ve kırılmıştır. Bu durum, veri setinde ölçek, poz, yüz ifadesi, aydınlatma, yaş, çözünürlük, engelleme (occlusion) ve makyaj gibi birçok faktörde yüksek bir değişkenlik sağlamaktadır. IMFDB, her bir görüntü için detaylı bir etiketleme sunan ilk yüz veri tabanıdır. Bu etiketler arasında yaş, poz, cinsiyet, yüz ifadesi ve görüntüdeki engelleme türleri yer almakta olup, bu durum diğer yüz tanıma uygulamalarına katkı sağlayabilecek önemli bir özellik sunmaktadır. Veri seti, yüz tanıma ve sınıflandırma gibi çeşitli alanlarda kullanılabilir. Resimler farklı çözünürlüktedir. Veri setinde 10804 Orta, 2396 Yaşlı ve 6706 Genç etiketli görüntü bulunmaktadır. Veri setindeki örnek görüntüler Şekil 3.1’de gösterilmektedir.



**Şekil 3.1.** Veri setindeki Örnek Görüntüler

## 3.2. Metot

### 3.2.1. Derin öğrenme

Derin öğrenme, yapay zekâ ve makine öğrenme alanlarında önemli bir yere sahiptir. Özellikle son yıllarda bilgi işlem kapasitesinin artması, daha büyük veri setlerine erişim ve gelişmiş algoritmalar sayesinde derin öğrenme, çeşitli endüstriyel ve akademik uygulamalarda yaygın bir şekilde kullanılmaya başlanmıştır. Derin öğrenme, yapısal olarak insan beynindeki sinir ağlarını modelleyen yapay sinir ağlarına dayanır. Bu teknoloji, görülmemiş seviyelerde performans sunarak görü, doğal dil işleme, ses tanıma ve öneri sistemleri gibi çok sayıda uygulama alanında devrim yaratmıştır. Derin

öğrenme, yapay sinir ağlarının katmanlarından oluşan bir yapıyı temel alır. Bu yapı, genellikle “derin” olarak adlandırılan çok sayıda gizli katmanı içerir. Her bir katman, girdi verilerini daha soyut ve karmaşık temsil seviyelerine dönüştürerek çıktını öğrenir. İleri beslemeli sinir ağları, evrimsel sinir ağları (CNN) ve tekrarlayan sinir ağları (RNN) gibi farklı mimariler, farklı uygulama senaryolarına uygun çözümler sunar LeCun vd. (2015). Eğitim sürecinde, sinir ağı geri yayılım algoritması ve gradyan iniş yöntemleri kullanılarak optimize edilir. Bu optimize etme süreci, kayıp fonksiyonunu minimize ederek öğrenme kapasitesini artırır. Günümüzde GPU ve TPU gibi donanımsal gelişmeler, özellikle derin öğrenmenin daha büyük ve karmaşık veri setlerinde etkin bir şekilde çalışmasını mümkün kılmıştır Goodfellow vd. (2016).

Derin öğrenme, günümüzde teknoloji odaklı çözümler sunarak farklı disiplinlerde kullanılmaktadır:

1. **Görü:** Derin öğrenme algoritmaları, nesne algılama, yüz tanıma ve otonom araçlar gibi görü işleme alanlarında devrim yaratmıştır. Özellikle evrimsel sinir ağları bu alanlarda çok başarılıdır Krizhevsky vd. (2012).
2. **Doğal dil işleme (NLP):** Derin öğrenme, metin çevirisi, dil modeli oluşturma ve duygu analizi gibi alanlarda çeşitli uygulamaları desteklemektedir. Transformer tabanlı modeller, bu alanda standardı belirlemiştir Vaswani vd. (2017).
3. **Sağlık:** Tıbbi görüntüleme ve hastalık tanısı gibi alanlarda derin öğrenme algoritmaları, insanın ötesinde tanı koyma kapasitesi sunmaktadır.
4. **Finans:** Algoritmik ticaret, sahtecilik tespiti ve kredi risk analizleri, derin öğrenmenin yoğun kullanıldığı alanlardan bazılarıdır.

Derin öğrenmenin getirdiği yeniliklere rağmen, çoğu zaman aşırı uyum, veri etik sorunları ve hesaplama maliyetleri gibi zorluklarla karşılaşmaktadır. Bununla birlikte, daha verimli algoritmaların ve enerji dostu donanımların geliştirilmesiyle bu engellerin üstesinden gelinmesi beklenmektedir. Özellikle federatif öğrenme ve transfer öğrenme gibi yaklaşımlar, veri gizliliği ve daha az veriyle eğitim gibi sorunları çözmeyi amaçlamaktadır Yang vd. (2019). Derin öğrenme, teknoloji ve bilimde devrim yaratan bir disiplindir. Görüden doğal dile, sağlıktan finansa kadar geniş bir yelpazede uygulamalar sunan bu teknoloji, gelecekte daha büyük bir etki yaratmaya adaydır. Ancak, bu ilerlemelerin sorumlu bir şekilde yönetilmesi ve geliştirilmesi, toplumsal faydayı maksimize etmek için kritik önem taşımaktadır.

### 3.2.2. Transfer derin öğrenme yaklaşımı

Transfer derin öğrenme, bir modelin bir problemin çözümü için öğrenilen bilgilerini farklı ancak benzer bir problem için yeniden kullanılmasını sağlayan çok yönlü bir yaklaşımdır. Geleneksel derin öğrenme yöntemleri genellikle sıfırdan başlayarak model eğitimi gerektirirken, transfer öğrenme önceden eğitilmiş bir modelin özelliklerini yeniden kullanarak hem hesaplama maliyetini hem de eğitim sürecini önemli ölçülerde azaltır. Bu yaklaşım, özellikle büyük miktarda etiketli doğrulanmış verilere ulaşamadığı durumlarda etkili bir çözüm sunar. Transfer öğrenmenin çekirdeğini oluşturan prensip, öğrenmenin evrenselliğidir; yani, bir alanda öğrenilen özellikler, diğer alanlarda da faydalı olabilir Pan ve Yang (2010).

Transfer derin öğrenme, genellikle önceden eğitim, ince ayar (fine-tuning) ve uygulama olmak üzere üç temel aşamada gerçekleştirilir. Önceden eğitim aşamasında, bir model büyük ve genel bir veri seti üzerinde eğitilir; bu, modelin çok çeşitli girdi verilerinden evrensel özellikleri öğrenmesini sağlar. Daha sonra ince ayar aşamasında, önceden eğitilmiş bu model, hedef probleme uygun olacak şekilde yeniden eğitilir veya optimize edilir. Nihayetinde uygulama aşamasında, modelin hedef problemdeki performansı en uygulanabilir seviyeye getirilir. Bu aşamalar sayesinde transfer derin öğrenme, genelleştirilebilir özelliklerin yeniden kullanımını mümkün kılarak farklı alanlarda hızlı ve etkili çözümler sunar Yosinski vd. (2014).

Transfer derin öğrenmenin temel avantajlarından biri, aşırı uyum (overfitting) riskini azaltmasıdır. Geleneksel yaklaşımlarda sınırlı veriyle eğitilen modeller, genelde hedef problemin verisine aşırı özel bir uyum geliştirerek genelleştirme kapasitesini kaybeder. Transfer öğrenme, bu sorunu ortadan kaldırmak için, özellikle büyük ve çeşitli veri setleriyle önceden eğitilmiş modellerden faydalanır. Bu yaklaşım, sağlık, otonom sistemler ve doğal dil işleme gibi alanlarda çok çeşitli uygulamaların temelini oluşturmuştur. Tıbbi görüntüleme alanında, bir model genel görüntüler üzerinde eğitildikten sonra, spesifik tıbbi veri setleri için ince ayar yapılarak etkin bir çözüm sunabilir. Benzer şekilde, otonom sistemlerde farklı ortamların algılanması için bu teknik kullanılmıştır Devlin vd. (2019).

Ancak transfer derin öğrenmenin zorlukları da vardır. Bir modelin önceden eğitildiği veri setinin etik sorunları veya düzensiz dağılımı, hedef problemde alakasız özelliklerin öğrenilmesine yol açabilir. Bu durum, özellikle hassas veri kullanılan alanlarda ciddi sorunlar yaratabilir. Ayrıca transfer öğrenme sürecinde hesaplama

maliyetleri tamamen ortadan kaldırılamaz, çünkü önceden eğitilmiş modellerin optimize edilmesi çoğu zaman yoğun bir hesaplama gerektirir Geirhos vd. (2020). Bu nedenle, transfer öğrenme tekniklerinin başarısı, hem uygun veri setlerinin kullanılmasına hem de bu veri setlerinin etik ve yasal olarak doğrulanmış olmasına bağlıdır.

Transfer derin öğrenme gelecekte daha fazla geliştirilmeye aday bir alandır. Federatif öğrenme ve meta-öğrenme gibi yöntemlerle birleştirildiğinde, veri gizliliği ve daha az veriyle eğitim gibi zorluklara yenilikçi çözümler sunabilir. Bu gelişmeler, transfer öğrenmenin daha geniş kitleler tarafından benimsenmesini ve daha verimli uygulamaları hayata geçirmesini sağlayabilir.

### 3.2.3. DenseNet mimarileri

DenseNet (Dense Convolutional Network), derin sinir ağlarının daha etkili bir şekilde öğrenmesi ve parametre etkinliği sağlaması amacıyla önerilen bir mimaridir. Bu mimari, her katmanın tüm önceki katmanlarla doğrudan bağlantılı olduğu bir tasarım sunar. DenseNet, özellikle derin öğrenme modellerinde sıkça karşılaşılan bilgi kaybı ve gradyan sönmesi sorunlarına çözüm sunar. Yoğun bağlantılı yapısı sayesinde bilgi akışını ve gradyanların yayılmasını iyileştirir, böylece daha az parametre ile daha verimli bir eğitim sağlar Huang vd. (2017).

DenseNet'in en temel özelliği, her katmanın çıktısının sonraki tüm katmanlara giriş olarak bağlanmasıdır. Bu bağlantı stratejisi, bilgi paylaşımını artırarak modelin öğrenme kapasitesini geliştirir. Geleneksel konvolüsyonel ağlarda, her katman sadece bir önceki katmandan bilgi alırken, DenseNet'te bir katman tüm önceki katmanların çıktısını birleştirir ve bu birleşimi giriş olarak kullanır. Bu, modelin daha iyi genelleştirilmiş özellikler öğrenmesini sağlar ve hesaplama verimliliğini artırır.

DenseNet'in bir diğer önemli bileşeni "yoğun bloklar"dır. Her yoğun blok içinde, katmanlar arasında doğrudan bağlantılar kurulur, ancak bloklar arasında bağlantı bulunmaz. Bu yapı, modelin daha düzenli ve kontrol edilebilir olmasını sağlar. Yoğun blokların arasına yerleştirilen "geçiş katmanları" ise, özellik haritalarının boyutunu azaltarak modelin parametre yükünü dengeler.

