



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**TERMAL GÖRÜNTÜ ÇÖZÜNÜRLÜĞÜNÜN**  
**ARTIRILMASI İÇİN DERİN ÖĞRENME**  
**TABANLI BULUT SİSTEMİNİN**  
**GELİŞTİRİLMESİ**

**Fatih Mehmet ŞENALP**

**DOKTORA TEZİ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Mart-2022**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Fatih Mehmet ŞENALP tarafından hazırlanan “Termal Görüntü Çözünürlüğünün Artırılması İçin Derin Öğrenme Tabanlı Bulut Sisteminin Geliştirilmesi” adlı tez çalışması 31/03/2022 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. Seral ÖZŞEN

.....

#### Danışman

Doç. Dr. Murat CEYLAN

.....

#### Üye

Dr. Öğr. Üyesi Hüseyin Oktay ALTUN

.....

#### Üye

Dr. Öğr. Üyesi Hasan KOYUNCU

.....

#### Üye

Dr. Öğr. Üyesi Saim ERVURAL

.....

Yukarıdaki sonucu onaylıyorum.

Prof. Dr. Saadettin Erhan KESEN  
Enstitü Müdürü

Bu tez çalışması Konya Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından 201102001 numaralı proje ile desteklenmiştir.

Tez çalışmasında kullanılan yenidoğan termal görüntüleri, TÜBİTAK tarafından desteklenen 215E019 numaralı proje kapsamında elde edilmiştir.

## **TEZ BİLDİRİMİ**

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 bildiririm.

## **DECLARATION PAGE**

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Fatih Mehmet ŞENALP

Tarih: 31/03/2022

# ÖZET

## DOKTORA TEZİ

### TERMAL GÖRÜNTÜ ÇÖZÜNÜRLÜĞÜNÜN ARTIRILMASI İÇİN DERİN ÖĞRENME TABANLI BULUT SİSTEMİNİN GELİŞTİRİLMESİ

**Fatih Mehmet ŞENALP**

**Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Danışman: Doç. Dr. Murat CEYLAN**

**2022, 84 Sayfa**

**Jüri**

**Prof. Dr. Seral ÖZŞEN**

**Doç. Dr. Murat CEYLAN**

**Dr. Öğr. Üyesi Hüseyin Oktay ALTUN**

**Dr. Öğr. Üyesi Hasan Koyuncu**

**Dr. Öğr. Üyesi Saim ERVURAL**

Termal görüntüleme sistemleri temassız bir şekilde sıcaklık ölçümü sağlamakta olup, insan sağlığına zararsızdır. Dolayısıyla, canlılar üzerinde güvenli bir şekilde kullanılabilir. Termal kameralar, sıcaklık değişiminin tespitini gerektiren kamu güvenliği, sağlık, savunma gibi birçok sektörde kullanılabilir. Bununla birlikte termal kameraların hem yüksek maliyetli olması hem de kenar detay bilgisi düşük görüntüler oluşturması kullanımlarını sınırlandırmaktadır. Düşük maliyetli termal kameralar ise termal görüntülemenin farklı alanlarda kullanımını kolaylaştırmaktadır. Bu termal kameralar düşük detay bilgisine sahip düşük çözünürlüklü termal görüntüler oluşturabilmektedir. Bu sebeple, düşük çözünürlüklü bu termal görüntülerin çözünürlüklerini iyileştirme ihtiyacı ortaya çıkmıştır. Burada, süper çözünürlük tekniklerinin düşük kalitedeki bu görüntüler üzerinde kullanımı büyük önem arz etmektedir. Süper çözünürlük, bir dizi düşük çözünürlüklü görüntü kullanılarak daha yüksek çözünürlüklü bir görüntü oluşturulması olarak tanımlanmaktadır; fakat son yıllardaki derin öğrenme tabanlı uygulamalar için, yüksek çözünürlüklü (gerçek referans) bir görüntünün, düşük çözünürlüklü (DÇ) karşılığında tahmin edilmesi şeklinde tanımlanması daha doğru bir ifade olacaktır. Süper çözünürlük kavramı hem yazılım hem de donanım tabanlı olarak uygulanabilir olmasına rağmen, gerçekleştirilen çalışmaların büyük bir kısmı yazılım tabanlı süper çözünürlük uygulamaları üzerinedir. Son yıllardaki derin öğrenme alanında yaşanan gelişmeler ve donanımsal ilerlemeler, derin öğrenme algoritmalarının süper çözünürlük uygulamalarında daha yaygın bir şekilde kullanılmasını sağlamıştır.

Tez çalışması kapsamında, iki farklı termal veri tabanı oluşturularak süper çözünürlük uygulamaları gerçekleştirilmiştir. Ayrıca, süper çözünürlük uygulamaları için ilk önce çekimci üretici ağlar (ÇÜA) tabanlı "Termal Süper Çözünürlük Çekimci Üretici Ağlar (TSCÇÜA)" modeli tasarlanmış olup, daha sonra bu modelin başarısını artırmak amacıyla TSCÇÜA+ modeli geliştirilmiştir. Süper çözünürlük uygulamalarında kullanılan ilk veri tabanı yenidoğan bebeklere (neonatal) ait termal görüntülerdir ve çalışmalarda yüksek çözünürlüklü (gerçek referans) görüntüler olarak dikkate alınmıştır. Daha sonra, düşük çözünürlüklü görüntülerden oluşan veri setleri belirli oranlarda (1/2, 1/4, 1/8, 1/16) alt ölçekleme yapılarak elde edilmiştir. Elde edilen sonuçlar görüntü kalite metrikleri olan tepe sinyal gürültü oranı (TSGO) ve yapısal benzerlik indeksi (YBİ) ile değerlendirilmiştir. TSGO ve YBİ değerleri incelendiğinde, geliştirilen modellerin literatürdeki diğer modellerle karşılaştırıldığında daha başarılı oldukları görülmektedir. Ayrıca TSCÇÜA+ modeli TSCÇÜA modeli ile karşılaştırıldığında, TSGO değerlerinde 1-1,5 dB aralığında artış gösterirken, YBİ değerlerinde %2-3 aralığında artış göstermiştir. Ek olarak, görev tabanlı değerlendirme yapabilmek amacıyla evrişimli sinir ağları tabanlı (ESA) tabanlı bir

sınıflayıcı model tasarlanarak, hasta-sağlıklı bebekleri sınıflama uygulamaları gerçekleştirilmiştir. Sonuçlar değerlendirildiğinde, süper çözünürlüklü görüntülerin sınıflama başarısının düşük çözünürlüklü görüntülere kıyasla yaklaşık %10 arttığı gözlenmiştir. Ayrıca, TSCÇÜA+ modelinin de TSCÇÜA modeline göre yaklaşık % 3 daha başarılı sınıflama yaptığı görülmüştür.

Tez çalışmaları kapsamında kullanılan ikinci veri tabanı, termal yüz görüntülerinden oluşmaktadır. Bu veri tabanı iki farklı termal kamera vasıtasıyla oluşturulmuştur. Burada, yüksek maliyetli bir termal görüntüleme sistemi kullanılarak yüksek çözünürlüklü (gerçek referans) görüntüleri elde edilirken, düşük maliyetli ve akıllı telefona takılarak kullanılabilen bir termal kamera aracılığıyla düşük çözünürlüklü görüntüler elde edilmiştir. Süper çözünürlük uygulamalarında yine TSCÇÜA ve TSCÇÜA+ modellerinden yararlanılmıştır. Burada, düşük maliyetli kameranın performansını yüksek maliyetli kameranın performansına yaklaştırarak, termal görüntüleme projelerindeki maliyet problemlerinin önüne geçilmesi hedeflenmiştir. Elde edilen sonuçlar değerlendirildiğinde, TSGO ve YBİ değerlerinin en gelişmiş modellere göre artış gösterdiği gözlenmiştir. Bunun yanı sıra TSCÇÜA+ modelinin TSCÇÜA modeline kıyasla TSGO değerinde yaklaşık olarak 0,5 dB, YBİ değerinde ise %5 daha başarılı olduğu görülmüştür.

Ayrıca, oluşturulan süper çözünürlük sisteminin bulut ortamında çalıştırılmasına yönelik bir çalışma yürütülmüştür. Android bir arayüz kullanılarak oluşturulan bulut tabanlı sistem sayesinde süper çözünürlük tekniklerinden gerçek zamanlı ve aktif olarak yararlanılabileceği öngörülmektedir. Farklı kullanıcılar tarafından kolay bir şekilde erişilebilen ve farklı uygulamalara adapte edilebilen bulut tabanlı geliştirilen bu sistem sayesinde düşük maliyetli termal kameralar gerçek hayata yönelik uygulamalarda yaygın bir şekilde kullanılabilir.

**Anahtar Kelimeler:** Bulut bilişim, Çekişmeli üretici ağlar, Derin öğrenme, Evrişimli sinir ağları, Sınıflama, Süper çözünürlük, Termal görüntüleme

## **ABSTRACT**

### **PhD THESIS**

# **DEVELOPMENT OF CLOUD SYSTEM BASED ON DEEP LEARNING FOR THERMAL IMAGE RESOLUTION ENHANCEMENT**

**Fatih Mehmet SENALP**

**Konya Technical University  
Institute of Graduate Studies  
Department of Electrical and Electronics Engineering**

**Advisor: Assoc. Prof. Dr. Murat CEYLAN**

**2022, 84 Pages**

**Jury**

**Prof. Dr. Seral ÖZŞEN**

**Assoc. Prof. Dr. Murat CEYLAN**

**Asst. Prof. Dr. Hüseyin Oktay ALTUN**

**Asst. Prof. Dr. Hasan Koyuncu**

**Asst. Prof. Dr. Saim ERVURAL**

Thermal imaging systems provide non-contact temperature measurement and are harmless to human health. Therefore, it can be used safely on living things. Thermal cameras can be used in many sectors such as public security, health and defense that require the detection of temperature changes. However, the high cost of thermal cameras and their low edge detail information limit their usage. Thus, low-cost thermal cameras facilitate the use of thermal imaging in different areas. These thermal cameras can create low resolution thermal images with low detail information. Therefore, the need to improve the resolution of these low-resolution thermal images has emerged. Here, the use of super resolution techniques on these low quality images is of great importance. Super resolution is defined as the creation of a higher resolution image using a set of low resolution images; but deep learning-based applications in recent years, it would be more accurate to describe it as estimating a high resolution (ground truth) image from its low resolution (LR) counterpart. Although the concept of super resolution can be applied both in software and hardware, most of the studies carried out are on software-based super resolution applications. In recent years, hardware advances and developments in the field of deep learning have made deep learning algorithms more widely used in super resolution (SR) applications.

Within the scope of the thesis study, super resolution applications were carried out by creating two different thermal databases. In addition, for super resolution applications, firstly, the “Thermal Super Resolution Generative Adversarial Networks (TSRGAN)” model based on generative adversarial networks (GAN) was designed, and then the TSRGAN+ model was developed in order to increase the success of this model. The first database used in super resolution applications was the thermal images of newborn babies (neonates) and were considered as high resolution (ground truth) images in the studies. Then, datasets consisting of low resolution images were obtained by down-scaling at certain ratios (1/2, 1/4, 1/8 and 1/16). The obtained results were evaluated with the image quality metrics peak signal to noise ratio (PSNR) and structural similarity index (SSIM). When PSNR and SSIM values are examined, it is seen that the developed models are more successful when compared to the state-of-the-art models. Also, when the TSRGAN+ model is compared with the TSRGAN model, PSNR values increased in the range of 1-1.5 dB, while SSIM values increased by 2-3%. In addition, a convolutional neural network-based (CNN-based) classifier model was designed to make task-based evaluation, and the applications were carried out to classify unhealthy-healthy babies. When the results were evaluated, it was observed that the classification success of super resolution images increased by about 9-11% compared to low

resolution images. In addition, the TSRGAN+ model was found to be approximately 3% more successful than the TSRGAN model. In addition, the TSRGAN+ model has achieved approximately 3% more successful classification success than the TSRGAN model.

The second database used within the scope of the thesis studies consists of thermal face images. This database was created by means of two different thermal cameras. Here, high-resolution (ground truth) images were obtained using a high-cost thermal imaging system, while low-resolution images were obtained through a low-cost thermal camera that can be attached to a smart phone. In super resolution applications, TSRGAN and TSRGAN+ models were used again. Here, it is aimed to avoid cost problems in thermal imaging projects by bringing the performance of a low-cost camera closer to that of a high-cost camera. When the obtained results were evaluated, it was observed that PSNR and SSIM values increased compared to the state-of-the-art models. In addition, the TSRGAN+ model was found to be approximately 0.5 dB more successful in PSNR and 5% more successful in SSIM compared to the TSRGAN model.

In addition, a study was conducted to run the created super resolution system in the cloud environment. It is foreseen that super resolution techniques can be utilized in real time and actively through the cloud-based system created using an Android interface. Thanks to the cloud-based system, which can be easily accessed by different users and adapted to different applications, low-cost thermal cameras will be widely used in real-life applications.

**Keywords:** Classification, Cloud computing, Convolutional neural networks, Deep learning, Generative adversarial networks, Super resolution, Thermal imaging

## ÖNSÖZ

Doktora tez çalışmalarımnda en çok emeđi geen, ok deđerli yardım ve y6nlendirmelerini eksik etmeyen, danıřmanım Konya Teknik niversitesi M6hendislik ve Dođa Bilimleri Fak6ltesi Elektrik-Elektronik M6hendisliđi 6đretim yesi Sayın Do. Dr. Murat Ceylan'a katkılarından dolayı ř6kranlarımı sunarım.

201102001 numaralı proje kapsamında bu tez alıřmasına destek veren Konya Teknik niversitesi Bilimsel Arařtırma Projeleri Koordinat6rl6đ6'ne, termal g6r6nt6lerin elde edilmesi s6recinde katkısı bulunan Konya Teknik niversitesi 6đretim 6yelerine ve tez alıřmasında kullanılan yenidođan verileri iin 215E019 numaralı proje ile katkı sađlayan T6B6TAK'a teřekk6r ederim.