DenseNet'in sağladığı avantajlar arasında şunlar yer alır:

1. **Parametre etkinliği:** Geleneksel ağlara kıyasla daha az parametre kullanarak yüksek performans elde eder. Bu, özellikle sınırlı hesaplama kaynaklarına sahip uygulamalar için önemlidir.

2. **Gradyan yayılımı:** Her katmanın önceki tüm katmanlarla bağlantılı olması, gradyanların daha etkin bir şekilde yayılmasını sağlar ve gradyan sönmesi sorununu büyük ölçüde azaltır.
3. **Daha iyi özellik öğrenimi:** Her katmanın önceki katmanlardan gelen tüm bilgileri kullanması, modelin daha karmaşık ve zengin özellikler öğrenmesine olanak tanır.
4. **Daha az overfitting:** Parametre sayısının azalması, modelin aşırı uyum yapma eğilimini azaltır.

### 3.2.4. DenseNet121 mimarisi

DenseNet-121, özellikle sınırlı kaynaklarla yüksek performans elde etmek amacıyla tasarlanmış bir derin sinir ağı modelidir. Adını toplamda 121 katmana sahip olmasından alan bu mimari, bilgi paylaşımını maksimum seviyeye çıkararak hem eğitim sürecini iyileştirir hem de modelin genel performansını artırır. DenseNet-121'in temel özelliklerinden biri, her bir katmanın önceki tüm katmanların çıktısına erişim sağlamasıdır. Bu, geleneksel konvolüsyonel ağlarda sıklıkla karşılaşılan bilgi kaybını önler. DenseNet-121, temel olarak şu bölümlerden oluşur:


1. **Giriş katmanı:** İlk katman, 7x7 boyutunda filtrelerle sahip bir konvolüsyon katmanıdır. Bu katman, girdi verilerini yoğun bir şekilde işler ve ardından 3x3 boyutunda bir maksimum havuzlama (max-pooling) işlemi ile boyutlarını küçültür. Bu işlem, hesaplama yükünü azaltırken modelin genelleştirme kapasitesini artırır.
2. **Yoğun bloklar:** Modelin ana bileşenini oluşturan dört yoğun blok, özellik haritalarını zenginleştiren bir dizi katman içerir. İlk yoğun blok 6 katmandan, ikinci blok 12 katmandan, üçüncü blok 24 katmandan ve dördüncü blok 16 katmandan oluşur. Her yoğun blok içinde, her bir katmanın çıktısı sonraki tüm katmanların girdisi olarak kullanılır. Bu, gradyan akışını iyileştirir ve bilgi kaybını minimuma indirir.
3. **Geçiş katmanları:** Yoğun bloklar arasında yer alan geçiş katmanları, özellik haritalarının boyutlarını azaltarak modelin parametre yükünü kontrol altında tutar. Bu katmanlar, 1x1 konvolüsyon ve 2x2 ortalama havuzlama işlemlerinden oluşur.

4. **Küresel ortalama havuzlama:** Dördüncü yoğun bloktan sonra, modelde küresel ortalama havuzlama işlemi uygulanır. Bu katman, her bir özellik haritasını tek bir skalar değere indirger ve böylece modelin parametre sayısını önemli ölçüde azaltır.
5. **Tam bağlantılı katman ve softmax:** Son olarak, tam bağlantılı bir katman ve softmax işlevi kullanılarak sınıflandırma işlemi gerçekleştirilir. Bu bölüm, modelin hedef veri kümesindeki sınıflandırma görevini yerine getirir.

DenseNet-121'in yenilikçi bağlantı stratejisi, modeli diğer derin öğrenme mimarilerinden ayırır. Geleneksel konvolüsyonel sinir ağlarında her katman, yalnızca bir önceki katmandan bilgi alırken, DenseNet-121'de her katman tüm önceki katmanların çıktısını kullanır. Bu, modelin daha zengin ve genelleştirilebilir özellikler öğrenmesini sağlar.

1. **Gradyan sönmesi sorununun çözümü:** Her katmanın tüm önceki katmanlarla bağlantılı olması, gradyanların ağ boyunca daha etkili bir şekilde yayılmasını sağlar. Bu, özellikle çok derin ağlarda sıkça karşılaşılan gradyan sönmesi sorununu büyük ölçüde ortadan kaldırır.
2. **Parametre verimliliği:** Geleneksel derin öğrenme modellerine kıyasla daha az parametre kullanarak yüksek doğruluk oranları elde eder. Bu, hesaplama kaynaklarının sınırlı olduğu durumlarda önemli bir avantajdır.
3. **Daha iyi özellik öğrenimi:** Her bir katmanın önceki tüm katmanlardan bilgi alması, modelin daha karmaşık ve zengin özellikler öğrenmesini sağlar.
4. **Yüksek performans:** DenseNet-121, ImageNet gibi büyük ölçekli veri setlerinde üstün performans göstermiştir. Bu, modelin pratik uygulamalarda güvenilirliğini artırır.

DenseNet-121, tıbbi görüntüleme, otonom sürüş, doğal dil işleme ve birçok başka alanda yaygın olarak kullanılmaktadır. Özellikle sınırlı veri setleri ile çalışılan durumlarda, bilgi paylaşımını optimize eden yapısı sayesinde etkili bir çözüm sunar. DenseNet-121 mimarisi ait görüntü Şekil 3.2'de verilmiştir.



Şekil 3.2. DenseNet121 Mimarisi Tareq vd. (2022)

### 3.2.5. DenseNet169 mimarisi

DenseNet-169, derin sinir ağı tasarımında derinlik ve verimliliği birleştiren güçlü bir mimaridir. Adını toplamda 169 katmandan oluşmasından alan bu model, özellikle büyük veri setleriyle çalışırken yüksek doğruluk oranları sağlamasıyla bilinir. DenseNet mimarilerinin temel yapı taşlarından biri olan "yoğun bağlantılar", DenseNet-169'da da temel bir rol oynar. Bu yapı, her bir katmanın önceki tüm katmanların çıktısını giriş olarak kullanmasına olanak tanır ve böylece bilgi paylaşımını maksimuma çıkarır.

DenseNet-169'un mimarisi şu bölümlerden oluşur:


1. **Giriş katmanı:** İlk katman, 7x7 boyutunda filtrelerle sahip bir konvolüsyon katmanıdır. Bu katman, giriş verilerini işleyerek özellik haritaları üretir. Daha sonra 3x3 maksimum havuzlama işlemi uygulanarak veri boyutları küçültülür. Bu işlemler, hem hesaplama verimliliğini artırır hem de modelin daha soyut özellikler öğrenmesini sağlar.
2. **Yoğun bloklar:** DenseNet-169, toplamda dört yoğun blok içerir. Bu bloklar, sırasıyla 6, 12, 32 ve 32 katmandan oluşur. Her bir yoğun blok, giriş verilerini işleyerek yeni özellik haritaları oluşturur ve bu haritalar, sonraki katmanlar tarafından doğrudan kullanılır. Yoğun blokların bu şekilde düzenlenmesi, modelin bilgi kaybını önler ve öğrenme sürecini hızlandırır.
3. **Geçiş katmanları:** Yoğun bloklar arasında yer alan geçiş katmanları, 1x1 konvolüsyon katmanlarından ve 2x2 ortalama havuzlama işlemlerinden oluşur. Geçiş katmanlarının temel işlevi, özellik haritalarının boyutlarını azaltarak modelin parametre yükünü dengelemektir. Bu sayede model, derinleştikçe hesaplama maliyetlerini kontrol altında tutabilir.

4. **Küresel ortalama havuzlama:** Dördüncü yoğun bloktan sonra küresel ortalama havuzlama işlemi uygulanır. Bu katman, her bir özellik haritasını tek bir skalar değere indirger ve böylece modelin parametre sayısını önemli ölçüde azaltır.
5. **Tam bağlantılı katman ve softmax:** Son aşamada, tam bağlantılı bir katman ve softmax işlevi kullanılarak sınıflandırma işlemi gerçekleştirilir. Bu bölüm, modelin belirli bir veri setindeki sınıflandırma görevlerini yerine getirmesini sağlar.

DenseNet-169'un Avantajları

1. **Yüksek parametre verimliliği:** DenseNet-169, yoğun bağlantıları sayesinde geleneksel ağlara kıyasla daha az parametre ile çalışır. Bu, sınırlı hesaplama kaynaklarına sahip ortamlar için önemli bir avantajdır.
2. **Gradyan sönmesi sorununun önlenmesi:** Her bir katmanın önceki tüm katmanlarla bağlantılı olması, gradyanların ağ boyunca daha etkili bir şekilde yayılmasını sağlar. Bu, derin ağlarda sıkça görülen gradyan sönmesi sorununu büyük ölçüde ortadan kaldırır.
3. **Daha iyi özellik öğrenimi:** Yoğun bağlantılar, her bir katmanın daha zengin ve genelleştirilebilir özellikler öğrenmesini sağlar. Bu, modelin özellikle büyük ölçekli veri setleri üzerinde daha iyi performans göstermesine olanak tanır.
4. **Esneklik ve uygulanabilirlik:** DenseNet-169, medikal görüntüleme, otonom araçlar ve doğal dil işleme gibi çeşitli uygulama alanlarında başarılı bir şekilde kullanılabilir. Modelin farklı veri türlerine kolayca uyarlanabilir olması, uygulama çeşitliliğini artırır.

DenseNet-169, derin öğrenme modellerinin performans ve verimlilik gereksinimlerini dengeleyen bir mimaridir. Özellikle büyük ölçekli sınıflandırma problemlerinde yüksek doğruluk oranları sağlayarak güvenilir bir çözüm sunar. Ayrıca, modeli oluşturan yoğun bloklar ve geçiş katmanları, tasarımın hem basit hem de etkili olmasını sağlar. DenseNet169 modelin mimarisi Şekil 3.3'te gösterilmiştir.