Son olarak, hayatımın her adımında desteklerini hep hissettiđim kıymetli aileme en iten minnet duygularımla teřekk6r6 bir bor bilirim.

Fatih Mehmet řENALP  
KONYA-2022



# İÇİNDEKİLER

<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>vi</b>
<b>ÖNSÖZ</b> .....	<b>viii</b>
<b>İÇİNDEKİLER</b> .....	<b>ix</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>xi</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>6</b>
<b>3. MATERYAL VE YÖNTEM</b> .....	<b>10</b>
3.1. Yenidoğan Bebeklere Ait Termal Görüntü Veri Tabanı .....	10
3.2. Termal Yüz Görüntüleri ile Oluşturulan Veri Tabanı .....	11
3.3. Görüntü Ön İşleme.....	13
3.4. Süper Çözünürlük Kavramı .....	14
3.5. Yapay Zeka Kavramı ve Derin Öğrenme Algoritmaları .....	15
3.5.1. Yapay sinir ağları.....	16
3.5.2. Evrişimli sinir ağları .....	18
3.5.3. Çekişmeli üretici ağlar .....	25
3.5.4. Termal süper çözünürlük çekişmeli üretici ağ (TSCÇÜA) .....	27
3.5.5. TSCÇÜA+ modeli .....	30
3.5.6. ESA tabanlı sınıflayıcı model .....	32
3.5.7. Artık sinir ağları (ResNet50 ve ResNet 101).....	33
3.5.8. VGG16 ve VGG19 modelleri .....	34
3.5.9. InceptionV3 ve Xception modelleri.....	35
3.6. Transfer Öğrenme .....	37
3.7. Başarı Değerlendirme Kriterleri .....	38
3.8. Bulut Ortamı .....	40
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA</b> .....	<b>42</b>
4.1. Termal Görüntüler Üzerinde Gerçekleştirilen Sınıflama Uygulamalarında Derin Öğrenme Tabanlı Süper Çözünürlük Yaklaşımının Etkileri.....	42
4.1.1. Kullanılan veri seti.....	42
4.1.2. Deneysel sonuçlar .....	43
4.2. Farklı Üst Ölçekleme Oranları için Yenidoğan Termal Görüntüleri ile Gerçekleştirilen Süper Çözünürlük ve Sınıflama Uygulamaları .....	48
4.2.1. Gerçekleştirilen süper çözünürlük uygulamaları .....	49
4.2.2. Sınıflama uygulamalarının başarısında süper çözünürlük metotlarının etkilerinin incelenmesi .....	51
4.3. Termal Yüz Görüntülerini İçeren Yeni Bir Veri Seti Üzerinde Süper Çözünürlük Uygulaması .....	54
4.3.1. Termal yüz görüntülerine ait iki farklı veri seti.....	54

4.3.2. Termal yüz görüntüleri üzerindeki süper çözünürlük uygulamaları.....	56
4.4. Termal Yenidoğan (Neonatal) Görüntülerinden Oluşan Yeni Bir Veri Seti için Derin Öğrenme Tabanlı Süper Çözünürlük Uygulaması.....	60
4.4.1. Farklı üst ölçekleme oranları için gerçekleştirilen süper çözünürlük uygulamalarında kullanılan veri setleri.....	61
4.4.2. Farklı üst ölçekleme oranları için süper çözünürlük uygulamaları.....	61
4.4.3. Sınıflama uygulamaları.....	64
4.5. Termal Yüz Görüntüleri İçin Bulut Tabanlı Süper Çözünürlük Uygulaması.....	66
4.5.1. TSCÇÜA+ modeli kullanılarak termal yüz görüntüleri üzerinde süper çözünürlük uygulaması .....	67
4.5.2. Süper çözünürlük modelinin bulut ortamında çalıştırılması.....	68
<b>5. SONUÇLAR VE ÖNERİLER .....</b>	<b>70</b>
5.1. Sonuçlar .....	70
5.2. Öneriler .....	73
<b>KAYNAKLAR .....</b>	<b>76</b>
<b>ÖZGEÇMİŞ .....</b>	<b>Error! Bookmark not defined.</b>

## SİMGELER VE KISALTMALAR

### Simgeler

$b$	: Bias değeri
$B$	: Renkli görüntünün mavi bandı
$C_1, C_2$	: Kararsızlık sabitleri
$cm$	: Santimetre
$^{\circ}C$	: Santigrat derece
$dB$	: Desibel
$dk$	: Dakika
$e_j$	: Hata değeri
$G$	: Renkli görüntünün yeşil bandı
$I_0$	: Referans görüntü
$I_D$	: Alt ölçeklenerek çözünürlüğü düşürülmüş görüntü
$I$	: Çıktı görüntü
$I_n^{LR}$	: Düşük çözünürlüklü görüntüler
$I_n^{HR}$	: Yüksek çözünürlüklü görüntüler
$K$	: Kelvin
$log$	: Logaritma
$L_{\text{çekişmeli}}^{SC}$	: Çekişmeli kayıp
$L_{okh}$	: OKH kaybı
$L_{tsççüa}$	: Algısal kayıp
$L_{vgg}$	: VGG kaybı
$\mu m$	: Mikrometre
$M \times M$	: Filtre boyutu
$m$	: Metre
$mm$	: Milimetre
$\mu$	: Ortalama
$n$	: Veri setinin boyutu
$R$	: Renkli görüntünün kırmızı bandı
$\sigma$	: Standart sapma
$\delta_G$	: Modelin ağırlık ve sapma değerleri
$\infty$	: Sonsuz
$\tanh$	: Hiperbolik tanjant
$\sum$	: Toplam
$w$	: Ağırlık değeri
$\psi_{i,j}$	: Özellik haritaları
$x_1, x_2, \dots, x_m$	: Yapay sinir ağlarının girdileri

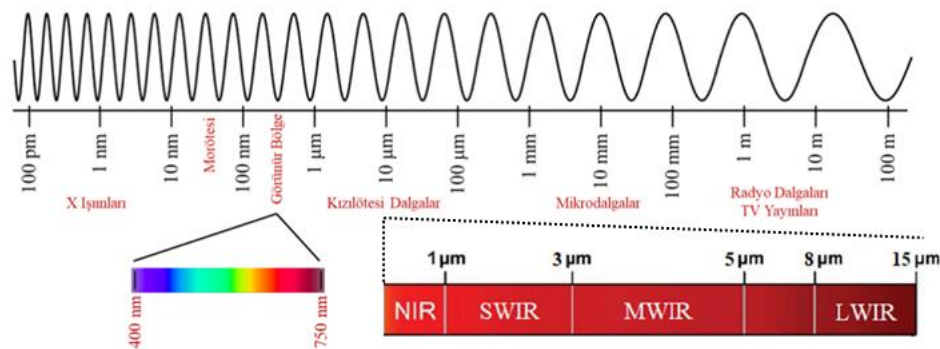
## Kısaltmalar

BT	: Bilgisayarlı tomografi
Colab	: Google colaboratory
ÇÜA	: Çekişmeli üretici ağlar
DÇ	: Düşük çözünürlüklü görüntü
DN	: Doğru negatif
DÖ	: Derin öğrenme
DP	: Doğru pozitif
ESA	: Evrişimli sinir ağı
FIR	: Uzak kızılötesi
GPU	: Grafik işlemci birimi
k-NN	: k-en yakın komşu
KKH	: Konjenital kalp hastalığı
LWIR	: Uzun dalga kızılötesi
MÖ	: Makine öğrenmesi
MR	: Manyetik rezonans
OKH	: Ortalama kare hata
MWIR	: Orta dalga kızılötesi
NIR	: Yakın kızılötesi
RGB	: 3 boyutlu renk uzayı
SÇ	: Süper çözünürlüklü görüntü
YBİ	: Yapısal benzerlik indeksi
SWIR	: Kısa dalga kızılötesi
TPU	: Tensör işleme birimi
TSCÇÜA	: Termal süper çözünürlük çekişmeli üretici ağlar
TSGO	: Tepe sinyal gürültü oranı
YBİ	: Yapısal benzerlik indeksi
YÇ	: Yüksek çözünürlüklü görüntü
YN	: Yanlış negatifler
YP	: Yanlış pozitifler
YSA	: Yapay sinir ağları
YYBÜ	: Yenidoğan yoğun bakım ünitesi

## 1. GİRİŞ

Görünür ışığın spektrumu, maddenin içinde hareket eden geniş bir algılanabilir sinyal (veya dalga) bandının küçük bir bölümüdür. Elektromanyetik spektrumda, her biri benzersiz bir dalga boyuna sahip çeşitli görünmez dalga türlerinden gelen radyasyon içeriği bulunur. İnsanlar, Şekil 1.1’de gösterilen elektromanyetik spektrumda 380 ile 720 nm arasındaki dalga boylarını algılayabilirler (Beiser, 2003). Bu durum göz önünde bulundurularak, standart renkli (RGB) görüntüler sağlayan kameralar nesnelere yansıyan enerjiyi algılama prensibine göre üretilmişlerdir. Ancak bu kameralar, kötü hava koşullarında, gece saatlerinde ve yetersiz aydınlatma koşullarında çok düşük ayrıntı düzeyine sahip görüntüler üretmektedirler (Chudasama ve ark., 2020). Bu gibi durumlarda termal kameralar ön plana çıkmaktadır. Termal radyasyon görünür ışıktan daha uzun dalga boylarına sahiptir, dolayısıyla insan gözüyle görünmemektedir. Mutlak sıfırın (0 Kelvin) üzerinde bir sıcaklığa sahip her nesne kızılötesi radyasyon yaymaktadır. Bir nesnenin sıcaklığı ne kadar yüksekse, yayılan radyasyon miktarı da o kadar yüksek olmaktadır. Kızılötesi termografi, Sir William Herschel tarafından kızılötesi radyasyonun keşfedilmesi sonucu ortaya çıkmış bir kavramdır (Herschel, 1800). Daha sonra kızılötesi ekipmanların (sensörler vs.) gelişmesiyle birlikte 1940’lı yıllarda kızılötesi kameralar icat edilmiştir (Lloyd, 2013). Termal kamera bir lens, bir termal sensör, işlemci, bellek ve mekanik bir muhafazadan oluşmaktadır. Lens, kızılötesi enerjiyi sensöre odaklamaktadır. Bu sensör, 80x60 pikselden başlayarak 1280x1024 piksele kadar veya daha fazla piksel konfigürasyonlarında olabilmektedir. Bu değerler termal kameranın çözünürlüğüdür. Bu kameraların çözünürlükleri görünür ışık görüntüleyicilere kıyasla düşüktür, çünkü termal dedektörlerin görünür ışıktan çok daha büyük dalga boylarına sahip enerjiyi algılaması gerekmektedir. Yani, her bir termal sensör çok daha büyük boyuta sahip olmaktadır. Nihayetinde, bir termal kamera genellikle aynı mekanik boyuttaki görünür sensörlerden çok daha düşük çözünürlüğe (daha az piksel) sahiptir. Bir termal kamera seçilirken dikkate alınması gereken önemli özellikler arasında çözünürlük, aralık, görüş alanı, odak, termal hassasiyet ve spektral aralık bulunmaktadır (Hansen ve Malchow, 2008). Nesnelere arasındaki sıcaklık farklarından yararlanan termal kameralar, görünmez termal radyasyonu ısı bölgesi görüntüleri şeklinde görünür hale getirmektedirler ve görüntünün yapısını kızılötesi enerjiye göre oluşturduğu renkler ve şekiller ile göstermektedirler. Termal kameralar ile görüntü elde edilirken aydınlatma koşullarından

etkilenme durumu söz konusu değildir ve karanlık ortamlarda dahi görüntü üretilmektedir. Termal kameralar yağış ve sis gibi hava koşullarından da etkilenmezler (Chudasama ve ark., 2020). Başlarda güvenlik ve askeri amaçlarla kullanılan termal kameralar; inşaat, altyapı, elektrik vb. alanlarda da yaygın olarak kullanılmaktadır. Ek olarak, medikal alanda da önemli bir yere sahip olan termal kameralar, temassız sıcaklık ölçümü sağlayabildiği için hastalık teşhisi gibi problemlerde invazif olmayan ve zararsız bir araç olarak uzmanlara yardımcı olmaktadır. Bununla birlikte termal görüntüleme sistemlerinin bazı dezavantajları da bulunmaktadır. Termal kamera sistemleri yüksek maliyete sahiptirler (Ornek ve ark., 2019). Ayrıca, termal görüntülerde kenar bilgileri (yüksek frekans bölgeleri) tam olarak elde edilememekte ve detay seviyesi düşük olan bulanık görüntüler elde edilmektedir. Bu gibi durumlar, termal kameraların medikal alanda kullanımını sınırlamaktadır. Bu sebeple termal görüntülerin çözünürlüğünü iyileştirme ihtiyacı ortaya çıkmıştır ve son yıllarda süper çözünürlük metotları yaygın bir şekilde kullanılmaktadır (Zhang ve ark., 2018). Örneğin; termal yüz görüntüleri (Şenalp ve Ceylan, 2022), termal uydu görüntüleri (Stankevich ve ark., 2019), cadde ve sokak manzaralarına ait termal görüntüler (Chudasama ve ark., 2020) kullanılarak çeşitli süper çözünürlük uygulamaları gerçekleştirilmiştir.



Şekil 1.1. Elektromanyetik spektrum ve kızılötesi alt bantları (Casimiro ve ark., 2019)

Yüksek görüntü kalitesi sağlayan kameralara olan ilgi son yıllarda oldukça hızlı bir biçimde artış göstermiştir. Ancak donanımsal seviyede elde edilebilecek çözünürlük miktarının sınırlı olması sebebiyle farklı çalışmalara odaklanılmıştır. Süper çözünürlük, gözlemlenmiş düşük çözünürlüklü görüntüden yüksek çözünürlüklüğe sahip başka bir görüntünün oluşturulması tekniğidir. Başka bir deyişle süper çözünürlük terimi, yüksek

çözünürlüklü (gerçek referans) bir görüntünün, düşük çözünürlüklü karşılığından tahmin edilmesi şeklinde tanımlanmaktadır (Yue ve ark., 2018). Süper çözünürlük ile ilgili temel çalışmalarda bazı interpolasyon teknikleri kullanılmaktadır. İnterpolasyon, bilinen piksel değerlerinden yararlanarak bilinmeyen noktadaki yeni piksel değerlerini tahmin etme yöntemidir. En yakın komşu (k-NN), lineer ve bikübik olmak üzere başlıca kullanılan üç interpolasyon yöntemi mevcuttur. Bu üç yöntem arasında en basit olanı en yakın komşu yöntemi olup, bu metotla elde edilen resimlerde mozaikleşmeler görülmektedir (Hasaltın ve Beşdok, 2004). Lineer interpolasyonda ise bu keskin köşeler elimine edilmiş olsa da bulanık görüntüler ortaya çıkabilmektedir (Hasaltın ve Beşdok, 2004). Bu dezavantajları minimize edebilen bikübik interpolasyon yöntemi, belirtilen 3 metot arasında en iyi sonucu vermekte ve yaygın bir şekilde tercih edilmektedir. Bikübik interpolasyon, bilinmeyen pikselin 4x4 komşuluğundaki 16 pikseli kullanarak yeni pikselin renk bilgisini oluşturmada ve bilinmeyen piksele daha yakın olan komşu piksellere daha çok ağırlık verilmektedir (Thevenaz ve ark., 2000). Son yıllarda ise derin ağ modelleri kullanılarak gerçekleştirilen görüntü kalitesini iyileştirme uygulamaları popüler bir hale gelmiştir (Dong ve ark., 2016). Geniş bir kullanım alanına sahip olan süper çözünürlük metotları; yüz tespiti ve yüz tanıma (Kumar ve Singh, 2018), nesne tanıma (Girshick ve ark., 2016), astronomi ve uzaktan algılama (Stankevich ve ark., 2019), sıkıştırılmış görüntü veya video kalitesi iyileştirme (Thawakar ve ark., 2019), görüntü gürültü giderme (Xie ve ark., 2021), hiperspektral görüntülerin iyileştirilmesi (Fu ve ark., 2019), termal görüntülerin çözünürlüğünün artırılması (Senalp ve Ceylan, 2021), sentetik açıklıklı radar görüntülerinin yeniden oluşturulması (Xiao ve ark., 2021), iris ve göz tanıma (Nguyen ve ark., 2013), işaret veya plaka tanıma (Glasner ve ark., 2009), parmak izi tanıma (Singh ve ark., 2015) ve biyomedikal görüntü işleme (Achanta ve ark., 2019) gibi çeşitli uygulamalar için alternatif bir çözüm yolu olarak dikkat çekmektedirler.

Öğrenme tabanlı süper çözünürlük çalışmalarını gerçekleştirmek için genellikle hazır bir veri seti ve bu veri setindeki görüntülerin alt ölçeklenmesiyle oluşturulan görüntü çiftleri kullanılmaktadır. Bu hazır veri seti, yüksek çözünürlüklü (gerçek referans) veri seti olarak değerlendirilmektedir. Tez çalışması kapsamında ilk olarak, TÜBİTAK tarafından desteklenmiş olan 215E019 numaralı proje kapsamında elde edilen hasta ve sağlıklı yenidoğan bebeklere ait yüksek çözünürlüklü termal görüntüler kullanılarak, veri seti çeşitli alt ölçekleme oranlarında yeniden boyutlandırılmış ve düşük çözünürlüklü termal görüntüler elde edilmiştir. Böylece düşük ve yüksek

çözünürlüklü görüntülerden meydana gelen veri seti oluşturulmuştur. Daha sonra, iki farklı termal kameradan elde edilen yüksek çözünürlüklü (YÇ - gerçek referans) ve düşük çözünürlüklü termal yüz görüntü çiftlerinden oluşan veri seti meydana getirilmiştir. Variocam HD© termal kamera ile yüksek çözünürlüklü görüntüler elde edilirken, Flir One Pro© termal kamera vasıtasıyla düşük çözünürlüklü görüntüler (DÇ) elde edilmiştir. Nihayetinde farklı termal görüntülere ait iki farklı termal veri seti oluşturulmuş ve bu görüntüler üzerinde süper çözünürlük uygulamaları gerçekleştirilmiştir. Bu görüntülerin elde edildiği termal kameralar Şekil 1.2'de gösterilmiştir.



Şekil 1.2. a) Variocam HD termal kamera (InfraTec, 2022), b) Flir One Pro termal kamera (FLIR, 2022)

Gerçekleştirilen uygulamalarda elde edilen sonuçlar tepe sinyal gürültü oranı (TSGO) ve yapısal benzerlik indeksi (YBI) görüntü kalite metrikleri dikkate alınarak değerlendirilmiştir. Ayrıca, termal bebek görüntüleriyle gerçekleştirilen uygulamalar için evrişimli sinir ağları tabanlı bir sınıflayıcı model tasarlanarak hasta-sağlıklı sınıflama başarısı da dikkate alınmıştır.

Büyük miktarda veri ve görüntü işlemedeki hesaplama karmaşıklığı sebebiyle bilgisayar ve akıllı telefonlar için akıllı bulut sistemleri geliştirmeye yönelik çalışmalar artış göstermektedir. Böylece bulut bilişim sayesinde bir platforma bağımlı kalma durumu ortadan kalkmış olmakta ve istenilen platform (Linux, Windows vs.) kullanabilmektedir. Bu sistemlerde yüksek kapasiteli sunucular kullanıldığı için büyük depolama alanlarına sahip olunabilmektedir. Bu tez kapsamında, geliştirilen süper çözünürlük modelleri bulut ortamında çalıştırılarak her yerden erişilebilir bir sistem



meydana getirilmiştir. Bu sayede, kullanıcıların farklı uygulamalar için de bulut tabanlı bu sistemden faydalanabilmeleri sağlanmıştır.

Tez çalışması kapsamında, derin öğrenme modellerinden yararlanarak düşük maliyetli termal kameradan elde edilen düşük çözünürlüklü termal görüntülerden süper çözünürlüklü termal görüntüler meydana getirilmiş olup, bu süper çözünürlük modelinin bulut ortamında çalışması sağlanmıştır. Böylece geleneksel termal kamera sistemlerinin getirdiği yüksek maliyet probleminin ortadan kaldırılması amaçlanmıştır. Bu çalışmada, akıllı telefon veya tablet bilgisayar vasıtasıyla kullanılabilen düşük maliyetli termal kamera ile görüntü çekimleri kolay bir şekilde gerçekleştirilmiş ve elde edilen termal görüntüler bulut ortamına yüklenerek süper çözünürlük modeli çalıştırılmıştır. Ayrıca, yenidoğan bebeklerin termal görüntüleri üzerinde sınıflama uygulamaları gerçekleştirilmiştir. Elde edilen sonuçlar, süper çözünürlük metodlarının sınıflama başarılarını artırdığını göstermiş olup, düşük maliyetli termal kameraların hastalık teşhisi vb. durumlar için alternatif bir çözüm olarak kullanılabilirliğini desteklemiştir.

## 2. KAYNAK ARAŞTIRMASI

Süper çözünürlük, ilk defa 1968 yılında Papoulis tarafından kullanılan bir terimdir. Tsai ve Huang ise 1984 yılında önerdiği süper çözünürlük algoritmasında ilk defa birden fazla görüntüden faydalanmıştır (Toyran, 2008). Daha sonra donanım sektöründeki gelişmeler ile birlikte interpolasyon ve bilhassa yapay zeka tabanlı süper çözünürlük uygulamaları yaygınlaşmıştır. Derin öğrenme algoritmaları kullanılarak gerçekleştirilen ilk süper çözünürlük çalışmalarında evrişimli sinir ağları (ESA) tabanlı modeller geliştirilmiştir (Anwar ve ark., 2020). İlk olarak “Super Resolution Convolutional Neural Network (SRCNN)” modeli sunulmuş ve düşük çözünürlüklü ile yüksek çözünürlüklü görüntüler arasında baştan sona haritalama (end to end mapping) tekniğinden faydalanılmıştır (Dong ve ark., 2016). Aynı çalışma ekibi tarafından “Fast Super Resolution Convolutional Neural Network (FSRCNN)” modeli geliştirilmiş olup, düşük çözünürlüklü görüntülerden özellik haritaları çıkarılarak derin ağın son katmanında üst ölçekleme (up-scaling) uygulanmıştır. Bu model SRCNN modeline kıyasla daha başarılı sonuçlar sağlamış olup, TSGO değerlerinde 0,3-0,6 dB aralığında artış gerçekleşmiştir (Dong ve ark., 2016). Daha sonra SRCNN modeline dayanarak geliştirilen “Very Deep Super Resolution (VDSR)” modelinde artık öğrenme (residual learning) yönteminden faydalanılmıştır. Ayrıca evrişim katmanlarının sayısı 3 yerine 20 olarak düzenlenmiş ve görüntü kalite metrikleri (TSGO-YBİ) dikkate alındığında daha başarılı sonuçlar gözlemlenmiştir. Dört farklı veri seti ile gerçekleştirilen uygulamalarda TSGO değeri 0,5-1 dB aralığında artış göstermiştir. Ayrıca YBİ değerleri dikkate alındığında %1-3 aralığında artış gerçekleşmiştir (Kim ve ark., 2016). Yine artık öğrenme yöntemiyle geliştirilen “Enhanced Deep Super Resolution (EDSR)” modelinin kullanıldığı başka bir çalışmada da derin ağın hem başarısı hem de eğitim hızı artış göstermiştir. Burada EDSR modelinin TSGO değerinin VDSR modeline göre 0,5-1,5 dB aralığında arttığı, YBİ değerinin ise yaklaşık %2 arttığı görülmüştür (Lim ve ark., 2017). Bahsedilen ESA tabanlı bu uygulamalar daha çok ortalama kare hata (OKH) değerini minimize etmeye yöneliktir; fakat son yıllarda görsel olarak daha kaliteli görüntüler elde edebilmek amacıyla çekişmeli üretici ağlar (ÇÜA) tabanlı birçok model önerilmiştir. İlk olarak SRGAN modeli geliştirilmiş ve bu modelin üretici ağ kısmında “Residual Networks (ResNet)” modeline benzer şekilde bağlantı atlama (skip connection) tekniği kullanılmıştır. SRGAN modeli, görsel olarak ESA tabanlı yöntemlere kıyasla daha başarılı sonuçlar elde edilmesini sağlamıştır (Ledig ve ark.,

2017). Böylece ÇÜA tabanlı süper çözünürlük uygulamalarına olan ilgiyi artırmıştır (Zhu ve ark., 2017). Daha sonra çift ayırt edici ağ kullanılarak gerçekleştirilen çalışmada, SRGAN modeline göre TSGO değerlerinde 1 dB, YBİ değerlerinde ise %2 artış gözlenmiştir (Huang, 2020). Hiperspektral görüntülerin kullanıldığı başka bir uygulamada ise çekişmeli üretici ağlar tabanlı model kullanılmış ve SRGAN modeli ile karşılaştırıldığında TSGO değerlerinde 1,5 dB, YBİ değerlerinde ise %2 daha başarılı sonuçlar elde etmiştir (Zhang ve ark., 2021). Çekişmeli üretici ağlar tabanlı modellerden medikal alanda da faydalanılmış ve prostat kanserinin erken teşhisiyle ilgili bir çalışma gerçekleştirilmiştir. Burada, MR görüntüleri kullanılarak belirli üst ölçekleme faktörü (x8) için TSGO ile YBİ değerlerinde sırasıyla 19,77 ve 0,60 değerleri elde edilmiş olup, literatürdeki diğer çalışmalara göre daha başarılı sonuçlara ulaşılmıştır. Ayrıca bir sınıflama uygulaması gerçekleştirilerek, prostat görüntülerinin %6 daha yüksek doğrulukta sınıflandığı görülmüştür (Shen ve ark., 2021).