Şekil 3.3. DenseNet169 Mimarisi Abdalla vd. (2022)


### 3.2.6. DenseNet201 mimarisi

DenseNet201 (Dense Convolutional Network), derin sinir ağlarının daha etkili bir şekilde öğrenmesi ve parametre etkinliği sağlaması amacıyla önerilen bir mimaridir. Bu mimari, her katmanın tüm önceki katmanlarla doğrudan bağlantılı olduğu bir tasarım sunar. DenseNet, özellikle derin öğrenme modellerinde sıkça karşılaşılan bilgi kaybı ve gradyan sönmesi sorunlarına çözüm sunar. Yoğun bağlantılı yapısı sayesinde bilgi akışını ve gradyanların yayılmasını iyileştirir, böylece daha az parametre ile daha verimli bir eğitim sağlar Huang vd. (2017). DenseNet-201, çok çeşitli uygulamalarda kullanılabilirliği ve üstün performansı ile dikkat çeken bir derin öğrenme modelidir. Bu modelin uygulama alanları aşağıdaki gibi özetlenebilir:

1. **Tıbbi görüntüleme:** DenseNet-201, medikal görüntüleme alanında yaygın olarak kullanılmaktadır. Örneğin, manyetik rezonans görüntüleme (MRI) veya bilgisayarlı tomografi (CT) gibi tıbbi veriler üzerinde anormallikleri tespit etmek için kullanılır. Modelin yoğun bağlantıları, sınırlı tıbbi veriyle bile yüksek doğruluk oranları elde edilmesini sağlar. Özellikle tümör teşhisi veya organ segmentasyonu gibi karmaşık görevlerde etkili sonuçlar vermektedir.
2. **Otonom araçlar:** DenseNet-201, otonom araçların çevresel algılama sistemlerinde kullanılmaktadır. Model, yol işaretleri, yayalar ve diğer araçlar gibi çevresel unsurları tanımlayarak güvenli sürüş deneyimi sağlar. Otonom araçlarda hızla değişen veri akışını işlemeye uygun bir yapıya sahiptir.
3. **Doğal dil işleme (NLP):** DenseNet-201, doğal dil işleme görevlerinde de etkili bir şekilde kullanılabilir. Özellikle metin sınıflandırma, duygu analizi ve dil modeli oluşturma gibi alanlarda başarıyla uygulanır. Modelin özellikleri, dil verilerinin derinlemesine işlenmesini mümkün kılar.

4. **Endüstriyel görüntü analizi:** DenseNet-201, üretim hatlarındaki kalite kontrol süreçlerinde kullanılır. Ürünlerdeki kusurların tespiti veya sınıflandırılması gibi görevlerde yüksek doğruluk sağlar. Model, özellikle karmaşık ve çeşitli özelliklere sahip ürünlerin analizinde başarılıdır.
5. **Finansal analiz:** DenseNet-201, finans sektöründe sahtecilik tespiti ve risk analizi gibi görevlerde uygulanabilir. Örneğin, finansal işlemler üzerindeki anomalileri tespit etmek için modelin güçlü öğrenme kapasitesinden faydalanılır.
6. **Tarım ve çevre izleme:** DenseNet-201, bitki sağlığı izleme, zararlı tespiti ve çevresel değişikliklerin analizi gibi tarım ve çevre uygulamalarında kullanılmaktadır. Model, karmaşık görüntü verilerini işleyerek çiftçilere ve çevre uzmanlarına değerli bilgiler sunar.
7. **Güvenlik ve gözetim:** DenseNet-201, yüz tanıma ve davranış analizi gibi güvenlik görevlerinde kullanılabilir. Özellikle kalabalık alanlarda anormalliklerin tespiti veya bireylerin izlenmesi gibi kritik uygulamalarda modelin etkinliği öne çıkar.

DenseNet-201, yüksek doğruluk oranları ve parametre verimliliği ile çeşitli endüstrilerde güçlü bir araç olarak kullanılmaktadır. Modelin esnek yapısı, farklı veri türlerine ve uygulama senaryolarına kolayca uyarlanabilir olmasını sağlamaktadır. Özellikle sınırlı veri ve kaynaklarla çalışan alanlarda modelin etkinliği daha da ön plana çıkmaktadır.



Şekil 3.4. DenseNet201 Mimarisi Akhtar vd. (2022)

### 3.2.7. DenseNet264 mimarisi

DenseNet (Dense Convolutional Network), derin sinir ağlarının daha etkili bir şekilde öğrenmesi ve parametre etkinliği sağlaması amacıyla önerilen bir mimaridir. Bu mimari, her katmanın tüm önceki katmanlarla doğrudan bağlantılı olduğu bir tasarım sunar. DenseNet, özellikle derin öğrenme modellerinde sıkça karşılaşılan bilgi kaybı ve gradyan sönmesi sorunlarına çözüm sunar. Yoğun bağlantılı yapısı sayesinde bilgi akışını ve gradyanların yayılmasını iyileştirir, böylece daha az parametre ile daha verimli bir eğitim sağlar Huang vd. (2017). DenseNet-264, DenseNet mimarisinin en derin varyantlarından biridir ve toplamda 264 katmandan oluşur. Bu mimari, özellikle büyük ve karmaşık veri setlerinde yüksek doğruluk oranları elde etmek için tasarlanmıştır. Yoğun bağlantıları ve katman derinliği, modelin yüksek seviyeli özellikleri öğrenme kapasitesini artırırken, parametre etkinliğini korur.

DenseNet-264'ün yapısal özellikleri şunlardır:


1. **Giriş katmanı:** Model, 7x7 konvolüsyon filtrelerine sahip bir giriş katmanı ile başlar. Bu katman, giriş verilerinin düşük seviyeli özelliklerini çıkarmak için kullanılır. Ardından, 3x3 maksimum havuzlama işlemi gerçekleştirilerek veri boyutları küçültülür. Bu adım, hem hesaplama maliyetini azaltır hem de daha soyut özelliklerin öğrenilmesini sağlar.
2. **Yoğun bloklar:** DenseNet-264, toplamda dört yoğun bloktan oluşur. Bu bloklar sırasıyla 6, 12, 64 ve 48 katmandan meydana gelir. Her yoğun blok, giriş verilerini işleyerek özellik haritaları oluşturur ve bu haritalar, sonraki katmanlar tarafından doğrudan kullanılır. Bloklar arasındaki bağlantılar, modelin bilgi paylaşımını optimize eder ve öğrenme sürecini hızlandırır.
3. **Geçiş katmanları:** Yoğun bloklar arasında geçiş katmanları bulunur. Bu katmanlar, özellik haritalarının boyutlarını küçültmek ve ağır parametre yükünü dengelemek için kullanılır. Geçiş katmanları, 1x1 konvolüsyon ve 2x2 ortalama havuzlama işlemlerinden oluşur.
4. **Küresel ortalama havuzlama:** Son yoğun bloktan sonra, model küresel ortalama havuzlama işlemi uygular. Bu işlem, her bir özellik haritasını tek bir skalar değere indirger. Bu, modelin parametre sayısını önemli ölçüde azaltır ve aşırı uyum riskini minimize eder.
5. **Tam bağlantılı katman ve softmax:** Modelin son aşamasında, tam bağlantılı bir katman ve softmax işlevi kullanılarak sınıflandırma işlemi gerçekleştirilir.

Softmax, modelin çıktılarını belirli bir sınıfa yönelik olasılıklar olarak temsil eder.

DenseNet-264'ün Avantajları

1. **Üstün performans:** DenseNet-264, ImageNet gibi büyük veri setlerinde yüksek doğruluk oranları sağlar. Derin mimarisi, özellikle karmaşık görevlerde etkili bir performans sunar.
2. **Gradyan sönmesini önleme:** Yoğun bağlantılar, gradyanların ağ boyunca daha etkili bir şekilde yayılmasını sağlar. Bu, derin ağlarda sıklıkla karşılaşılan gradyan sönmesi sorununu ortadan kaldırır.
3. **Parametre verimliliği:** Modelin yoğun bağlantıları, geleneksel konvolüsyonel sinir ağlarına kıyasla daha az parametreyle daha yüksek performans elde etmesini sağlar. Bu, hesaplama kaynaklarının sınırlı olduğu durumlarda önemli bir avantajdır.
4. **Uygulama çeşitliliği:** DenseNet-264, tıbbi görüntüleme, otonom araçlar, doğal dil işleme ve endüstriyel kalite kontrol gibi çeşitli uygulamalarda kullanılabilir. Modelin esnek yapısı, farklı veri türlerine kolayca uyarlanmasını sağlar.
5. **Daha iyi özellik öğrenimi:** Modelin yoğun bağlantıları, katmanlar arasında bilgi paylaşımını optimize ederek daha zengin ve genelleştirilebilir özelliklerin öğrenilmesini sağlar.

DenseNet-264, derin öğrenme modellerinin karmaşıklığını artırırken parametre etkinliğini koruyan yenilikçi bir mimaridir. Büyük ölçekli sınıflandırma ve segmentasyon problemleri için güçlü bir araç olan bu model, modern derin öğrenme araştırmalarında ve uygulamalarında önemli bir yere sahiptir. DenseNet 264 mimarisi Şekil 3.5'te verilmiştir.



Şekil 3.4. DenseNet264 Mimarisi Narmatha (2023)

### 3.2.8. Evrişimsel sinir ağları (Convolutional Neural Networks - CNN)

Evrişimsel Sinir Ağları (CNN), özellikle görüntü işleme ve bilgisayarla görme uygulamaları için tasarlanmış bir derin öğrenme mimarisidir. CNN'ler, veri üzerinde uzamsal bağıntıları öğrenerek yüksek doğruluk oranlarına ulaşır. Bu ağlar, veriyi işlemek için evrişim katmanları, havuzlama katmanları ve tam bağlantılı katmanlardan oluşan bir yapı kullanır. CNN'lerin temel özellikleri ve yapısal bileşenleri şu şekilde özetlenebilir:

1. **Evrişim katmanları:** CNN'lerin temel yapı taşı olan bu katmanlar, giriş verilerinden özellik haritaları çıkarmak için filtreler kullanır. Bu filtreler, giriş verilerindeki kenarlar, köşeler ve dokular gibi düşük seviyeli özellikleri öğrenir. Her filtre, veriyi farklı bir perspektiften işler ve çıkış olarak bir özellik haritası üretir LeCun vd. (1998).
2. **Aktivasyon fonksiyonları:** Evrişim katmanlarının ardından genellikle ReLU (Rectified Linear Unit) gibi aktivasyon fonksiyonları kullanılır. Bu fonksiyonlar, doğrusal olmayan yapılar oluşturarak ağın daha karmaşık ilişkileri öğrenmesini sağlar.
3. **Havuzlama katmanları:** Havuzlama katmanları, giriş verisinin boyutlarını azaltarak ağın parametrelerini ve hesaplama yükünü düşürür. Maksimum havuzlama (max-pooling) ve ortalama havuzlama (average-pooling) gibi

yöntemler, özellik haritalarının en belirgin bileşenlerini koruyarak bilgi kaybını minimize eder.

4. **Tam bağlantılı katmanlar:** CNN'in son aşamasında bulunan bu katmanlar, sınıflandırma görevleri için kullanılır. Evrişim ve havuzlama katmanlarından gelen bilgiler bu katmanda birleştirilir ve ağın çıktısı elde edilir.
5. **Softmax katmanı:** Çıkış katmanında bulunan softmax fonksiyonu, ağın tahminlerini olasılıklara dönüştürür. Bu, sınıflandırma görevlerinde ağın hangi sınıfa daha yüksek olasılıkla ait olduğunu belirlemesini sağlar.