Görünür görüntüler üzerindeki süper çözünürlük uygulamalarında elde edilen başarılar ve donanımsal ilerlemeler neticesinde, termal görüntüler üzerinde de çeşitli süper çözünürlük uygulamaları gerçekleştirilmiştir. Bu alanda ilk olarak ESA tabanlı “Thermal Image Enhancement using Convolutional Neural Network (TEN)” modeli geliştirilmiştir. Bu çalışmada kısıtlı veri setine sahip olduğu için modelin eğitimi sürecinde renkli (RGB) görünür görüntülerden faydalanılmıştır (Choi ve ark., 2016). Yine ESA tabanlı geliştirilen ve artık öğrenme metodundan faydalanılan çalışmada; gri, açıklık, yoğunluk ve parlaklık olmak üzere 4 RGB tabanlı alanın değerlendirilmesi sonucunda, termal görüntüyü geliştirmek için en iyi sonucun parlaklık alanında elde edildiği görülmüştür (Lee ve ark., 2017). Daha sonra, eğitim sürecinde de termal görüntüler kullanılarak görsel olarak daha başarılı sonuçlara ulaşılmış ve TSGO değerinin yaklaşık 0,7 dB artış gösterdiği belirtilmiştir (Rivadeneira ve ark., 2019). ESA tabanlı geliştirilen model ile gerçekleştirilen diğer bir uygulamada ise x8 üst ölçekleme faktörü için süper çözünürlüklü termal görüntüler elde edilmiştir (He ve ark., 2019). Yine geliştirilen çoklu görüntülü süper çözünürlük (MISR) modeli kullanılarak süper çözünürlüklü termal görüntüler oluşturulmuştur. Elde edilen sonuçlar, önerilen modelin hem görünür hem de termal görüntülerde etkinliğini göstermiştir. Burada, süper çözünürlüklü ve referans görüntüler arasındaki farklılıkların bikübik interpolasyon ile karşılaştırıldığında sırasıyla %18 ve %25 azaldığı gözlenmiştir (Mandanici ve ark., 2019). Bu çalışmaların dışında kontrast ve parlaklık iyileştirme gibi çeşitli termal görüntü iyileştirme çalışmaları da ortaya konulmuştur. Bu görüntü iyileştirme

uygulamalarında ESA ağının çıkışında elde edilen artık görüntünün düşük çözünürlüklü termal görüntüye eklenmesiyle süper çözünürlüklü termal görüntü elde edilmektedir. Daha sonra, ÇÜA tabanlı modeller geliştirilerek ve sahne bilgileri de kullanarak süper çözünürlük uygulamaları gerçekleştirilmiştir. Bu çalışmada, görünür görüntünün dokusuna sahip yüksek çözünürlüklü görüntüler oluşturmak için stil görüntüsü olarak aynı çözünürlük, sahne ve görüş alanının görünür görüntüleri kullanılmıştır. (Liu ve ark., 2019). Ayrıca, geliştirilen CycleGAN modeli kullanılarak x2 üst ölçekleme tekniği için önemli bir başarı elde edilmiştir. (Rivadeneira ve ark., 2020). Diğer bir çalışmada ise termal yüz görüntüleri üzerinde süper-çözünürlük uygulaması gerçekleştirmek amacıyla “The Deep Convolutional Generative Adversarial Network (DCGAN)” modeli sunulmuştur. Burada, 16x16 boyutlarındaki düşük çözünürlüklü görüntüler üst ölçeklenerek 64x64 boyutlarındaki süper çözünürlüklü termal yüz görüntüleri elde edilmiştir. Testler, yakın kızılötesi (NIR) ve uzun dalga kızılötesi (LWIR) spektrumunda çalışan farklı kızılötesi yüz veri setleri kullanılarak yapılmıştır. Önerilen sistemin iyi performans gösterdiği ve yüzün önemli ayrıntılarını koruduğu görülmüştür. Böylece güvenlik uygulamaları için kalabalığın içindeki yüzlerin taranabileceği veya uzaktaki yüzlerin tespit edebileceği, kızılötesi veya multi spektral bir yüz tanıma sisteminin oluşturulabileceği gösterilmiştir (Guei ve Akhloufi, 2018). Termal görüntülerde çözünürlük iyileştirme nesne tanıma çalışmaları için de kullanılmaktadır. Böylece tespit edilecek nesne hakkındaki faydalı bilgi en üst düzeye çıkarılabilmekte ve hedef tespit-tanıma sistemlerinde nesneyi tanımayı daha verimli hale getirilebilmektedir (Zhang ve ark., 2018). Uzun menzilli kızılötesi görüntülerde, loş hedef ve arka plandaki engeller nesne tespit-tanıma uygulamalarında büyük problem teşkil etmektedir. Buna çözüm olarak; ESA tabanlı bir ağ kullanılarak görüntüdeki hedef ile arka plan arasındaki kontrastın artırılması sağlanarak hedeflenen kısım belirginleştirilmiştir (Fan ve ark., 2018). Termal görüntüleme tıp alanında da yaygın bir şekilde kullanılmakta ve termal görüntünün iyileştirilmesi çalışmaları bu alanda da gelişim göstermektedir. Örnek bir çalışmada, diyabet hastalarına ait termal ayak görüntülerini elde etmek için Android akıllı telefona bağlı bir termal kamera kullanılmıştır. Dört farklı ayak görüntüsü üzerinde testler gerçekleştirilmiş ve sıcaklık değişimlerinin yerleri doğru bir şekilde belirlenmiştir. Sonuç olarak, diyabetik ayak ülser gelişiminin erken tespitine yönelik uygulamalar başarılı şekilde tamamlanmış ve diyabet hastalarına olası ayak ülserlerini kendi kendilerine kontrol edebilme imkanı sağlanmıştır (Fraiwan ve ark., 2017). Biyomedikal alanda gerçekleştirilen diğer bir çalışmada ise düşük doz BT

(bilgisayarlı tomografi) ve düşük alan MR (manyetik rezonans) görüntüleri üzerinde süper çözünürlük uygulamaları yerine getirmek amacıyla MedSRGAN modeli geliştirilmiştir (Gu ve ark., 2020). Farklı üst ölçekleme teknikleri üzerinde de uygulamalar yapmak amacıyla geliştirilen TherISuRNet modeli kullanılarak, 3 adet üst ölçekleme faktörü (x2, x3, x4) üst ölçekleme faktörü için süper çözünürlük çalışmaları gerçekleştirilmiştir. Burada, termal görüntülerden oluşan üç farklı hazır veri seti (PBVS, FLIR, KAIST) kullanılmıştır (Chudasama ve ark., 2020). Son olarak orijinal bir veri seti üzerinde süper çözünürlük uygulamaları gerçekleştirmek amacıyla yenidoğan bebeklere ait termal görüntülerden oluşan veri seti işletilmiş, x4 üst ölçekleme faktörü için süper çözünürlük teknikleri uygulanmıştır. Bu çalışmada “ÇÜA tabanlı geliştirilen Termal Süper Çözünürlük Çekişmeli Üretici Ağlar (TSCÇÜA)” modeli kullanılmış ve hasta-sağlıklı bebek sınıflaması yapabilmek için evrişimli sinir ağları tabanlı geliştirilen bir sınıflayıcı model tasarlanmıştır (Senalp ve Ceylan, 2022). Daha sonra, aynı çalışma ekibi tarafından veri seti büyütülmüş ve farklı üst ölçekleme teknikleri (x2, x4, x8) için süper çözünürlük uygulamaları gerçekleştirilmiştir. Burada, aynı görüntü grubuna (x4) ait termal görüntüler dikkate alındığında sınıflama başarısının %94,5’ten %96’ya yükseldiği görülmüştür (Senalp ve Ceylan, 2021).

Büyük veri ve dijitalleşme, bulut teknolojileri tabanlı uygulamalara olan ilgiyi önemli ölçüde artırmıştır. Gerçekleştirilen bir çalışmada bilgisayar ve akıllı telefonlar için akıllı bulut sistemi önerilmiştir. Burada, adli soruşturmalara ait termal görüntülerin iyileştirilmesine yönelik frekans domeninde lokal ve global görüntü işlemeye dayalı yeni bir algoritma geliştirilmiştir. Bu görüntü iyileştirme tekniği neticesinde daha fazla kontrast ve detay içeren termal görüntülerin meydana geldiği görülmüştür. Ayrıca, bu bulut tabanlı sistem oluşturulurken güvenlik altyapısı da dikkate alınmıştır (Voronin ve ark., 2018).

### 3. MATERYAL VE YÖNTEM


Tez çalışması kapsamında, farklı süper çözünürlük uygulamaları için iki farklı veri seti kullanılmış olup, iki farklı süper çözünürlük yaklaşımı ve evrişimli sinir ağı tabanlı bir sınıflayıcı model geliştirilmiştir.

Bu bölümde; oluşturulan veri tabanları, derin öğrenme yöntemleri, uygulanan görüntü ön işleme teknikleri, elde edilen deneysel sonuçların değerlendirilmesinde kullanılan metrikler ve bulut ortamı hakkında detaylı bilgiler yer almaktadır.

#### 3.1. Yenidoğan Bebeklere Ait Termal Görüntü Veri Tabanı

Bu veri tabanındaki termal görüntüler Selçuk Üniversitesi Tıp Fakültesi Yenidoğan Yoğun Bakım Ünitesi'nde (YYBÜ) elde edilmiştir. Bu termal görüntüler, TÜBİTAK tarafından desteklenmiş olan 215E019 numaralı “Yenidoğan Yoğun Bakım Üniteleri İçin Termal Görüntüleme Tabanlı Ön-Teşhis Sistemi” projesi kapsamında IRBIS yazılımı ve bir bilgisayar aracılığıyla renkli (RGB) formatta elde edilmiştir (Ornek ve ark., 2020).

Veri tabanının oluşturulması sürecinde 640x480 termal çözünürlüğe sahip Variocam HD termal kameradan faydalanılarak, yenidoğan bebeklere (neonatal) ait sağlıklı ve konjenital kalp hastası (KKH) bebeklerin termal görüntüleri elde edilmiştir. Kullanılan termal kameranın termal duyarlılığı 0,05°C' tir ve termal kamera supine pozisyondaki yenidoğanlardan 60-100 cm mesafeye yerleştirilmiştir (Savasci ve ark., 2020). Daha sonra termal kamera tarafından yakalanan görüntüler bilgisayar ortamına aktarılmış ve 640x480 görüntü boyutuna sahip olan termal görüntüler elde edilmiştir. Bu görüntülerden hasta ve sağlıklı bebeklere ait bazı örnekler Şekil 3.1'de yer almaktadır. Burada, üst satırdaki görüntüler sağlıklı bebeklere, alt satırdaki görüntüler hasta bebeklere ait termogramlardır. Oluşturulan bu veri tabanında 876 termal yenidoğan görüntüsü bulunmaktadır. Bu termal görüntülerin 438 tanesi sağlıklı bebeklere ait olup, 438 tanesi ise konjenital kalp hastası bebeklere aittir.



Şekil 3.1. Yenidoğan veri tabanına ait örnek termogramlar


### 3.2. Termal Yüz Görüntüleri ile Oluşturulan Veri Tabanı

Bu veri tabanının oluşturulması sürecinde teknik özellikleri Çizelge 3.1’de verilmiş olan iki farklı termal kamera kullanılmıştır. Bu kameralar ile 35 farklı kişiye ait yüksek ve düşük çözünürlüklü renkli formattaki termal yüz görüntüleri elde edilmiştir. Termal görüntülerin elde edilmesi için yapılan çekimler yaklaşık 24 °C oda sıcaklığına sahip kapalı bir ortamda gerçekleştirilmiştir. Ayrıca termal yüz görüntüleri alınacak kişiler, ortam sıcaklığına uyum sağlamaları amacıyla çekim işleminden en az 5 dk önce ortamda hazır bulunmuşlardır. İki farklı termal kameranın kullanıldığı görüntü çekimleri önce Variocam HD termal kamera sonra Flir One Pro termal kamera ile gerçekleştirilmiştir. Ayrıca Flir Tools programı vasıtasıyla yüksek ve düşük çözünürlüklü görüntüler arasındaki renk tonu farkları minimize edilmiştir. Böylece farklı termal kameralardan elde edilmelerine rağmen düşük çözünürlüklü - yüksek çözünürlüklü görüntü çiftleri aynı standartlara getirilmiştir.


Veri tabanı oluşturulurken yüksek çözünürlüklü termal görüntüler, 640x480 çözünürlüğe sahip Variocam HD termal kamera ile 1 metre ve 0,5 metre mesafeden çekimler yapılarak; düşük çözünürlüklü görüntüler ise 160x120 çözünürlüğe sahip Flir One Pro termal kamera kullanılarak elde edilmiştir. Flir One Pro termal kamerası Android işletim sistemi kullanan bir mobil cihaz üzerinde kullanılmıştır (Şekil 3.2). Elde edilen termal görüntü örnekleri Şekil 3.3’te yer almaktadır. Burada, ilk sütundaki görüntüler Flir kamera ile elde edilen düşük çözünürlüklü termal yüz görüntülerine, ikinci sütundaki görüntüler ise Variocam kamera ile elde edilen yüksek çözünürlüklü termal yüz görüntülerine aittir.

**Çizelge 3.1.** Termal kameraların teknik özellikleri

Teknik Özellikler	Variocam HD	Flir One Pro
Termal Çözünürlük	640x480	160x120
Hassasiyet	0,05 °C	0,07 °C
Ölçüm Aralığı	-20 °C - 400 °C	-40 °C - 2000 °C



**Şekil 3.2.** Tez çalışmasında kullanılan Flir One Pro termal kamera bağlantısı yapılmış mobil telefon



**Şekil 3.3.** İki farklı termal kameradan elde edilen örnek görüntüler

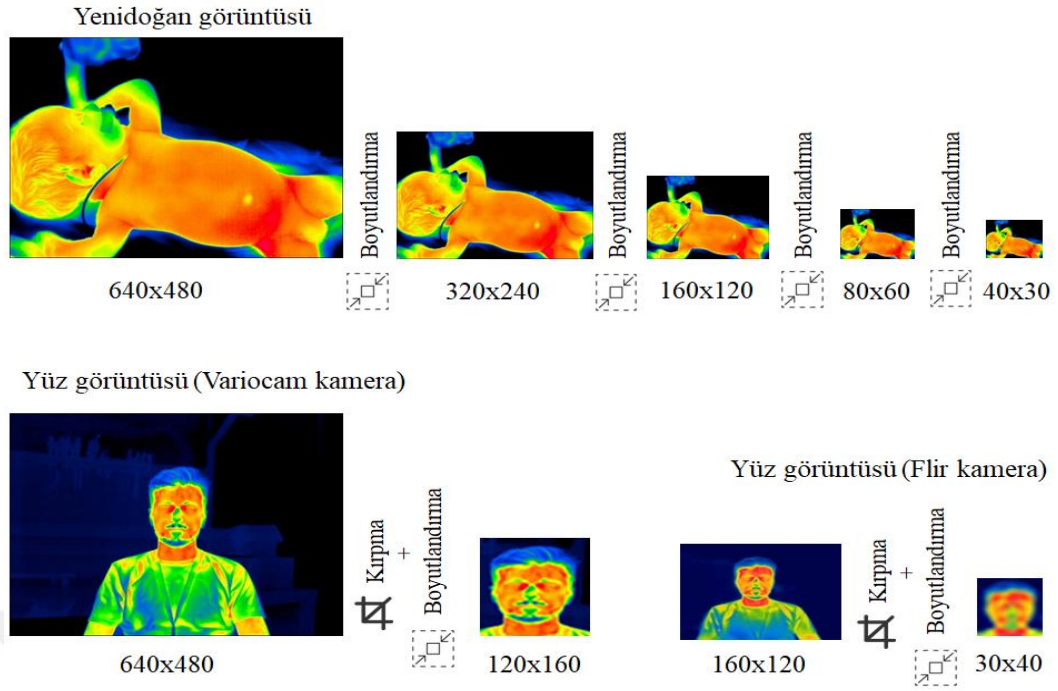


### 3.3. Görüntü Ön İşleme

Tez kapsamında, farklı üst ölçekleme oranlarında gerçekleştirilen süper çözünürlük uygulamaları için farklı boyutlarda görüntülere ihtiyaç duyulmaktadır. Bu sebeple termal kameralardan elde edilen orijinal görüntüler üzerinde yeniden boyutlandırma işlemleri yapılmıştır. Yenidoğan bebeklere ait termal görüntülerden (640x480) oluşan veri seti, x2, x4, x8 ve x16 üst ölçekleme oranlarında gerçekleştirilen süper çözünürlük uygulamalarına uygun olacak şekilde yeniden boyutlandırılmış ve sırasıyla 320x240, 160x120, 80x60, 40x30 boyutlarındaki düşük çözünürlüklü görüntüler elde edilmiştir. Böylece yüksek ve düşük çözünürlüklü görüntü çiftleri oluşturulmuştur. Her uygulama için referans görüntü boyutu sabit tutularak, düşük çözünürlüklü görüntüler üst ölçekleme oranına göre düzenlenmiştir.