CNN'lerin Avantajları

1. **Otomatik özellik çıkarımı:** Geleneksel yöntemlerden farklı olarak, CNN'ler verilerden özellikleri manuel müdahale olmadan çıkarır. Bu, özellikle büyük ve karmaşık veri setleri üzerinde çalışırken önemli bir avantaj sağlar.
2. **Parametre verimliliği:** CNN'lerin evrişim filtreleri, görüntülerdeki uzamsal ilişkileri daha az parametre kullanarak öğrenir. Bu, hesaplama maliyetlerini düşürürken doğruluk oranlarını artırır.
3. **Uygulama çeşitliliği:** CNN'ler, görüntü işleme, ses analizi, metin sınıflandırma ve daha birçok alanda başarıyla kullanılabilir. Özellikle nesne algılama, yüz tanıma ve doğal dil işleme gibi görevlerde ön plana çıkar.

Uygulama Alanları

1. **Tıbbi görüntüleme:** CNN'ler, röntgen, MRI ve CT taramaları gibi tıbbi görüntüler üzerinde hastalık teşhisi ve anormallik tespiti için yaygın olarak kullanılmaktadır.
2. **Otonom sürüş:** CNN'ler, otonom araçların çevresel algılama sistemlerinde, özellikle yol işaretlerinin ve diğer araçların tanımlanmasında kullanılır.
3. **Güvenlik sistemleri:** Yüz tanıma ve davranış analizi gibi güvenlik uygulamaları CNN'lerin başlıca kullanım alanlarındanıdır.
4. **Sanat ve eğlence:** CNN'ler, görüntü stil transferi, video oyunları ve artırılmış gerçeklik uygulamalarında da kullanılır.

Evrişimsel Sinir Ağları, esnek ve güçlü yapıları sayesinde modern yapay zeka uygulamalarının temel taşlarından biri haline gelmiştir. Özellikle görüntü işleme görevlerindeki başarısı, CNN'lerin hem akademik araştırmalarda hem de endüstriyel uygulamalarda yaygın olarak kullanılmasını sağlamaktadır.

### 3.2.9. CNN katman mimarisi

Convolutional Neural Networks (CNN), bir görüntüden özellikleri çıkarmak ve bunları sınıflandırma gibi görevler için kullanmak üzere tasarlanmış çok katmanlı bir yapıdır. CNN mimarisindeki her katman, belirli bir işlevi yerine getirir ve bir sonraki katmana anlamlı veriler sağlar. Bu bölümde, CNN'in temel katmanları olan Evrişim Katmanı, Aktivasyon Katmanı, Havuzlama Katmanı ve Tam Bağlantılı Katman matematiksel ifadelerle birlikte detaylandırılacaktır.

#### 3.2.9.1. Evrişim katmanı (Convolution Layer)

Evrişim katmanı, CNN'in temel yapı taşıdır. Bu katman, bir görüntüden özellikleri çıkarmak için bir filtre veya çekirdek (kernel) matrisi uygular. Evrişim işlemi, görüntüdeki lokal özellikleri algılar ve bir özellik haritası (feature map) üretir. Bir evrişim işlemi şu şekilde tanımlanır:

$$Y[i, j] = \sum_{m=0}^{k-1} \sum_{n=0}^{k-1} X[i + m, j + n] \cdot K[m, n] + b \quad (3.1)$$

Burada

- $X[i, j]$ : Giriş görüntüsündeki piksel değeri
- $K[m, n]$ :  $k \times k$  Boyutundaki çekirdek (kernel) matrisi
- $Y[i, j]$ : Çıkış özellik haritasındaki değer
- $b$ : Biaslık (bias)
- $k$ : Çekirdek boyutu (örneğin  $3 \times 3$  veya  $5 \times 5$ )

#### Açıklama:

- Çekirdek matrisi, görüntü üzerinde kayan bir pencere gibi hareket eder (kaydırma işlemi), ve her bir konumda giriş görüntüsü ile çekirdeğin elemanları çarpılarak toplanır.
- Bu işlem, kenar algılama, desen tespiti veya nesne konturunun belirlenmesi gibi temel özellikleri çıkarır.
- Çekirdek boyutu ve adım sayısı (stride) gibi hiperparametreler, özellik haritasının boyutunu belirler LeCun vd. (1998).

**Çıkış boyutu hesabı:** Eğer Giriş görüntüsü boyutu  $W \times H$  , çekirdek boyutu  $k$ , adım sayısı  $s$ , ve sıfır dolgusu  $p$  ise çıkış boyutu şu şekilde hesaplanır:

$$\text{Çıkış Boyutu} = \left( \frac{W+2p-k}{s} \right) \times \left( \frac{H+2p-k}{s} \right) + 1 \quad (3.2)$$

### 3.2.9.2. Aktivasyon katmanı

Aktivasyon katmanı, evrişim katmanından gelen çıktıların doğrusal olmayan bir dönüşüme tabi tutulduğu katmandır. Aktivasyon fonksiyonları, modelin karmaşık ilişkileri öğrenmesine olanak tanır. En Yaygın Aktivasyon Fonksiyonları:

**ReLU (Rectified Linear Unit):**

$$f(x) = \max(0, x) \quad (3.3)$$

Negatif değerleri sıfıra eşitler ve pozitif değerleri olduğu gibi bırakır. ReLU, hesaplama açısından verimli ve yaygın olarak kullanılan bir fonksiyondur Krizhevsky vd. (2012).

**Sigmoid :**

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.4)$$

Çıkışı 000 ile 111 arasında sıkıştırır. Genellikle sınıflandırma katmanlarında kullanılır Goodfellow vd. (2016).

**Tanh:**

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.5)$$

Çıkışı  $[-1,1]$  arasında sıkıştırır ve veriyi merkezler. Tanh, bazı durumlarda sigmoidden daha iyi performans gösterir LeCun vd. (1998).

### 3.2.9.3. Havuzlama katmanı (Pooling Layer)

Havuzlama katmanı, özellik haritalarının boyutunu küçültürken bilgi yoğunluğunu korur. Bu katman, hesaplama maliyetini düşürür ve genelleme kapasitesini artırır. Havuzlama Türleri:

**Maksimum havuzlama(Max Pooling)**

$$Y[i, j] = \max (X[i : i + k, j : j + k]) \quad (3.6)$$

Belirli bir bölgedeki maksimum değeri alır. Kenarlar ve önemli desenleri korumada etkilidir.

### Ortalama havuzlama (Average Pooling)

$$Y[i, j] = \frac{1}{k^2} \sum_{m=0}^{k-1} \sum_{n=0}^{k-1} X[i + m, j + n] \quad (3.7)$$

Belirli bir bölgedeki değerlerin ortalamasını alır. Daha yumuşak çıktılar sağlar.

**Çıkış boyutu hesabı:** Giriş boyutu  $W \times H$ , havuzlama boyutu  $k \times k$ , adım sayısı  $s$  ve dolgu(padding) miktarı  $p$  ile tanımlandığında:

$$\text{Çıkış Boyutu} = \left( \frac{W+2p-k}{s} + 1 \right) \times \left( \frac{H+2p-k}{s} + 1 \right) \quad (3.8)$$

### 3.2.9.4. Tam bağlantılı katman (Fully Connected Layer)

Tam bağlantılı katman, çıkarılan özelliklerin bir sınıflandırma problemde kullanılmak üzere işlenmesini sağlar. Bu katmanda her nöron, bir önceki katmandaki tüm nöronlarla bağlantılıdır.

$$y = f(W \cdot x + b) \quad (3.9)$$

Burada:

- $x$ : Giriş Vektörü
- $W$ : Ağırlık Matrisi
- $b$ : Biaslık (bias) terimi
- $f$ :Aktivasyon fonksiyonu

**Softmax fonksiyonu:** Tam bağlantılı katmanın çıktısı genellikle softmax fonksiyonuyla normalize edilir:

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^N e^{z_j}} \quad (3.10)$$

Burada:

- $z_i$ :  $i$ -inci sınıfa ait skor
- $P(y_i)$ :  $i$ - inci sınıfa ait olasılık

Softmax modelin her sınıfa ait olasılığı tahmin etmesini sağlar ve çok sınıflı sınıflandırma problemlerinde yaygın olarak kullanılır Goodfellow vd. (2016).

### 3.2.10. Performans ölçütleri

Convolutional Neural Networks (CNN) gibi derin öğrenme modellerinin performansını değerlendirmek için kullanılan metrikler, sınıflandırma, regresyon, nesne algılama gibi farklı görev türlerine bağlı olarak çeşitlilik gösterir. Bu metrikler, modelin doğru tahmin yapma yeteneğini, hatalarını ve genelleme kapasitesini değerlendirmek için kullanılır. Aşağıda, sınıflandırma ve nesne algılama görevlerinde kullanılan temel performans ölçütleri detaylı bir şekilde açıklanmış ve matematiksel ifadelerle verilmiştir.

**Doğruluk (Accuracy):** Doğruluk, modelin doğru sınıflandırma oranını ifade eder. Tüm doğru tahminlerin, toplam tahminlere oranıdır.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.11)$$

Burada:

- TP: Doğru Pozitif (True Positive)
- TN: Doğru Negatif (True Negative)
- FP: Yanlış Pozitif (False Positive)
- FN: Yanlış Negatif (False Negative)

**Hassasiyet (Precision):** Hassasiyet, modelin pozitif tahminlerinde ne kadar isabetli olduğunu ölçer. Yanlış pozitiflerin etkisini azaltır.

$$Precision = \frac{TP}{TP+FP} \quad (3.12)$$

**Duyarlılık (Recall) veya true positive Rate (TPR):** Duyarlılık, gerçek pozitiflerin ne kadarının doğru sınıflandırıldığını gösterir. Yanlış negatiflerin etkisini ölçer.

$$Precision = \frac{TP}{TP+FP} \quad (3.13)$$

**F1-Skoru:** F1-Skoru, hassasiyet ve duyarlılık arasındaki dengeyi ölçer. İki metriğin harmonik ortalamasıdır.

$$F1 - Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (3.14)$$

**Alıcı işletim karakteristiği (ROC) eğrisi ve AUC:** ROC eğrisi, farklı eşik değerlerinde duyarlılık (Recall) ve yanlış pozitif oranını (FPR) görselleştirir. Eğri altında kalan alan (AUC), modelin ayrıştırma yeteneğini gösterir.

$$FPR = \frac{FP}{FP+TN} \quad (3.15)$$

CNN'in performansını deęerlendirirken kullanılan metrikler, grev trne ve veri setine baęlı olarak seilmelidir. Dengeli veri setlerinde doęruluk (accuracy) yeterli olabilirken, dengesiz veri setlerinde F1-Skoru, ROC eęrisi ve karmaşıklık matrisi gibi metrikler daha anlamlı sonular sunar.

#### 4. BULGULAR

Bu tez çalışmasında, yaş tahmini için Hintli aktörlere ait yüz görüntülerinin sınıflandırılmasında çeşitli DenseNet modelleri kullanılmıştır. DenseNet modelleri, Derin Sinir Ağlarının (DNN) bir alt kümesi olup, katmanlar arasındaki bağlantıları yoğunlaştırarak bilgi akışını artıran ve parametre sayısını azaltan bir mimaridir. Bu çalışma kapsamında DenseNet-121, DenseNet-169, DenseNet-201 ve DenseNet-264 modelleri eğitilmiş ve test edilmiştir. Bu modeller arasındaki temel fark, her bir modelin sahip olduğu katman sayısıdır. Daha derin modeller (örneğin DenseNet-201 ve DenseNet-264), daha karmaşık özellikleri öğrenme kapasitesine sahipken, daha az katmanlı modeller (örneğin DenseNet-121 ve DenseNet-169), daha hızlı eğitim süreci sunar.

Çalışmada kullanılan DenseNet modelleri, yüz görüntülerinden yaş sınıflandırması gerçekleştirmek için eğitilmiş ve test edilmiştir. DenseNet mimarisi, bilgi akışını artıran yoğun bağlantılar sunarak sınıflandırma performansını iyileştiren bir yöntemdir. Bu çalışmada DenseNet-121, DenseNet-169, DenseNet-201 ve DenseNet-264 modelleri kullanılmıştır. Her bir modelin özellikleri ve veri seti üzerindeki başarısı ayrıntılı olarak değerlendirilmiştir.

DenseNet modellerinin temel yapısı, her katmanın çıktısının, kendisinden sonraki tüm katmanlara giriş olarak aktarılmasına dayanır. Bu yaklaşım, modelin her bir katmanda öğrendiği özelliklerin maksimum düzeyde yeniden kullanılmasını sağlar. Ayrıca parametre sayısının azaltılması, eğitim sürecinde modelin daha hızlı öğrenmesine ve gradyanların kaybolması probleminin büyük ölçüde önlenmesine olanak tanır. Bu avantajlar, DenseNet mimarilerinin, veri çeşitliliği ve sınıflandırma zorluğu yüksek veri setleri üzerinde etkili bir şekilde çalışmasını mümkün kılar.

Eğitim sürecinde, veri setinin çeşitliliği ve geniş kapsamlı etiketleme yapısı, sınıflandırmanın doğruluğunu artırmıştır. Kullanılan IMFDB veri seti, yaş kategorilerinin yanı sıra poz, yüz ifadesi ve cinsiyet gibi ek faktörlerle etiketlenmiştir. Bu çeşitlilik, modelin genelleştirme kapasitesini artırmış ve veri setindeki zorluklara rağmen etkili sonuçlar elde edilmesini sağlamıştır. Ancak, veri setindeki görüntülerin farklı çözünürlüklerde olması ve engelleme gibi faktörlerin bulunması, eğitim sürecinde modele ek bir zorluk getirmiştir. Bu durum, modelin daha derin özellikleri öğrenebilme kapasitesini test etmiştir.

DenseNet-121 ve DenseNet-169 modelleri, daha az katmanlı yapılarıyla hesaplama maliyetini düşürürken, DenseNet-201 ve DenseNet-264 modelleri, daha derin mimarileri sayesinde daha karmaşık özellikleri öğrenme kapasitesine sahip olmuştur. Bu farklılıklar, modellerin veri seti üzerindeki başarısını etkileyen temel unsurlar arasında yer almıştır. Eğitim sırasında kullanılan veri artırma teknikleri, modelin genelleme kapasitesini artırmış ve overfitting riskini azaltmıştır. Özellikle, rastgele yatay çevirme ve normalize etme gibi teknikler, veri setindeki doğal varyasyonların modellenmesine yardımcı olmuştur.

Optimizasyon sürecinde Adam optimizasyon algoritması kullanılmıştır. Bu algoritma, öğrenme hızını adaptif olarak ayarlayarak modelin daha hızlı yakınsama sağlamasına yardımcı olmuştur. CrossEntropyLoss kayıp fonksiyonu, çok sınıflı sınıflandırma problemlerinde yaygın olarak kullanılan bir yöntemdir ve burada da etkili bir şekilde çalışmıştır. Eğitim sürecinde kullanılan 0.001 öğrenme hızı, modelin kararlı bir şekilde öğrenmesine olanak tanımıştır. Mini-batch boyutunun 32 olarak seçilmesi, hem bellek kullanımını optimize etmiş hem de eğitim sürecinin verimli bir şekilde gerçekleştirilmesini sağlamıştır.

Elde edilen bulgular, DenseNet mimarilerinin, yaş sınıflandırması gibi karmaşık görevlerde yüksek başarı elde ettiğini göstermiştir. Modelin seçimi, veri setinin büyüklüğüne ve hesaplama kaynaklarına bağlı olarak değişiklik gösterebilir. Daha az katmanlı modeller hızlı sonuçlar verirken, daha derin modeller karmaşık veri setlerinde daha yüksek doğruluk oranlarına ulaşmıştır. Bu çalışma, yüz sınıflandırma görevlerinde DenseNet modellerinin etkinliğini ortaya koymuş ve benzer sınıflandırma problemlerinde bu mimarilerin kullanımını teşvik etmiştir. DenseNet modelleri ile elde edilen performans oranları Tablo 4.1’de verilmiştir.

| Model       | Accuracy | Precision | Recall | F1-Score |
|-------------|----------|-----------|--------|----------|
| DenseNet121 | %85.3    | 0.86      | 0.84   | 0.85     |
| DenseNet169 | %87.1    | 0.88      | 0.87   | 0.87     |
| DenseNet201 | %89.2    | 0.89      | 0.89   | 0.89     |
| DenseNet264 | %89.8    | 0.90      | 0.90   | 0.90     |

**Tablo 4.1.** DenseNet Modelleri performans değerleri

DenseNet Modelleri Performans Değerleri incelendiğinde, dört farklı DenseNet modelinin yaş sınıflandırması görevindeki başarıları çeşitli metrikler açısından detaylı bir şekilde değerlendirilmiştir. Her bir modelin doğruluk (accuracy), kesinlik

(precision), geri çağırma (recall) ve F1 skoru gibi metriklerde nasıl performans gösterdiği derinlemesine analiz edilmiştir.

DenseNet-121 modeli, temel DenseNet mimarisi içerisinde daha az sayıda katman içeren bir yapı sunar. Bu model, %85.3 doğruluk oranı ile veri setinde başarılı bir performans sergilemiştir.

- **Precision (0.86):** Yanlış pozitiflerin az olduğunu ve modelin pozitif sınıflandırmalarında genel olarak güvenilir olduğunu göstermektedir. Ancak, diğer metriklerle kıyaslandığında precision değeri bir miktar yüksek olmasına rağmen recall değerinin (%84) görece düşük olması, modelin bazı pozitif örnekleri atlama eğiliminde olduğunu düşündürmektedir.
- **Recall (0.84):** Pozitif örneklerin sınıflandırılmasında birkaç eksiklik bulunduğunu gösterir. Model, doğru pozitif örneklerin bir kısmını kaçırmıştır.
- **F1-Score (0.85):** Precision ve recall değerleri arasındaki bu uyum, modelin genel performansının dengeli olduğunu yansıtır. F1 skoru, DenseNet-121'in hafif bir model olarak, özellikle daha hızlı ve hesaplama maliyeti düşük görevler için uygun olduğunu kanıtlamaktadır.

DenseNet-169 modeli, daha fazla katman ile DenseNet-121'e göre daha karmaşık özellikleri öğrenme kapasitesine sahiptir. Bu model, %87.1 doğruluk oranıyla bir önceki modele göre anlamlı bir iyileşme sağlamıştır.

- **Precision (0.88):** Model, yanlış pozitif sınıflandırmalarda daha başarılı bir azalma göstermiştir. Pozitif sınıfların tahmin doğruluğu oldukça yüksektir.
- **Recall (0.87):** Doğru pozitifleri yakalama oranındaki artış, modelin veri setindeki pozitif örnekleri daha güvenilir bir şekilde sınıflandırabildiğini göstermektedir.
- **F1-Score (0.87):** Hem precision hem de recall değerlerinin yüksek ve uyumlu olması, modelin genel performansını yukarı çekmiştir. Bu durum, DenseNet-169'un dengeli bir yapıda yüksek performans sunabileceğini ortaya koymaktadır.

DenseNet-201 modeli, daha derin bir mimari sunarak daha karmaşık veri örüntülerini öğrenme kapasitesine sahiptir. %89.2 doğruluk oranıyla, önceki iki modele kıyasla belirgin bir üstünlük sağlamıştır.


- **Precision (0.89):** Pozitif sınıflarda çok az hata yapıldığı ve modelin güvenilir tahminlerde bulunduğu görülmektedir.

- **Recall (0.89):** Pozitif örneklerin büyük çoğunluğunu doğru bir şekilde sınıflandırma başarısı dikkat çekmektedir. Bu durum, modelin genelleme kapasitesinin yüksek olduğunu göstermektedir.
- **F1-Score (0.89):** Precision ve recall arasında mükemmel bir denge sağlanmıştır. DenseNet-201, veri setindeki çeşitlilik ve zorluklar göz önüne alındığında oldukça etkili bir model olarak öne çıkmaktadır.

DenseNet-264 modeli, en fazla katmana sahip olan ve dolayısıyla en karmaşık örüntüleri öğrenme kapasitesine sahip olan modeldir. %89.8 doğruluk oranıyla en yüksek başarıyı sağlamıştır.

- **Precision (0.90):** Yanlış pozitif sınıflandırmaların minimumda olduğunu ve pozitif sınıfların oldukça doğru bir şekilde tahmin edildiğini göstermektedir.
- **Recall (0.90):** Pozitif örneklerin neredeyse tamamı doğru bir şekilde sınıflandırılmıştır. Bu durum, DenseNet-264'ün tüm veri setinde etkili bir şekilde öğrenme gerçekleştirdiğini ortaya koymaktadır.
- **F1-Score (0.90):** Bu model, tüm metrikler açısından en yüksek değerlere ulaşmış ve DenseNet serisinde en başarılı model olarak öne çıkmıştır. Ancak, bu başarı, daha fazla hesaplama maliyeti ve eğitim süresi gerektirdiği için, bu modelin seçimi uygulama amacına ve hesaplama kaynaklarına bağlıdır.

Tablodaki değerler, modeller arasında katman sayısının artışıyla birlikte performansta anlamlı bir iyileşme olduğunu göstermektedir. DenseNet-121, düşük hesaplama maliyetiyle hızlı sonuçlar sunarken, DenseNet-264 daha yüksek doğruluk, precision, recall ve F1 skoru değerleriyle öne çıkmıştır. DenseNet-169 ve DenseNet-201, performans ve hesaplama maliyeti arasında dengeli bir çözüm sunan modeller olarak değerlendirilebilir. Model seçimi, uygulamanın gereksinimlerine, hesaplama kaynaklarına ve veri setinin zorluk seviyesine göre yapılmalıdır. Modellere ait kayıp(loss) ve başarı grafikler Şekil 4.1.'de verilmiştir.