Termal yüz görüntülerinden oluşan veri seti üzerinde ise ilk önce elde edilen ham görüntüler için kırpma ve boyutlandırma işlemleri gerçekleştirilmiştir. Daha sonra arka fondaki alanlar kırpılarak sadece yüz bölgesine odaklanılması sağlanmış ve bu görüntüler yeniden boyutlandırılmıştır. Burada, iki farklı termal kameradan elde edilen görüntülerin boyutları x4 üst ölçekleme oranı için gerçekleştirilen süper çözünürlük uygulamalarına uygun olacak biçimde düzenlenmiş ve düşük-yüksek çözünürlüklü görüntü çiftleri elde edilmiştir. Ham görüntülerden oluşan veri setinde yüksek çözünürlüklü görüntüler 640x480, düşük çözünürlüklü görüntüler ise 120x160 boyutundadır. Ayrıca, kırpılmış görüntülere ait veri setinde yüksek çözünürlüklü görüntülerin boyutlarına (120x160) göre 1/4 oranında olacak şekilde kırpılmış görüntüler yeniden boyutlandırılarak düzenlenmiş ve 30x40 boyutlarında düşük çözünürlüklü görüntüler elde edilmiştir.

Şekil 3.4'te termal yenidoğan ve yüz görüntülerine ait iki farklı veri seti için gerçekleştirilen görüntü ön işleme süreçleri görülmektedir. Yenidoğan görüntüleri için sadece boyutlandırma işlemi yapılırken, yüz görüntüleri için hem kırpma hem de boyutlandırma işlemleri gerçekleştirilmiştir.



Şekil 3.4. İki farklı veri seti için önerilen görüntü ön işleme prosesleri

### 3.4. Süper Çözünürlük Kavramı

Çözünürlük, bir görüntünün veya videonun keskinliğini ve netliğini tanımlamak için kullanılan bir ölçü olarak ifade edilebilmektedir. Genellikle monitörlerin, yazıcıların, dijital görüntülerin ve diğer çeşitli donanım ve yazılım teknolojilerinin kalitesini değerlendirmek için kullanılmaktadır.

Süper çözünürlük, düşük çözünürlüklü bir görüntünün çözünürlüğünü iyileştirerek daha yüksek çözünürlüklü görüntü elde etme tekniği olarak ifade edilmektedir (Şenalp ve Ceylan, 2022). Süper çözünürlük teknikleri; tıbbi görüntüleme, biyometrik tanıma ve uydu görüntüleme gibi birçok görüntü işleme uygulamasında önemli rol oynamaktadır. Düşük çözünürlüklü görüntüler, Denklem 3.1 kullanılarak yüksek çözünürlüklü görüntülerden modellenmektedir. Burada,  $I_y$  yüksek çözünürlüklü görüntüyü,  $I_x$  düşük çözünürlüklü görüntüyü,  $D$  görüntü bozulma fonksiyonunu ve  $\sigma$  ise gürültüyü ifade etmektedir. Bozulma parametreleri  $D$  ve  $\sigma$  bilinmeyen ifadeler olup, sadece yüksek ve düşük çözünürlüklü görüntüler bilinmektedir. Süper çözünürlük algoritmalarının görevi, yüksek ve düşük çözünürlüklü görüntüleri kullanarak bozulma fonksiyonunun tersini bulmaktır.

$$I_x = D(I_y; \sigma) \quad (3.1)$$


Süper çözünürlük tekniklerinin kullanım alanlarına örnek olarak; gözetim uygulamaları için güvenlik kameralarından elde edilen düşük çözünürlüklü görüntüler üzerinde yüz tespiti ve tanıma, sunucu maliyetlerini azaltma veya videolar üzerinde gerçek zamanlı çözünürlük artırma uygulamaları gösterilebilmektedir (Yue ve ark., 2018). Ayrıca, tarama süresi, uzamsal kapsama alanı ve sinyal-gürültü oranı söz konusu olduğunda yüksek çözünürlüklü MR görüntülerini elde edebilmek zor olabildiği için düşük çözünürlüklü MR görüntülerinden yüksek çözünürlüklü MR görüntülerinin oluşturulması medikal alandaki süper çözünürlük uygulamalarına örnek olarak verilebilmektedir (Gu ve ark., 2020).

### 3.5. Yapay Zeka Kavramı ve Derin Öğrenme Algoritmaları

Yapay zeka, belirli görevleri yerine getirmek için insan beyninin yapısını taklit eden ve topladığı bilgilere göre yinelemeli olarak kendisini iyileştirebilen sistemler olarak tanımlanmaktadır. Yapay zekâ pek çok biçimde kendini göstermektedir. 1956 yılında gerçekleştirilen Dartmouth Konferansı'nda John MC Carthy isim babası olduğu yapay zeka terimini ortaya atmıştır. Yapay zeka teriminin izi antik Mısır'a kadar sürülebilmektedir; fakat 1940'lı yıllarda bilgisayarın gelişimi ile birlikte insana benzer bir makine zekası oluşturabilmek mümkün hale gelmiştir. Diğer yandan bilişsel düşünme ve doğal dil, yapay zekanın büyümesini sağlamıştır. İlk yapay zeka programı, 1956 yılında Allen Newell, Herbert Simon tarafından yazılan *The Logic Theorist*'dir (Newell ve Simon, 1956). Bilgisayar biliminde yapay zeka, yapay sinir ağları (YSA), makine öğrenmesi (MÖ), derin öğrenme (DÖ) birçok alt disiplini içermektedir. Günümüzde yapay zeka, askeri, medikal, uzay ve telekomünikasyon gibi geniş kullanım alanlarına sahiptir. Makine öğrenimi, yapay zekanın bir alt bölümüdür ve büyüyen veri bilimi alanının önemli bir bileşenidir. İstatistiksel yöntemler kullanılarak geliştirilen algoritmalar; sınıflamalar veya tahminler yapmak üzere eğitilmekte ve veri madenciliği ile ilgili projelerde temel yöntemler olarak değerlendirilmektedir. Derin öğrenme ise aslında makine öğrenmesinin alt dalıdır ve nöral ağlar teknolojisi üzerinde çalışmaktadır. Derin öğrenme ile makine öğrenmesi terimlerinin birbirinden ayrıldığı esas nokta algoritmalarının öğrenme biçimidir. Derin öğrenme, uygulamadaki özellik çıkartma kısmını önemli derecede otomatikleştirmektedir. Böylece insan müdahalesini ortadan kaldırarak, daha büyük veri kümelerinin kullanılabilmesini sağlamaktadır (Aggarwal ve Kumar, 2018).

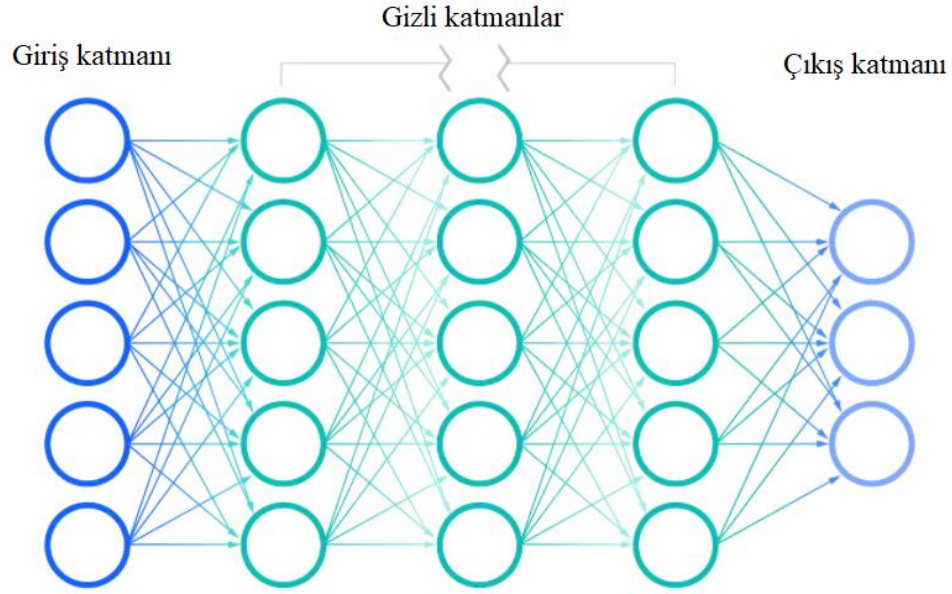
### 3.5.1. Yapay sinir ağları

Yapay sinir ağları (YSA), makine öğreniminin bir alt kümesidir ve derin öğrenme algoritmalarının dayandığı en temel yapılardır. Adları ve yapıları, biyolojik nöronların birbirine sinyal gönderme şeklini taklit ederek insan beyninden esinlenmiştir. Yapay sinir ağlarının tarihi 1943 senesine kadar uzanmaktadır. Matematikçiler McCulloch ve Walter Pitts, basit bir algoritmaya sahip olan ve insan beyninin işleyişine yaklaşmayı amaçlayan bir devre sistemi kurmuşlardır. Bu çalışmadan çıkan ana fikir, ikili eşiği olan nöronların Boole mantığıyla (0/1 veya doğru/yanlış ifadeleri) karşılaştırılmasıdır (McCulloch ve Pitts, 1943). Algılayıcı (perceptron), 1958'de Frank Rosenblatt tarafından oluşturulan en eski sinir ağıdır. Tek bir nörona sahiptir ve bir sinir ağının en basit şeklidir (Rosenblatt, 1958). Bu sinir ağının yapısı Şekil 3.5'te gösterilmektedir.



Şekil 3.5. Algılayıcı (perceptron)

Yapay sinir ağları (YSA), bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı içeren bir düğüm katmanından oluşmaktadır. Yapay sinir ağlarının genel yapısı Şekil 3.6'da gösterilmiştir. Bu yapı aynı zamanda çok katmanlı algılayıcılar (multi-layer perceptrons) olarak da adlandırılmaktadır. Her düğüm veya yapay nöron diğerine bağlanır ve ilişkili bir ağırlığa, eşiğe sahiptir. Herhangi bir düğümün çıktısı belirtilen eşik değerinin üzerindeyse, o düğüm etkinleştirilmekte ve ağın bir sonraki katmanına veri gönderilmektedir. Aksi takdirde, ağın bir sonraki katmanına hiçbir veri iletilmemektedir (Aggarwal ve Kumar, 2018).



Şekil 3.6. Yapay sinir ağı (YSA)

Her bir düğüm, girdi verileri, ağırlıklar, bir sapma (veya eşik) ve bir çıktıdan oluşan kendi doğrusal regresyon modeli olarak değerlendirilebilmektedir. Yapay sinir ağlarının matematiksel modeli Denklem 3.2’de verilmiştir. Burada,  $w$  ağırlıkları,  $x$  girdileri ve  $b$  ise yanlılık (bias) değerini temsil etmektedir.

$$\sum_i^m w_i \cdot x_i + b = w_1 x_1 + w_2 x_2 + \dots + w_m x_m + b \quad (3.2)$$

Bir girdi katmanı belirlendikten sonra ağırlıklar atanmaktadır. Bu ağırlıklar, herhangi bir değişkenin önemini belirlemeye yardımcı olmakta ve daha büyük olan ağırlıklar diğer girdilere kıyasla çıktıya daha fazla etkide bulunmaktadır. Tüm girdiler daha sonra ilgili ağırlıklarıyla çarpılmakta ve sonrasında toplanmaktadır. Daha sonra çıktı, çıktıyı belirleyen bir aktivasyon fonksiyonundan geçirilmektedir. Bu çıktı belirli bir eşiği aşarsa, ağıdaki bir sonraki katmana veri iletilerek düğüm etkinleştirilmektedir. Bu, bir düğümün çıktısının bir sonraki düğümün girdisi olmasına neden olmaktadır. Verileri bir katmandan sonraki katmana geçirme işlemi, bu sinir ağını ileri beslemeli bir ağ olarak tanımlamaktadır. Son olarak, çıktı katmanına iletilen girdilerden faydalanarak hata değeri hesaplanmakta ve geri yayılım algoritması kullanılarak önceki

katmanlardaki ağırlıklar güncellenmektedir. Bu süreç hedeflenen optimum başarı seviyesine ulaşılan kadar devam etmektedir (Ceylan, 2009).

Sinir ağlarının başarısı, mevcut veriler arasındaki ilişkiyi doğru bir şekilde öğrenme ve geliştirme açısından eğitim verilerine bağlı olmaktadır. Bununla birlikte, bu öğrenme algoritmaları iyi ayarlamalar yapıldığında, bilgisayar bilimi ve yapay zeka alanlarında güçlü araçlardır. Böylece bu algoritmalar, verilerin yüksek hızda doğru bir şekilde sınıflandırılmasını ve kümelenmesini mümkün hale getirmektedirler. Ayrıca sinir ağ modelleri, bilgisayarlı görü ve doğal dil işleme gibi alanların temel dayanağını oluşturmaktadırlar.