**Şekil 4.1.** DenseNet modeller kayıp ve başarı grafikleri. (A) DenseNet121, (B) DenseNet169, (C) DenseNet201, (D) DenseNet264 modeller

Şekil 4.1'e bakıldığında; DenseNet-121 modelinin loss ve accuracy grafikleri, modelin hızlı bir şekilde yakınsama sağladığını ve eğitim sürecinde oldukça düşük kayıplara ulaştığını göstermektedir.

- **Eğitim kayıpları:** Eğitim kayıpları grafikte hızlı bir azalma göstermekte ve yaklaşık 20. epoch civarında neredeyse sabit bir değere ulaşmaktadır. Bu durum, modelin eğitim verilerini çok iyi öğrendiğini göstermektedir.
- **Test kayıpları:** Test kayıplarının başlangıçta azaldığı ancak daha sonra dalgalanarak artış gösterdiği gözlenmiştir. Bu durum, DenseNet-121'in erken epoch'larda genelleme kapasitesinin yüksek olduğunu, ancak eğitim sürecinin ilerleyen aşamalarında **overfitting** (aşırı öğrenme) eğilimi gösterdiğini düşündürmektedir.
- **Doğruluk:** Eğitim doğruluğu çok yüksek bir seviyeye (%99+) ulaşmış, ancak test doğruluğu %85 civarında sabitlenmiştir. Bu durum, modelin eğitim verisini çok iyi öğrenirken test verisinde aynı başarıyı sağlayamadığını, yani genelleme kapasitesinin sınırlı olduğunu göstermektedir.
- **Genel değerlendirme:** DenseNet-121 hızlı yakınsama sağlamakta ve eğitim süreci açısından verimli bir model sunmaktadır. Ancak, test kayıplarındaki artış

ve doğruluk seviyesindeki sınırlı iyileşme, modelin daha karmaşık veri örüntülerini öğrenme kapasitesinin sınırlı olduğunu işaret etmektedir.

DenseNet-169 modelinin grafikleri, DenseNet-121'e kıyasla daha dengeli bir öğrenme süreci sunduğunu göstermektedir.

- **Eğitim kayıpları:** Eğitim kayıpları hızlı bir şekilde azalmış ve yaklaşık 30. epoch'tan itibaren düşük bir değerde sabitlenmiştir. Eğitim kayıplarının DenseNet-121'e benzer bir şekilde düşük seviyelere inmesi, modelin eğitim verisini etkili bir şekilde öğrendiğini göstermektedir.
- **Test kayıpları:** Test kayıpları grafikte belirgin dalgalanmalar göstermesine rağmen genel olarak azalma eğilimindedir. Bu durum, DenseNet-169'un genelleme kapasitesinin DenseNet-121'e kıyasla daha iyi olduğunu göstermektedir.
- **Doğruluk:** Eğitim doğruluğu %99 seviyesine ulaşmıştır. Test doğruluğu ise yaklaşık %87 seviyesinde sabitlenmiştir. Bu, modelin test verisinde daha iyi genelleme yaptığını ve eğitimde öğrenilen bilgiyi test verisine daha iyi uyguladığını göstermektedir.
- **Genel değerlendirme:** DenseNet-169, eğitim kayıplarını minimize ederken test doğruluğunda DenseNet-121'e göre daha iyi sonuçlar sunmaktadır. Ancak, test kayıplarındaki dalgalanmalar ve yüksek doğruluğa rağmen bir miktar overfitting gözlemlenebilir.

DenseNet-201 modelinin grafikleri, daha derin bir mimarinin avantajlarını ve eğitim sürecindeki kararlılığı ortaya koymaktadır.

- **Eğitim kayıpları:** Eğitim kayıpları, önceki modellerde olduğu gibi hızlı bir şekilde azalmış ve oldukça düşük bir seviyeye ulaşmıştır. Eğitim sürecinde modelin, eğitim verisini çok iyi öğrenebildiği açıkça görülmektedir.
- **Test kayıpları:** Test kayıpları, önceki iki modele göre daha düşük seviyelere inmiş ve daha az dalgalanma göstermiştir. Bu, DenseNet-201'in daha güçlü bir genelleme kapasitesine sahip olduğunu göstermektedir.
- **Doğruluk:** Eğitim doğruluğu, %99 seviyelerine ulaşırken test doğruluğu %89 civarında sabitlenmiştir. DenseNet-201, test doğruluğu açısından önceki modellere göre daha iyi sonuçlar sunmaktadır ve bu doğruluk seviyesi, modelin

karmaşık veri örüntülerini öğrenme kapasitesinin yüksek olduğunu göstermektedir.


- **Genel değerlendirme:** DenseNet-201, eğitim ve test verileri üzerinde oldukça iyi sonuçlar elde etmiş ve genelleme kapasitesini kanıtlamıştır. Test kayıplarındaki kararlılık ve doğruluk seviyesindeki artış, bu modelin daha karmaşık veri setlerinde etkili bir şekilde çalışabileceğini göstermektedir.

DenseNet-264 modelinin grafikleri, en derin mimarinin sunduğu avantajları ve zorlukları yansıtmaktadır.

- **Eğitim kayıpları:** Eğitim kayıpları, diğer modellere benzer şekilde hızlı bir şekilde azalmış ve oldukça düşük bir seviyeye ulaşmıştır. Modelin, eğitim verisini etkili bir şekilde öğrendiği açıkça görülmektedir.
- **Test kayıpları:** Test kayıpları, genel olarak düşük bir seviyede sabitlenmiştir. Ancak zaman zaman dalgalanmalar gözlemlenmiştir. Bu dalgalanmalar, modelin daha karmaşık veri örüntülerini öğrenirken zaman zaman genelleme sorunları yaşadığını gösterebilir.
- **Doğruluk:** Eğitim doğruluğu %99 seviyesindedir. Test doğruluğu ise %89.8 ile en yüksek seviyeye ulaşmıştır. DenseNet-264, test doğruluğu açısından en başarılı modeldir ve genelleme kapasitesinin oldukça yüksek olduğunu göstermektedir.
- **Genel değerlendirme:** DenseNet-264, eğitim ve test süreçlerinde en yüksek performansı sergilemiştir. Ancak bu model, daha derin yapısı nedeniyle daha fazla hesaplama gücü gerektirmekte ve eğitim süreci daha uzun sürmektedir.

Grafiklerin detaylı analizi, DenseNet modellerinin eğitim ve test süreçlerinde belirgin farklılıklar sunduğunu göstermektedir. Daha derin modeller, genellikle daha yüksek doğruluk oranlarına ulaşmakta ve daha iyi genelleme kapasitesine sahip olmaktadır. Ancak bu modellerin hesaplama maliyetleri ve eğitim süreleri daha yüksek olabilir. Modeller arasında seçim yaparken, genelleme kapasitesi, doğruluk ve eğitim süresi gibi faktörlerin dikkate alınması önemlidir. DenseNet-264, en yüksek test doğruluğunu (%89.8) sunarken, DenseNet-121 hızlı sonuçlar elde etmek için uygun bir alternatif olarak değerlendirilebilir.

DenseNet-121, DenseNet-169, DenseNet-201, ve DenseNet-264 modellerine ait karışıklık matrislerinin aşağıda detaylı analizi sunulmuştur. Her bir matris, modellerin sınıflandırma performansını üç yaş kategorisinde (Middle, Old, Young) nasıl gerçekleştirdiğini göstermektedir. Modellere ait karışık matrisleri ise Şekil 4.2’de verilmiştir.



Şekil 4.2. DenseNet modeller karışıklık matrisleri. (A) DenseNet121, (B) DenseNet169, (C) DenseNet201, (D) DenseNet264 modeller

DenseNet-121 modeli, ilk aşamada dengeli bir sınıflandırma sunmasına rağmen, genelleme kapasitesinde bazı sınırlamalara sahiptir.

- **Middle:** Orta yaş grubu için 2952 doğru sınıflandırma gerçekleştirilmiştir. Ancak, 107 yanlış tahminle yaşlı ve 174 yanlış tahminle genç olarak sınıflandırılmıştır. Orta yaş grubu genel olarak başarılı sınıflandırılmıştır.
- **Old:** Yaşlı kategorisinde 560 doğru tahmin yapılmış, ancak 163 örnek orta yaş ve 14 örnek genç olarak sınıflandırılmıştır. Bu, yaşlı kategorideki karışıklığın belirgin olduğunu göstermektedir.

- **Young:** Genç kategoride 1672 doğru sınıflandırma yapılmıştır. Ancak genç bireylerin 301'i orta yaş olarak sınıflandırılmıştır ve bu grup için karışıklık nispeten yüksektir.

DenseNet-169 modeli, doğruluk oranını artırmış ve kategoriler arasındaki karışıklığı azaltarak daha dengeli bir performans göstermiştir.

- **Middle:** Orta yaş kategorisi için 2884 doğru sınıflandırma yapılmıştır. Hatalı tahminler, 89 yaşlı ve 220 genç örnek olarak sınıflandırma şeklinde görülmüştür.
- **Old:** Yaşlı kategorisinde 545 doğru tahmin gerçekleştirilmiş, ancak 139 orta yaş ve 45 genç birey yanlış sınıflandırılmıştır.
- **Young:** Genç kategorideki doğruluk artarak 1749 doğru sınıflandırmaya ulaşmıştır. Hatalı sınıflandırmalar ise azalmış ve yalnızca 288 örnek orta yaş, 13 örnek yaşlı olarak tahmin edilmiştir.

DenseNet-201, daha karmaşık örüntüleri öğrenme kapasitesi sayesinde genç ve yaşlı kategorilerdeki sınıflandırma başarısını artırmıştır.

- **Middle:** Orta yaş grubu için 2801 doğru sınıflandırma yapılmıştır. Yanlış tahminler 128 yaşlı ve 276 genç birey şeklinde gerçekleşmiştir.
- **Old:** Yaşlı kategorideki doğruluk %54 ile önceki modellere benzer bir seviyededir. Yanlış sınıflandırmalar 150 orta yaş ve 45 genç birey olarak yapılmıştır.
- **Young:** Genç kategorisinde doğruluk en yüksek seviyeye ulaşarak 1778 doğru sınıflandırma yapılmıştır. Hatalı sınıflandırmalar 222 orta yaş ve 32 yaşlı birey olarak görülmüştür.

DenseNet-264 modeli, en derin yapısı sayesinde genel doğruluk oranını en yüksek seviyeye çıkarmış, ancak kategoriler arasında sınırlı bir karışıklık gözlemlenmiştir.


- **Middle:** Orta yaş kategorisi için 2891 doğru tahmin yapılmıştır. Hatalı sınıflandırmalar 187 yaşlı ve 229 genç birey şeklinde gerçekleşmiştir.
- **Old:** Yaşlı kategorisi için doğruluk biraz düşerek 519 doğru tahmine ulaşmıştır. Yanlış sınıflandırmalar 138 orta yaş ve 24 genç birey olarak gözlemlenmiştir.
- **Young:** Genç kategorideki doğruluk 1640 doğru tahmin ile diğer modellere göre bir miktar azalmıştır. Hatalı sınıflandırmalar 307 orta yaş ve 37 yaşlı birey olarak gerçekleşmiştir.

DenseNet-121: Dengeli bir başlangıç performansı sunmasına rağmen, özellikle genç kategorisinde yüksek karışıklık gözlenmiştir. DenseNet-169: Genç kategorisindeki doğruluğu artırmış ve yaşlı kategorisindeki karışıklığı önemli ölçüde azaltmıştır.

DenseNet-201: Genç bireylerin sınıflandırmasında en iyi performansı göstermiş ve kategoriler arasındaki dengeyi sağlamıştır. DenseNet-264: Genel doğruluk en yüksek seviyeye çıkmış olsa da genç ve yaşlı kategorilerdeki karışıklık artmıştır.

Her modelin güçlü ve zayıf yönleri, uygulama gereksinimlerine göre değerlendirilerek seçilebilir. Daha derin modeller genellikle daha iyi performans sunar, ancak sınırlı kaynaklar veya hızlı sonuç gereksinimleri durumunda daha hafif modeller tercih edilebilir.

Bir sonraki grafikte DenseNet-121, DenseNet-169, DenseNet-201, ve DenseNet-264 modellerine ait ROC eğrilerinin detaylı analizi verilmiştir. ROC eğrileri, modellerin sınıflandırma performansını ve ayırım yeteneklerini değerlendirmek için kullanılmıştır. Her sınıf için AUC değerleri (eğri altında kalan alan) belirtilmiş ve yorumlanmıştır.



**Şekil 4.3.** DenseNet modellere ait ROC eğrileri. (A) DenseNet121, (B) DenseNet169, (C) DenseNet201, (D) DenseNet264 modeller

Şekil 4.3 detaylı bir şekilde incelendiğinde modeller için aşağıdaki sonuçlara varılmaktadır.

DenseNet-121 modeli, yaş grupları arasında ayırım yapma yeteneği ile güçlü bir başlangıç sunmaktadır.

- **Class MIDDLE (AUC = 0.95):** Orta yaş grubunda AUC değeri oldukça yüksektir ve modelin pozitif örnekleri doğru bir şekilde ayırt edebildiğini göstermektedir. Ancak, diğer sınıflara kıyasla hafif bir performans farkı bulunmaktadır.
- **Class OLD (AUC = 0.97):** Yaşlı kategorisinde AUC değeri en yüksektir ve modelin yaşlı bireyleri sınıflandırmadaki başarısını yansıtmaktadır.
- **Class YOUNG (AUC = 0.97):** Genç kategoride ayırım yeteneği yaşlı kategorisine benzer şekilde oldukça güçlüdür.

**Sonuç:** DenseNet-121, yaşlı ve genç kategorilerde güçlü bir performans sergilemekte, orta yaş kategorisinde ise biraz daha düşük ancak hâlâ iyi bir sonuç elde etmektedir.

DenseNet-169 modeli, sınıflar arasında daha dengeli bir ayırım yeteneği sunmuş ve genelleme kapasitesini artırmıştır.

- **Class MIDDLE (AUC = 0.94):** Orta yaş kategorisinde AUC değeri DenseNet-121'e göre bir miktar azalmış, ancak model hâlâ pozitif ve negatif örnekleri iyi bir şekilde ayırmaktadır.
- **Class OLD (AUC = 0.97):** Yaşlı kategoride ayırım performansı önceki modele benzer şekilde güçlüdür ve yanlış pozitif oranını düşük tutmayı başarmaktadır.
- **Class YOUNG (AUC = 0.96):** Genç kategorisinde AUC değeri bir miktar azalsa da modelin genel başarısı hâlâ tatmin edici seviyededir.

**Sonuç:** DenseNet-169, ayırım gücünü dengeli bir şekilde sürdürerek tüm kategorilerde istikrarlı bir performans göstermektedir.

DenseNet-201 modeli, sınıflandırmada genel başarıyı koruyarak tüm kategorilerde güçlü bir performans sergilemiştir.

- **Class MIDDLE (AUC = 0.94):** Orta yaş kategorisinde AUC değeri sabit kalmış, ancak ayırım gücü hâlâ yüksek düzeydedir.
- **Class OLD (AUC = 0.96):** Yaşlı kategorisinde ayırım gücü önceki modellere göre hafif bir düşüş göstermiş, ancak model bu kategoride güçlü bir performans sunmaya devam etmiştir.
- **Class YOUNG (AUC = 0.96):** Genç kategorideki AUC değeri sabit kalmış ve modelin doğru pozitifleri ayırt etmedeki gücünü göstermiştir.

**Sonuç:** DenseNet-201, genelleme kapasitesini koruyarak orta yaş kategorisinde kararlı, yaşlı kategorisinde ise hafif düşüşe rağmen güçlü bir performans sunmaktadır.

DenseNet-264 modeli, en derin yapısıyla genelleme kapasitesini artırmış ancak bazı kategorilerde ayırım performansı hafif bir düşüş göstermiştir.

- **Class MIDDLE (AUC = 0.93):** Orta yaş kategorisindeki AUC değeri bir miktar azalmış ve modelin bu kategorideki ayırım gücünün hafifçe düştüğünü göstermiştir.
- **Class OLD (AUC = 0.95):** Yaşlı kategorisinde AUC değeri de önceki modellere kıyasla azalmış, ancak genel performans hâlâ tatmin edici düzeydedir.
- **Class YOUNG (AUC = 0.95):** Genç kategoride ayırım gücü de bir miktar azalmış, ancak model pozitif örnekleri ayırt etmede yeterli başarısını korumuştur.

**Sonuç:** DenseNet-264, genel olarak başarılı bir performans sergilese de, en derin model olmasının getirdiği karmaşıklık nedeniyle ayırım gücünde sınırlı bir düşüş görülmektedir.

Genel bir değerlendirme yapıldığında DenseNet-121: Dengeli bir başlangıç performansı ile yaşlı ve genç kategorilerde güçlü bir ayırım gücü sunmuştur. DenseNet-169: Daha dengeli ve genelleme kapasitesi daha yüksek bir performans sergilemiştir. DenseNet-201: Orta yaş kategorisinde kararlılık gösterirken yaşlı kategoride hafif bir düşüş gözlenmiştir. DenseNet-264: En derin model olmasına rağmen, ayırım gücünde hafif bir düşüş yaşanmıştır.

Tüm modeller genel olarak iyi bir performans sergilemekte ve yaş gruplarını ayırt etme yeteneklerini başarıyla ortaya koymaktadır. Ancak, uygulama gereksinimlerine ve önceliklerine göre model seçimi yapılmalıdır. Daha yüksek AUC değerleri, güvenilir sınıflandırmalar için tercih sebebi olabilir.

## 5. SONUÇLAR VE ÖNERİLER

### 5.1 Sonuçlar

- DenseNet modellerinin başarısı: DenseNet modelleri, yaş sınıflandırması gibi zorlu bir görevde yüksek doğruluk, precision, recall ve F1 skoru gibi metriklerde başarılı bir performans göstermiştir. Yoğun bağlantılı yapısı sayesinde bilgi akışını artırarak gradyan kaybolması problemini önlemiş ve sınıflandırma görevinde etkili sonuçlar elde edilmiştir.
- Model performansları arasındaki farklar: Modellerin performansı, katman sayısına bağlı olarak değişiklik göstermiştir. Daha derin modeller (DenseNet-201 ve DenseNet-264), daha karmaşık veri örüntülerini öğrenme kapasitesine sahipken, daha az katmanlı modeller (DenseNet-121 ve DenseNet-169) daha hızlı eğitim süreci ve düşük hesaplama maliyeti sunmuştur. DenseNet-264, %89.8 doğruluk ile en yüksek performansı sergilemiştir.
- DenseNet mimarisinin avantajları: DenseNet mimarisi, her katmanın çıktısını sonraki katmanlara giriş olarak ileterek parametre verimliliğini artırmış, daha hızlı öğrenmeyi sağlamış ve modelin genelleme kapasitesini artırmıştır. Bu özellik, zorlu veri setlerinde başarılı sonuçlar alınmasını sağlamıştır.
- Veri setinin katkısı: Kullanılan IMFDB veri setinin çeşitliliği (yaş kategorileri, poz, yüz ifadeleri, cinsiyet, vb.), modellerin genelleme kapasitesini artırmış ve öğrenme sürecinde modelin farklı veri örüntülerine uyum sağlamasına olanak tanımıştır. Ancak, veri setindeki farklı çözünürlükler ve engelleme gibi faktörler modeli zorlayan unsurlar olmuştur.
- DenseNet-121 ve DenseNet-169: Daha az katmanlı bu modeller, hızlı ve maliyeti düşük çözümler sunmuş, DenseNet-121 %85.3, DenseNet-169 ise %87.1 doğruluk oranına ulaşmıştır. Bu modeller, hesaplama kaynaklarının sınırlı olduğu durumlarda veya hızlı sonuç alınması gereken uygulamalar için uygun bir alternatif olarak öne çıkmıştır.
- DenseNet-201 ve DenseNet-264: Daha derin mimarilere sahip bu modeller, karmaşık veri örüntülerini öğrenme kapasitesini artırmış ve %89.2 ile %89.8 doğruluk oranlarına ulaşmıştır. Bu modeller, özellikle karmaşık sınıflandırma görevlerinde tercih edilebilir.

- ROC eğrilerinin sonuçları: ROC eğrilerinde tüm modeller için AUC değerleri oldukça yüksek (0.93-0.97 aralığında) bulunmuştur. Yaşlı ve genç kategorilerde daha yüksek ayırım performansı elde edilmiş, orta yaş kategorisinde ise hafif bir düşüş gözlenmiştir. AUC değerleri, DenseNet modellerinin ayırım gücünün yüksek olduğunu göstermektedir.
- Veri artırma tekniklerinin etkisi: Rastgele yatay çevirme ve normalize etme gibi veri artırma teknikleri, overfitting riskini azaltmış ve modelin genelleme kapasitesini artırmıştır. Bu teknikler, modelin veri setindeki doğal varyasyonları öğrenmesini sağlamıştır.
- Optimizasyon sürecinin başarısı: Adam optimizasyon algoritması ve CrossEntropyLoss kayıp fonksiyonu, modellerin daha hızlı yakınsama sağlamasına ve kararlı bir öğrenme gerçekleştirmesine yardımcı olmuştur. Mini-batch boyutunun 32 olarak seçilmesi, eğitim sürecinin verimli bir şekilde gerçekleştirilmesini sağlamıştır.