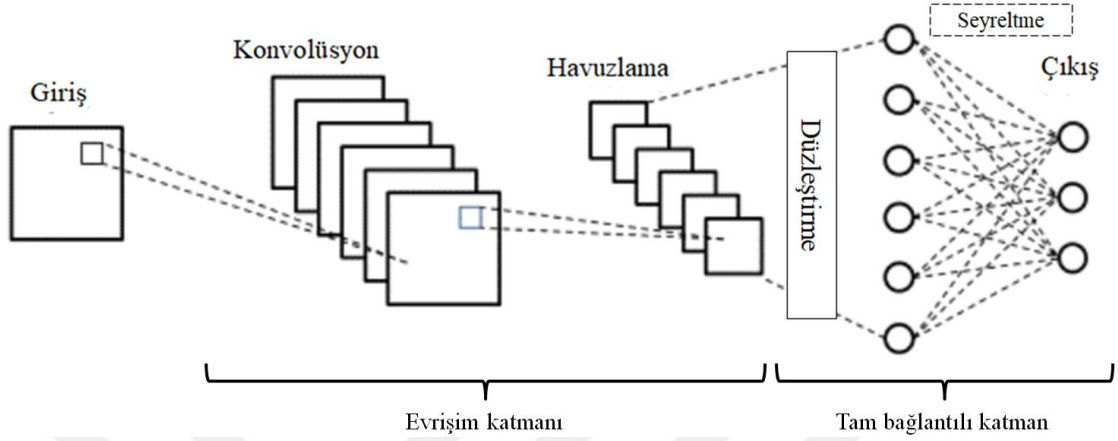
### 3.5.2. Evrişimli sinir ağları

Evrişimli sinir ağları (ESA), görüntülerden belirli özellikleri tanıyabilen, sınıflandırabilen ve görsel görüntüleri analiz etmek için yaygın olarak kullanılan bir derin sinir ağları sınıfı olarak tanımlanabilmektedir. Uygulama alanları, görüntü ve video tanıma, görüntü sınıflama, tıbbi görüntü analizi, bilgisayarlı görü ve doğal dil işlemeye kadar uzanmaktadır (Alzubaidi ve ark., 2021). ESA'daki 'Evrişim' terimi, bir fonksiyonun formunun diğeri tarafından nasıl değiştirildiğini gösteren bir integral işlemi olup, üçüncü bir fonksiyon üretmek için iki fonksiyonun çarpıldığı özel bir doğrusal işlem türü olan evrişimi (konvolüsyon) ifade etmektedir. Basit bir ifadeyle, matris olarak temsil edilebilen iki görüntünün çarpılarak, görüntüden özellikleri çıkarmak için kullanılan bir çıktının elde edilmesidir. İki boyutlu bir konvolüsyon işleminin matematiksel gösterimi Denklem 3.3'te verilmiştir. Burada,  $x[m,n]$  ifadesi girdi sinyalinin,  $h[m,n]$  ifadesi ise dürtü yanıtını göstermektedir.

$$y[m, n] = x[m, n] * h[m, n] = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} x[i, j] \cdot h[m - i, n - j] \quad (3.3)$$

Evrişimli sinir ağları; konvolüsyon katmanları, havuzlama (pooling) katmanları ve tam bağlantılı (fully connected) katmanlar olmak üzere 3 farklı katman türünden oluşmaktadır. Bu üç katmana ek olarak, seyreltme (dropout) katmanı ve aktivasyon fonksiyonu olan iki önemli parametre daha bulunmaktadır. Evrişimli sinir ağlarının mimarisi Şekil 3.7'de görülmektedir. Evrişim kısmı, 'Özellik Çıkarma' işlemi için

görüntünün çeşitli özelliklerini ayırarak ve tanımlayarak analiz etmektedir. Tam bağlantılı katman kısmı ise evrişim sürecinin çıktısını kullanmakta ve önceki aşamalarda çıkarılan özelliklere dayanarak görüntülerin sınıflarını tahmin etmektedir.



Şekil 3.7. Evrişimli sinir ağları (ESA)

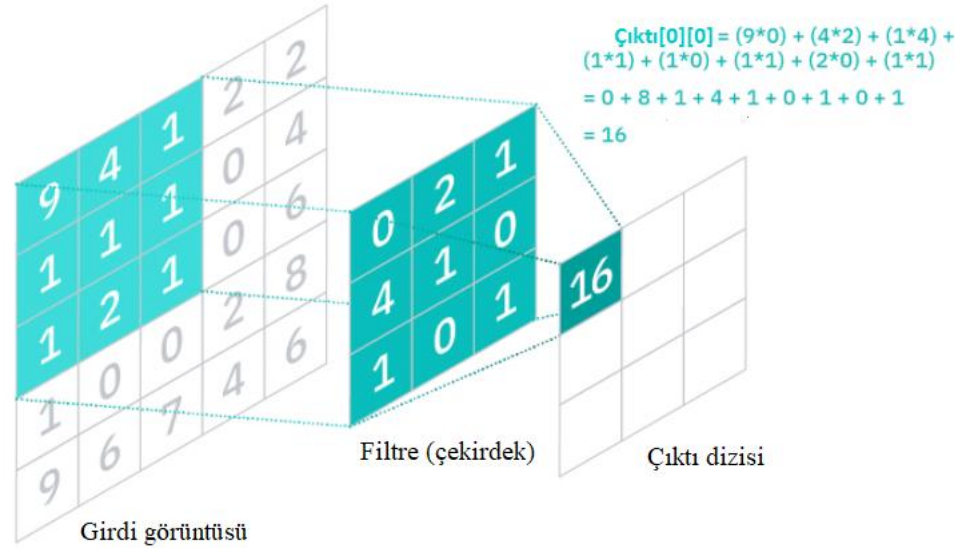
### 3.5.2.1. Konvolüsyon katmanı

Konvolüsyon (evrişim) katmanı, bir ESA mimarisinin temel yapı taşıdır ve hesaplamaların çoğunluğunun gerçekleştiği yerdir. Bu katman, girdi görüntülerinden çeşitli özellikleri çıkarmak için kullanılan ilk katmandır. Bu katmanda, girdi görüntüsü ile belirli bir  $M \times M$  boyutundaki filtre arasında matematiksel konvolüsyon işlemi gerçekleştirilmektedir. Filtre giriş görüntüsünün üzerinde kaydırılarak, filtrenin boyutuna ( $M \times M$ ) göre filtre ile giriş görüntüsünün parçaları arasında iç çarpım yapılmaktadır. Daha sonra, filtre bir adım kaydırılmakta ve çekirdek (filtre) tüm görüntüyü tarayana kadar işlem tekrarlanmaktadır. Böylece, nokta çarpımları serisinin son çıktısı elde edilmektedir. Özellik haritası olarak adlandırılan bu çıktı, köşeler ve kenarlar gibi görüntü hakkında bilgiler içermektedir. Daha sonra, bu özellik haritası, girdi görüntüsünün diğer bazı özelliklerini öğrenmek için sonraki konvolüsyon katmanlarını beslemektedir. Şekil 3.8’de gösterilen örnek konvolüsyon işleminde de görüldüğü üzere, özellik haritasındaki her bir çıkış değeri giriş görüntüsündeki her bir piksel değerine bağlı olmamakta ve yalnızca filtrenin uygulandığı  $3 \times 3$  boyutundaki alana bağlanmaktadır. Çıkış dizisinin her bir giriş değerine doğrudan eşlenmesi

gerektiğinden, evrişim (ve havuzlama) katmanlarına “kısmen bağlı” katmanlar da denilmektedir (Dargan ve ark., 2019).

Özellik haritasının oluşturulması sırasında filtre görüntü boyunca hareket ederken ağırlıklar sabit kalmaktadır. Ağırlık değerleri, eğitim sırasında geri yayılım ve gradyan inişi süreci boyunca ayarlanmaktadır. Ancak, sinir ağının eğitimi başlamadan önce ayarlanması gereken ve çıktının hacimsel boyutunu etkileyen üç hiperparametre bulunmaktadır. Bunlar şu şekildedir:

- **Filtre sayısı** çıktının derinliğini etkilemektedir. Örneğin; 3 farklı katman kullanılması durumunda 3 farklı özellik haritası elde edilmiş olmaktadır.
- **Adım** (stride), çekirdeğin giriş matrisi üzerinde hareket ettiği mesafe veya piksel sayısıdır. İki veya daha büyük adım değerleri nadir kullanılmakla birlikte, büyük bir adım kullanılması durumunda çıktı o derece daha küçük boyutta elde edilmektedir.
- **Sıfır dolgu** (zero padding) genellikle filtreler giriş görüntüsüne uymadığı zaman kullanılmaktadır. Burada, giriş matrisinin dışında kalan tüm öğeler sıfıra ayarlanmaktadır. Böylece daha büyük veya eşit boyutlu bir çıktı üretilmektedir.

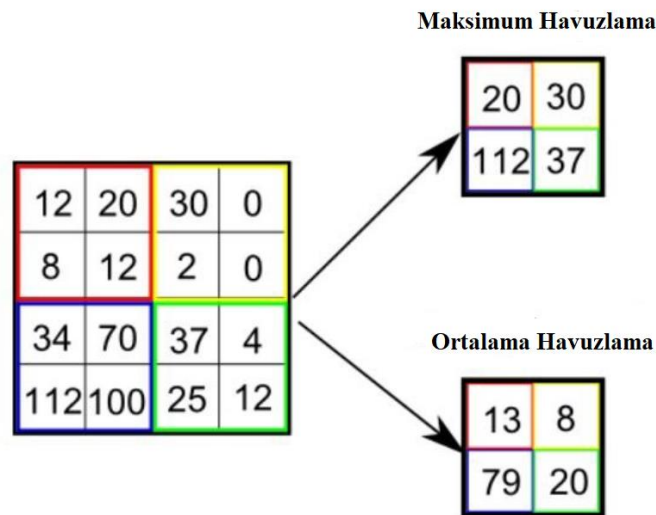


Şekil 3.8. Konvolüsyon katmanlarında filtre işlemi (IBM, 2021)



### 3.5.2.2. Havuzlama katmanı

ESA’larda genellikle bir evrişim katmanını bir havuzlama katmanı izlemektedir. Bu katmanın birincil amacı, hesaplama maliyetlerini azaltmak için özellik haritasının boyutunu küçültmektir. Bu işlem, katmanlar arasındaki bağlantıları azaltarak gerçekleştirilmekte ve her bir özellik haritasında bağımsız olarak çalışmaktadır. Kullanılan yönteme bağlı olarak birkaç tür havuzlama işlemi vardır. Maksimum havuzlama işleminde en büyük eleman özellik haritasından alınmaktadır. Ortalama havuzlama işleminde ise önceden tanımlanmış boyutta bir görüntü bölümündeki öğelerin ortalaması hesaplanmaktadır. Maksimum ve ortalama havuzlama yöntemlerine dair örnekler Şekil 3.9’da gösterilmiştir. Burada, havuzlama işleminin 2x2 çerçeve boyutunda yapıldığı ve bu çerçeve matrislerinin tüm görüntü üzerinde dolaştırıldığı görülmektedir. İlk çerçeve incelendiğinde, maksimum havuzlama uygulanması halinde 20 değerinin, ortalama havuzlama uygulandığında ise  $(12+20+8+12)/4=13$  değerinin çıkış matrisine iletiği görülmektedir. Havuzlama katmanı genellikle evrişim katmanı ile tam bağlantılı katman arasında bir köprü görevi görmektedir. Havuzlama katmanında çok fazla bilgi kaybolmasına rağmen evrişimli sinir ağlarına birtakım avantajlar da sağlamaktadır. Havuzlama katmanları; karmaşıklığı azaltmaya, verimliliği artırmaya ve aşırı öğrenme (İng., over fitting) riskini sınırlandırmaya yardımcı olmaktadır (Dong ve ark., 2015).

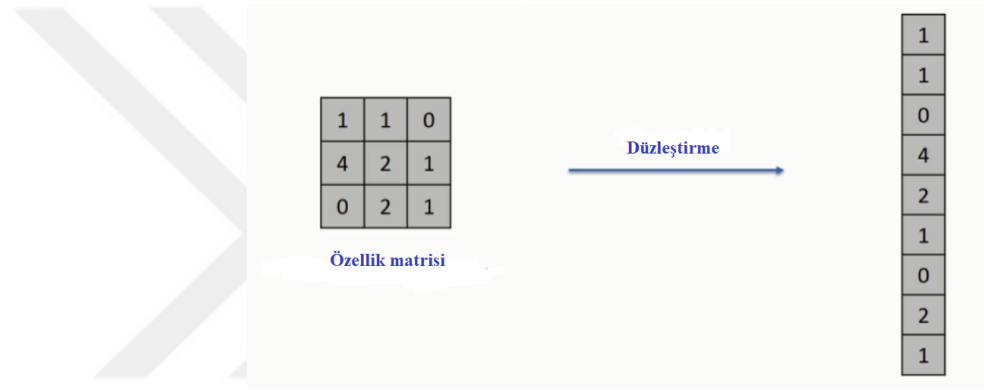


Şekil 3.9. Maksimum ve ortalama havuzlama

### 3.5.2.3. Düzleştirme katmanı

ESA mimarisinde konvolüsyon ve havuzlama katmanlarından sonra düzleştirme (flatten) katmanı gelmektedir. Konvolüsyon ve havuzlama katmanları bir modelde birden fazla kullanılabilir. Bu süreç tamamlandıktan sonra elde edilen özellik matrislerinin tam bağlantılı katmanda kullanılabilmesi için vektör haline getirilmesi gerekmektedir. Böylece tam bağlantılı katmanın girişleri hazır hale gelmiş olmaktadır.

3x3 boyutunda örnek bir matris üzerinde uygulanan düzleştirme işlemi ve sonrasında elde edilen 9x1 boyutundaki vektör Şekil 3.10'da gösterilmiştir.



Şekil 3.10. Düzleştirme işlemi

### 3.5.2.4. Tam bağlantılı katman

Bir sinir ağındaki tam bağlantılı katmanlar, bir katmandaki tüm girdilerin bir sonraki katmanın her aktivasyon birimine bağlandığı katmanlardır. Yani tam bağlantılı katmanda, çıktı katmanındaki her bir düğüm, bir önceki katmandaki bir düğüme doğrudan bağlanmaktadır. Tam bağlantılı katman, nöronlarla birlikte ağırlık (İng., weight) ve yanlıktan (İng., bias) oluşmakta olup, nöronları iki farklı katman arasında bağlamak için kullanılmaktadır. Bu katmanlar genellikle çıkış katmanından önce yerleştirilmekte ve bir ESA mimarisinin son birkaç katmanını oluşturmaktadırlar. Burada, önceki katmanlardan gelen girdi görüntüsü düzleştirilmekte (düzleştirme katmanı) ve tam bağlantılı katman beslenmektedir. Daha sonra, düzleştirilmiş vektör matematiksel fonksiyon işlemlerinin gerçekleştiği birkaç tam bağlantılı katmandan daha geçmektedir. Bu aşamada sınıflama işlemi gerçekleştirmeye başlamaktadır. Önceki

katmanlardan ve bunların farklı filtrelerinden çıkarılan özniteliklere dayalı olarak sınıflama görevi yerine getirilmektedir. Evrişim ve havuzlama katmanları genellikle ReLu gibi aktivasyon fonksiyonlarını kullanma eğilimindeyken, tam bağlantı katmanları genellikle girdileri uygun şekilde sınıflamak için bir softmax aktivasyon fonksiyonundan yararlanarak 0 ile 1 arasında bir olasılık üretmektedirler.

### 3.5.2.5. Seyreltme katmanı

Genellikle tüm özellikler tam bağlantılı katmana bağlandığında, eğitim veri setinde aşırı öğrenme meydana gelebilmektedir. Bu durum, belirli bir modelin eğitim süreci sonunda başarılı bir sınıflama yaptığı görüldükten sonra yeni bir veri seti üzerinde kullanıldığında, modelin performansında olumsuz bir etkiye neden olabilmektedir. Bu sorunun üstesinden gelmek için, eğitim süreci sırasında sinir ağından birkaç nöronun çıkarıldığı ve modelin boyutunun küçültüldüğü bir seyreltme katmanı kullanılmaktadır. Örneğin; 0,3'lük bir seyreltme değeri seçildiğinde, düğümlerin %30'u sinir ağından rastgele çıkarılmaktadır. Böylece hem aşırı öğrenme probleminin önüne geçilmekte hem de ağır eğitim hızı artırılmaktadır.

### 3.5.2.6. Aktivasyon fonksiyonları

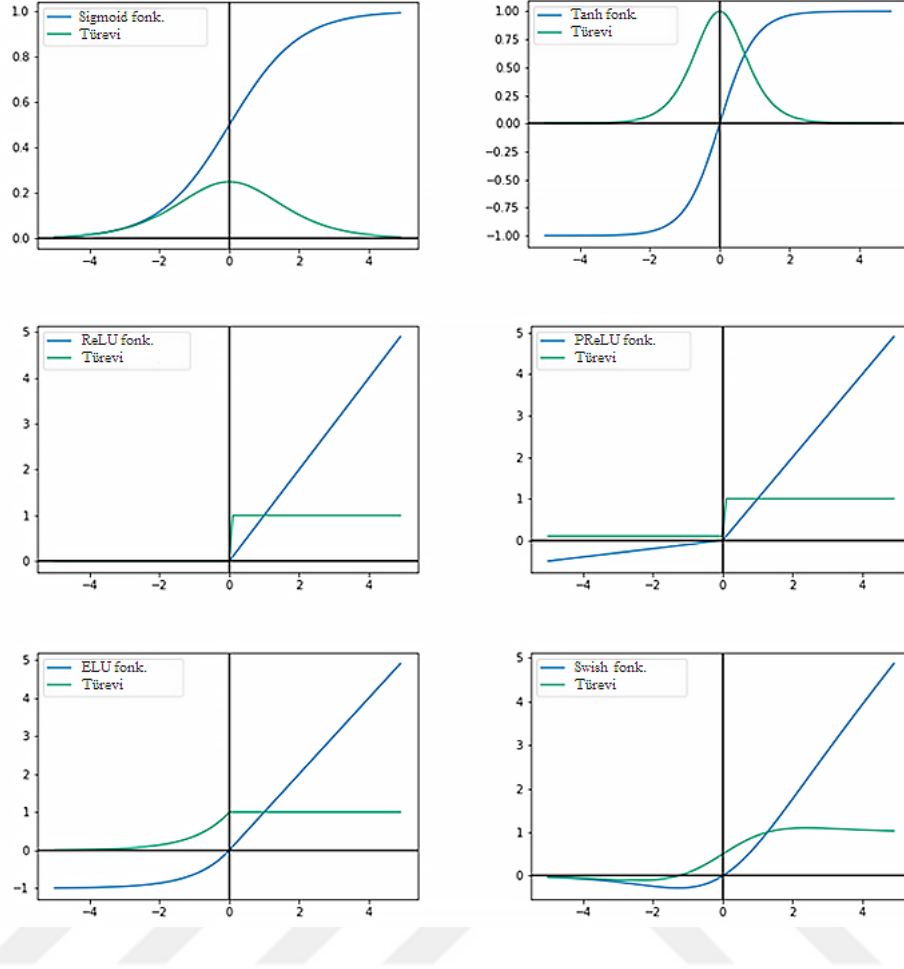
Bir sinir ağındaki bir aktivasyon fonksiyonu, girdinin ağırlıklı toplamının bir düğümden veya ağ katmanındaki düğümlerden bir çıktıya nasıl dönüştürüleceğini tanımlamaktadır. Evrişimli sinir ağlarının da en önemli parametrelerinden biri aktivasyon fonksiyonlarıdır. Aktivasyon fonksiyonları, ağın değişkenleri arasındaki her türlü sürekli ve karmaşık ilişkiyi öğrenmek ve tahmin etmek için kullanılmaktadırlar. Basit bir ifadeyle, modelin hangi bilgilerinin sonraki katmana iletileceğine ve hangilerinin ağın çıkışına etki etmemesi gerektiğine karar vermektedirler. Aktivasyon fonksiyonları tipik olarak türevlenebilirdirler, yani verilen bir girdi değeri için birinci dereceden türev hesaplanabilmektedir. Bu işlem, modelin ağırlıklarını güncellemek için tahmin hatasının türevini gerektiren hata algoritmasının, ağın eğitiminde kullanılan geri yayılım yönteminde kullanılmasından dolayı gerekmektedir. Ayrıca aktivasyon fonksiyonları derin ağa doğrusal olmama (İng., non-linearity) özelliği katmaktadırlar. Aktivasyon fonksiyonunun seçimi, bir sinir ağının kapasitesi ve performansı üzerinde büyük bir etkiye sahip olup, modelin farklı bölümlerinde farklı aktivasyon fonksiyonları

kullanılabilmektedir. Örneğin; ReLU, softmax, tanh ve sigmoid fonksiyonları gibi çeşitli uygulamalarda kullanılan aktivasyon fonksiyonları mevcuttur. Bu fonksiyonların her birinin kullanımını uygulamaya göre değişkenlik göstermektedir. İkili sınıflama ESA modeli için sigmoid ve softmax fonksiyonları tercih edilirken, çok sınıflı bir sınıflama için genellikle softmax fonksiyonu kullanılmaktadır (Rasamoelina ve ark., 2020).

Derin öğrenme ve bilgisayarlı görü alanlarında yaygın olarak kullanılan sigmoid, tanh, ReLU, Leaky Relu, PReLU, ELU, Swish, Mish ve softmax aktivasyon fonksiyonlarının denklemleri ve değer aralıkları Çizelge 3.2’de verilmiştir. Ayrıca, bazı aktivasyon fonksiyonlarının ve türevlerinin grafikleri Şekil 3.11’de gösterilmiştir.

**Çizelge 3.2.** Yaygın olarak kullanılan aktivasyon fonksiyonlarının matematiksel ifadeleri

Aktivasyon fonksiyonu	Denklem	Değer aralığı
Sigmoid	$\frac{1}{1 + e^{-x}}$	(0, 1)
Tanh	$\frac{2}{1 + e^{-2x}} - 1$	(-1, 1)
ReLU	$\max(0, x)$	$[0, \infty)$
Leaky ReLU	$\max(0, x) + \alpha \cdot \min(0, x)$	$(-\infty, +\infty)$
PReLU	$\max(0, x) + \alpha \cdot \min(0, x)$	$(-\infty, +\infty)$
ELU	$\max(0, x) + \min(0, \alpha \cdot (e^x - 1))$	$(-\alpha, +\infty)$
Swish	$\frac{x}{1 + e^{-x}}$	$(\approx -0,2784, +\infty)$
Mish	$x \tanh(\log(1 + e^x))$	$(\approx -0,3088, +\infty)$
Softmax	$\frac{e^i}{\sum_{j=0}^k e^j}, i=0,1,\dots,k$	(0, 1)

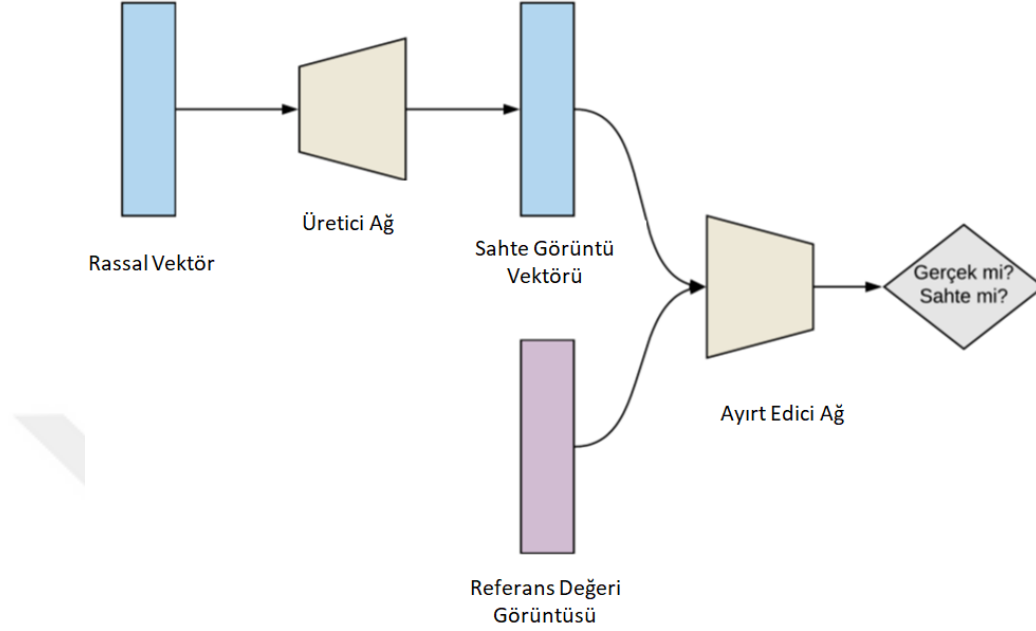


Şekil 3.11. Aktivasyon fonksiyonları ve bu fonksiyonların türevleri

### 3.5.3. Çekişmeli üretici ağlar

Çekişmeli üretici ağlar (ÇÜA), verilerden örnekleri otomatik olarak keşfeden ve öğrenen denetimsiz bir öğrenme algoritmasıdır. Bu örnekleri öğrendikten sonra çıktı olarak girdi ile aynı özelliklere sahip yeni veriler üretmektedirler. Çekişmeli üretici ağlar, üretici (generator) ve ayırt edici (discriminator) olmak üzere iki alt modele bölünmüş bir derin ağ modeli olarak tanımlanabilmektedir. ÇÜA mimarisi Şekil 3.12’de gösterilmiştir. Burada, üretici model girdiden yeni görüntüler üretmeye çalışırken, ayırt edici model ise verilerin veri kümesinden gerçek bir görüntü mü yoksa yapay olarak oluşturulmuş görüntülerden (sahte) mi olduğunu belirlemektedir. Ayırt edici ağ modeli genellikle evrişimli sinir ağı formunda ikili bir sınıflandırıcı olarak işlev görmektedir. Her bir döngüde her iki model de sonuçlarını iyileştirmeye çalışır, çünkü üretici ağ modelinin amacı görüntüyü tanımlamada ayırt edici ağ modelini yanıltmak iken, ayırt

edici ağın amacı ise sahte görüntüleri doğru bir şekilde tespit etmektir (Goodfellow ve ark., 2014).