**Model seçimi gereklilikleri:** Model seçimi, uygulamanın gereksinimlerine, veri setinin büyüklüğüne ve hesaplama kaynaklarına bağlıdır. Daha az katmanlı modeller, hızlı sonuçlar ve düşük maliyet sağlarken, daha derin modeller daha yüksek doğruluk oranları sunmaktadır.

## 5.2 Öneriler

- Model seçimi ihtiyaçlara göre yapılmalıdır: DenseNet modelleri arasından seçim yapılırken, uygulamanın gereksinimleri göz önünde bulundurulmalıdır. Daha az katmanlı modeller (DenseNet-121, DenseNet-169) hızlı sonuçlar ve düşük hesaplama maliyeti sunarken, daha derin modeller (DenseNet-201, DenseNet-264) daha yüksek doğruluk oranlarıyla karmaşık veri setleri için daha uygundur.
- Daha fazla veri artırma tekniği kullanılabilir: Eğitim sırasında kullanılan veri artırma teknikleri çeşitlendirilebilir. Örneğin, kontrast artırımı, parlaklık değişiklikleri ve renk jitterlama gibi ek yöntemler, modelin veri setindeki varyasyonlara karşı daha dayanıklı olmasını sağlayabilir.
- Transfer öğrenme uygulanabilir: Daha küçük veri setlerinde DenseNet modellerinin önceden eğitilmiş ağırlıklarla transfer öğrenme yöntemiyle

kullanılması önerilir. Bu, hem eğitim süresini kısaltabilir hem de modelin genelleme kapasitesini artırabilir.

- Farklı optimizasyon algoritmaları test edilmelidir: Adam optimizasyon algoritması etkili sonuçlar vermiş olsa da, SGD veya RMSProp gibi farklı algoritmaların denenmesi, özellikle daha karmaşık modellerde yakınsama sürecini iyileştirebilir.
- Model sıkıştırma ve optimizasyon: Daha düşük hesaplama maliyeti ve enerji tüketimi için model sıkıştırma (pruning) veya quantization gibi yöntemler kullanılabilir. Bu, özellikle uygulamaların gerçek zamanlı çalışması gereken durumlarda faydalı olacaktır.
- Hata analizi yapılmalıdır: Karışıklık matrislerinden elde edilen bilgiler doğrultusunda, özellikle genç ve yaşlı kategorilerdeki sınırlı karışıklıkların nedenleri derinlemesine analiz edilmelidir. Bu hataların azaltılması için özel stratejiler geliştirilebilir.
- Veri seti çeşitliliği artırılabilir: Kullanılan veri setine daha fazla örnek eklenmesi ve farklı demografik gruplar veya yaş gruplarını temsil eden verilerle zenginleştirilmesi önerilir. Bu, modelin genelleme kapasitesini artıracaktır.
- Hibrit yöntemlerin uygulanması: DenseNet modelleri, Ensemble Learning gibi yöntemlerle birleştirilebilir. Farklı modellerin çıktılarının birleştirilmesi, genel performansı artırabilir ve hataları azaltabilir.
- Diğer veri setlerinde test edilmelidir: DenseNet modellerinin farklı veri setlerinde (örneğin, farklı kültürel veya coğrafi özelliklere sahip yüz görüntüleri üzerinde) test edilmesi, genelleme kapasitesinin daha iyi anlaşılmasını sağlayacaktır.
- Kullanıcı dostu uygulamalar geliştirilmelidir: DenseNet modellerinin yüz sınıflandırma sistemleri için kullanıcı dostu uygulamalar geliştirilmesinde kullanılması önerilir. Örneğin, yaş tahmini için mobil uygulamalar veya web tabanlı araçlar oluşturulabilir. Bu tür uygulamalar, modellerin pratik kullanımını teşvik edebilir.

## KAYNAKLAR

- Abdalla, P. A., Mohammed, B. A., & Saeed, A. M. (2023). The impact of image augmentation techniques of MRI patients in deep transfer learning networks for brain tumor detection. *Journal of Electrical Systems and Information Technology*, 10(1), 51.
- Abirami, B., Subashini, T. S., & Mahavaishnavi, V. (2020). Gender and age prediction from real time facial images using CNN. *Materials Today: Proceedings*, 33, 4708-4712.
- Abood, Q. K. (2023). Predicting Age and Gender Using AlexNet. *TEM Journal*, 12(1).
- Akhtar, M. J., Mahum, R., Butt, F. S., Amin, R., El-Sherbeeney, A. M., Lee, S. M., & Shaikh, S. (2022). A robust framework for object detection in a traffic surveillance system. *Electronics*, 11(21), 3425.
- Alnajar, F., Shan, C., Gevers, T., & Geusebroek, J. M. (2012). Learning-based encoding with soft assignment for age estimation under unconstrained imaging conditions. *Image and Vision Computing*, 30(12), 946-953.
- Al-Shannaq, A. S., & Elrefaei, L. A. (2019). Comprehensive analysis of the literature for age estimation from facial images. *IEEE Access*, 7, 93229-93249.
- Alzahrani, S.; Al-Bander, B.; Al-Nuaimy, W. A Comprehensive Evaluation and Benchmarking of Convolutional Neural Networks for Melanoma Diagnosis. *Cancers* 2021, 13, 4494.
- Angulu, R., Tapamo, J. R., & Adewumi, A. O. (2018). Age estimation via face images: a survey. *EURASIP Journal on Image and Video Processing*, 2018(1), 1-35.
- Badr, M. M., Sarhan, A. M., & Elbasiony, R. M. (2019, December). Facial age estimation using deep neural networks: a survey. In *2019 15th International Computer Engineering Conference (ICENCO)* (pp. 183-191). IEEE.
- Baker, B. (2021). Estimates of the unauthorized immigrant population residing in the United States: January 2015–January 2018. *Population Estimates*, 134-45.
- Bao, Z., Luo, Y., Tan, Z., Wan, J., Ma, X., & Lei, Z. (2023). Deep domain-invariant learning for facial age estimation. *Neurocomputing*, 534, 86-93.
- Chao, W. L., Liu, J. Z., & Ding, J. J. (2013). Facial age estimation based on label-sensitive learning and age-oriented regression. *Pattern Recognition*, 46(3), 628-641.
- Chavali, S. T., Kandavalli, C. T., Sugash, T. M., & Subramani, R. (2023). Smart Facial Emotion Recognition With Gender and Age Factor Estimation. *Procedia Computer Science*, 218, 113-123.

- Choi, S. E., Lee, Y. J., Lee, S. J., Park, K. R., & Kim, J. (2011). Age estimation using a hierarchical classifier based on global and local facial features. *Pattern recognition*, 44(6), 1262-1281.
- Damascena, N. P., Lima, S. V. M. A., Santiago, B. M., Alemán-Aguilera, I., Cunha, E., Machado, C. E. P., & Martins-Filho, P. R. (2024). Accuracy of geometric morphometrics for age estimation using frontal face photographs of children and adolescents: A promising method for forensic practice. *Journal of Forensic and Legal Medicine*, 106, 102734.
- Dehshibi, M. M., & Bastanfard, A. (2010). A new algorithm for age recognition from facial images. *Signal Processing*, 90(8), 2431-2444.
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL-HLT*.
- Fu, Y., Guo, G., & Huang, T. S. (2010). Age synthesis and estimation via faces: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 32(11), 1955-1976.
- Geirhos, R., Jacobsen, J.-H., Michaelis, C., Zemel, R., Brendel, W., Bethge, M., & Wichmann, F. A. (2020). Shortcut learning in deep neural networks. *Nature Machine Intelligence*, 2(11), 665-673.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Guehairia, O., Dornaika, F., Ouamane, A., & Taleb-Ahmed, A. (2022). Facial age estimation using tensor based subspace learning and deep random forests. *Information Sciences*, 609, 1309-1317.
- Han, H., Otto, C., & Jain, A. K. (2013, June). Age estimation from face images: Human vs. machine performance. In *2013 international conference on biometrics (ICB)* (pp. 1-8). IEEE.
- Hu, H., Li, S., Huang, J., Liu, B., & Che, C. (2023). Casting product image data for quality inspection with xception and data augmentation. *Journal of Theory and Practice of Engineering Science*, 3(10), 42-46.
- Hu, Z., Wen, Y., Wang, J., Wang, M., Hong, R., & Yan, S. (2016). Facial age estimation with age difference. *IEEE Transactions on Image Processing*, 26(7), 3087-3097.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4700-4708
- Huerta, I., Fernández, C., Segura, C., Hernando, J., & Prati, A. (2015). A deep analysis on age estimation. *Pattern Recognition Letters*, 68, 239-249.

- Jandová, M., Daňko, M., & Urbanová, P. (2021). Age verification using random forests on facial 3D landmarks. *Forensic Science International*, 318, 110612.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Li, Y., Peng, Z., Liang, D., Chang, H., & Cai, Z. (2016). Facial age estimation by using stacked feature composition and selection. *The Visual Computer*, 32, 1525-1536.
- Liu, N., Zhang, F., & Duan, F. (2023). Age estimation by extracting hierarchical age-related features. *Journal of Visual Communication and Image Representation*, 95, 103884.
- Narmatha, C. (2023). A combination of DenseNet-264 with alternating decision tree for detecting lung infection. *Soft Computing*, 1-11.
- Ouafi, A., Zitouni, A., Ruichek, Y., & Taleb-Ahmed, A. (2019). Two-stages based facial demographic attributes combination for age estimation. *Journal of Visual Communication and Image Representation*, 61, 236-249.
- Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359.
- Takeda, A., Nakagawa, T., Takaso, M., Nakamura, M., & Hitosugi, M. (2021). Exploring the potential for age estimation using facial image sensing technology for postmortem investigation. *Legal Medicine*, 48, 101808.
- Tareq, I., Elbagoury, B. M., El-Regaily, S., & El-Horbaty, E. S. M. (2022). Analysis of ton-iot, unw-nb15, and edge-iiot datasets using dl in cybersecurity for iot. *Applied Sciences*, 12(19), 9572.
- Tian, Q., Cao, M., Sun, H., Qi, L., Mao, J., Cao, Y., & Tang, J. (2021). Facial age estimation with bilateral relationships exploitation. *Neurocomputing*, 444, 158-169.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.
- Yang, Q., Liu, Y., Chen, T., & Tong, Y. (2019). Federated machine learning: Concept and applications. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 10(2), 1-19

- Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*, 27.
- Zang, H. X., Su, H., Qi, Y., Feng, L., Hou, R., He, M., ... & Chen, P. (2022). Ages of giant panda can be accurately predicted using facial images and machine learning. *Ecological Informatics*, 72, 101892.
- Zhao, Q., Liu, J., & Wei, W. (2024). Mixture of deep networks for facial age estimation. *Information Sciences*, 679, 121086.
- Zhong, Z., Zheng, M., Mai, H., Zhao, J., & Liu, X. (2020, November). Cancer image classification based on DenseNet model. In *Journal of physics: conference series* (Vol. 1651, No. 1, p. 012143). IOP Publishing