Şekil 3.12. Çekişmeli üretici ağlar (ÇÜA)

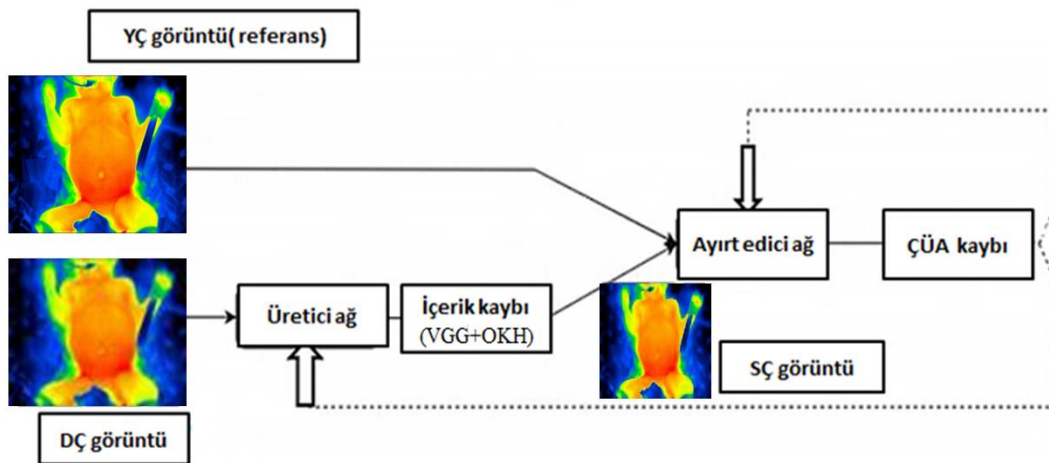
Üretici ve ayırt edici ağların optimizasyonu için çekişmeli üretici ağların eğitimi sırasında her iki ağın da kayıp fonksiyonları farklı şekilde hesaplanmaktadır. Üretici ağın çıktısı olarak üretilmiş olan örnek için kayıp hesaplanarak parametrelerin optimizasyonu gerçekleştirilmektedir. Ayırt edici ağda ise geri yayılım tekniğini uygulamak için hem gerçek hem de üretilmiş örneklerin toplam kaybı hesaplanmakta ve bu şekilde ağ parametreleri güncellenmektedir. Çekişmeli üretici ağların matematiksel ifadesi Denklem 3.4’te verilmiştir. Burada,  $x$  gerçek görüntü örneklerini,  $z$  ise görüntü üretilmesi için üretici ağına verilen gürültüyü temsil etmektedir. Ayrıca,  $G(z)$  ifadesi üretici ağın ürettiği sahte görüntü örneklerini,  $D(x)$  ifadesi ayırt edici ağın gerçek bir örnek görüntünün gerçek olma olasılığını ve  $D(G(z))$  ifadesi de ayırt edici ağın sahte bir örnek görüntünün gerçek olma olasılığını göstermektedir.

$$\min_G \max_D V(D, G) = E_{x \rightarrow p_{veri}(x)} [\log D(x)] + E_{z \rightarrow p_z(z)} [\log(1 - D(G(z)))] \quad (3.4)$$

Çekişmeli üretici ağların kullanım alanları arasında; yüz yaşlandırma, görüntü-görüntü dönüşümü, metin-görüntü dönüşümü, görüntü çözünürlüğü artırma, görüntü renklendirme, video akışı tahmin etme, üç boyutlu görüntüler üretme vb. uygulamalar yer almaktadır (Jabbar ve ark., 2021).

### 3.5.4. Termal süper çözünürlük çekişmeli üretici ağ (TSCÇÜA)

Tez çalışmaları kapsamında gerçekleştirilen süper çözünürlük uygulamaları için TSCÇÜA (Termal Süper Çözünürlük ÇÜA) derin ağ modeli geliştirilmiştir. Önerilen derin ağ modeli çekişmeli üretici ağlar (ÇÜA) tabanlı olarak geliştirilmiş olup, üretici (generator) ve ayırt edici (discriminator) ağ olmak üzere iki kısımdan meydana gelmektedir. Ağ modelinin temel çalışma prensibi, düşük çözünürlüklü termal görüntülerin üretici ağ vasıtasıyla belirli oranlarda (x2, x4 vb.) üst ölçeklenerek süper çözünürlüklü termal görüntülerin çıktı olarak oluşturulmasıdır. Ayırt edici ağ ise oluşturulan süper çözünürlüklü ve yüksek çözünürlüklü görüntü arasında ayırım yapabilmesi için kullanılmıştır. Aynı zamanda derin ağın kaybını (ÇÜA kaybı) kullanarak geri yayılım yöntemiyle (İng., back propagation) hem ayırt edici hem de üretici ağın eğitim sürecinde kullanılmıştır. TSSÇÜA derin ağ modelinin mimarisi Şekil 3.13'te gösterilmektedir.



Şekil 3.13. TSCÇÜA mimarisi

Denklem 3.5'teki  $G$  ifadesi, TSCÇÜA modelinde tahmin edilen süper çözünürlüklü görüntüyü temsil etmektedir. Ayrıca  $\delta_G$ , derin ağın kaybindan yararlanarak geri yayılım yönteminden yararlanarak optimize edilen modelin ağırlık ve

sapma değerlerini,  $I_n^{LR}$  ve  $I_n^{HR}$  ise eğitim veri setine ait düşük çözünürlüklü ve yüksek çözünürlüklü örnek görüntüleri temsil etmektedir.  $L_{tsççüa}$ , algısal kayıp (perceptual loss) değerini göstermektedir ve kenar detay bilgilerini elde ederek görsel kaliteyi artırabilmek amacıyla geri yayılım tekniğinde kullanılmaktadır. Burada,  $L_{tsççüa}$  değeri uygulamaya göre değişkenlik gösterebilmekle birlikte gerçekleştirilen süper çözünürlük uygulamalarında, derin ağın eğitim sürecinin sonuna doğru azalacak şekilde 1,403 ile 0,01 aralığında değerler almıştır. Eğitim süreci başladığında yüksek olan kayıp değeri zamanla azalmakta ve optimum seviye ulaşıncaya kadar eğitim süreci devam etmektedir.

$$\delta_G = \min \frac{1}{N} \sum_{n=1}^N L_{tsççüa} (G_{\delta_G} (I_n^{DC}), I_n^{YC}) \quad (3.5)$$

*Algısal kayıp*, içerik kaybı (content loss) ve çekişmeli kayıp (adversarial loss) değerlerinin toplamından oluşmaktadır. Bu kayıp değerinin matematiksel ifadesi Denklem 3.6'da verilmiştir. Algısal kayıp, TSCÇÜA modelinin kaybı olarak değerlendirilmekte ve süper çözünürlüklü görüntü ile gerçek referans görüntü arasındaki görsel kalite farkını minimize etmek amacıyla kullanılmaktadır. Algısal kayıp işlevi, piksel başına kayıp (per-pixel loss) fonksiyonunun aksine tüm pikseller arasındaki bütün karesel hataları toplayarak ve ortalamayı alarak çalışmaktadır. Piksel başına kayıp fonksiyonlarının algısal farklılıkları yakalayamamasının nedeni, görüntünün perspektif olarak benzer görünmesine rağmen piksel başına değerlerinin farklı olabilmesidir (Johnson ve ark., 2016).

$$L_{\text{toplaml}(tsççüa)} = \underbrace{L_{okh} + L_{vgg}}_{L_{içerik}} + L_{çekişmeli} \quad (3.6)$$

*Ortalama kare hata (OKH)*, bir derin öğrenme modelinin başarısını ölçen ve her zaman pozitif değere sahip bir ölçüttür. Bu değer sıfıra yaklaştıkça modelin başarısı artmaktadır. OKH değerinin hesaplanma formülü Denklem 3.7'de verilmiştir. Burada n veri setinin boyutunu temsil ederken,  $e_j$  ise tahmin edilen değer ile esas değer arasındaki hatayı ifade etmektedir (Trenkler, 1985).



$$OKH = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (3.7)$$

*VGG kayıp*, önceden eğitilmiş VGG19 modelinden faydalanılarak Denklem 3.8'de verilen formülle hesaplanmaktadır.  $G_\varphi(I^{DC})$ , süper çözünürlüklü görüntüyü temsil ederken,  $I^{YC}$  gerçek referans görüntüyü temsil etmektedir. Ayrıca  $\psi_{i,j}$ , i. maksimum havuzlama katmanından önce j. konvolüsyon katmanındaki özellik haritalarını göstermektedir. Bu özellik haritalarının boyutları ise  $W_{i,j}$  ve  $H_{i,j}$  ile gösterilmektedir (Gu ve ark., 2020).

$$L_{VGG_{i,j}}^{SC} = \frac{1}{W_{i,j} H_{i,j}} \sum_{m=1}^{W_{i,j}} \sum_{n=1}^{H_{i,j}} (\psi_{i,j}(I^{YC})_{m,n} - \psi_{i,j}(G_\varphi(I^{DC}))_{m,n})^2 \quad (3.8)$$

*İçerik kaybı*, piksel olarak benzerlik yerine algısal benzerliği koruyabilmek için kullanılmaktadır (Dosovitskiy ve ark., 2016). Bu kayıp değeri, önceden eğitilmiş Relu aktivasyon katmanları temelli 19 katmanlı ağ (VGG19) ile hesaplanmaktadır. Ayrıca görüntülerdeki iyileştirmenin karşılığını görüntü kalite metrikleri olan TSGO ve YBİ değerlerinde de gözlemlenmek amacıyla OKH değeri de içerik kaybının hesaplanmasında dikkate alınmıştır.

*Çekişmeli kayıp*, yapısal kaybı azaltarak daha iyi görüntüler elde etmek amacıyla kullanılmaktadır. Denklem 3.9'da görüldüğü üzere ayırt edici ağın veri seti üzerindeki olasılıklarına dayanarak hesaplanmaktadır.  $D_\alpha(G_\beta(I^{DC}))$ , süper çözünürlüklü görüntünün referans görüntüye benzeme olasılığını ifade etmektedir.  $G_\beta(I^{DC})$  ifadesi ise yeniden oluşturulmuş süper çözünürlüklü görüntüyü temsil etmektedir.

$$L_{\text{çekişmeli}}^{SC} = \sum_{n=1}^N -\log D_\alpha(G_\beta(I^{DC})) \quad (3.9)$$

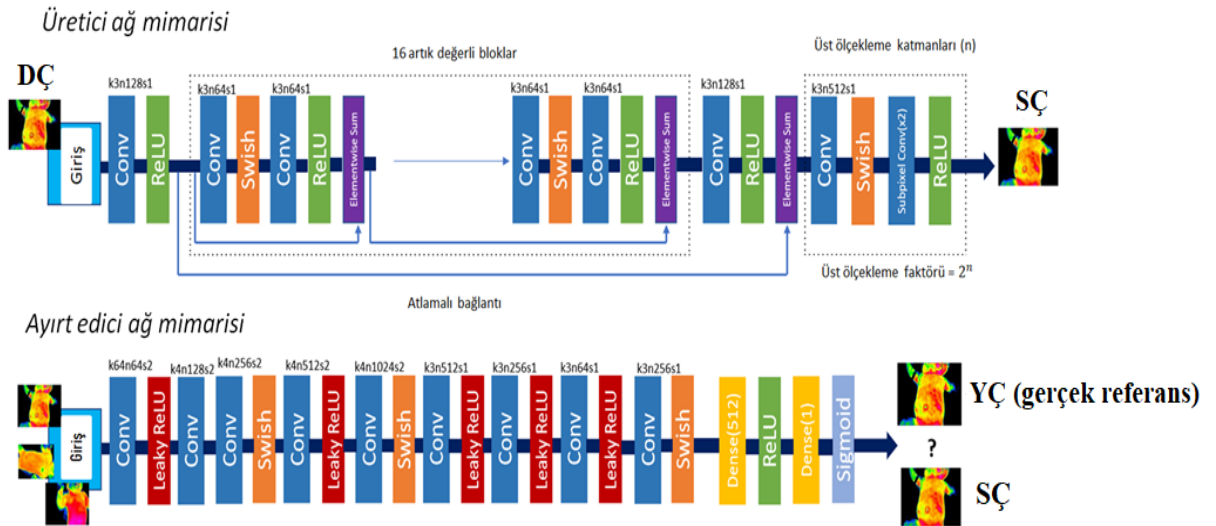
TSCÇÜA modelinin mimarisi genel olarak konvolüsyon, yığın normalleştirme (batch normalization) ve aktivasyon katmanlarından (relu, leakyrelu, swish, tanh) teşekkül etmektedir. Üretici ağ mimarisinde swish ve ReLU aktivasyon fonksiyonları tercih edilmiştir. Böylece aktivasyon fonksiyonun negatif ekseninde de öğrenme sağlanmış olup, eğitim hızında düşüş meydana gelmesinin önüne geçilmiştir. Böylece

ağın daha az görüntü ile hızlı bir şekilde eğitilmesi sağlanmaktadır. Ayırt edici ağ mimarisinde ise LeakyReLU aktivasyon fonksiyonu tercih edilerek negatif eksendeki öğrenmenin daha stabil olarak gerçekleşmesi sağlanmıştır. Ayrıca gradyanın yok olması (vanishing gradient) probleminin önüne geçmek için hem üretici hem de ayırt edici ağ mimarilerinde yığın normalleştirme katmanları kullanılmıştır (Ioffe ve ark., 2015). Ek olarak, artık (residual) bloklar derin öğrenme modellerinin eğitim zorluklarını kolaylaştırarak başarıyı artırdığı için üretici ağ mimarisinde bağlantı atlama tekniği uygulanmıştır.

Derin ağ mimarisinin eğitimi aşamasında hem hata fonksiyonun lokal minimuma ulaşabilmesi hem de ağın eğitim hızında önemli bir düşüş gerçekleşmemesi için öğrenme oranı 0,0003 olarak belirlenmiş ve optimasyon metodu olarak Adam algoritması kullanılmıştır. Ayrıca eğitim hızını artırmak ve ağın başarısını geliştirmek için eğitim küçük görüntü yamaları ile gerçekleştirilmiştir. Bu sebeple üretici ağın girişinde görüntü yama (patch) boyutları olarak (16, 16, 3) tercih edilmiş ve çıktı olarak ise (64, 64, 3) boyutlarında görüntü yamaları elde edilmiştir. Daha sonra bu görüntü yamaları ayırt edici ağa iletilmekte ve gerçek referans görüntülerle karşılaştırılmaktadır.

### 3.5.5. TSCÇÜA+ modeli

Yerine getirilen süper çözünürlük çalışmalarında TSCÇÜA modelinin başarısını hem görsel kalite hem de görüntü kalite metrikleri açısından artırmak amacıyla TSCÇÜA+ modeli geliştirilmiştir. Bu bölümde TSCÇÜA+ modeli hakkında detaylı bilgiler verilmiş ve TSCÇÜA modelinden farkları üzerinde durulmuştur. TSCÇÜA+ modeli yine ÇÜA tabanlı bir model olup, üretici ve ayırt edici ağ kısımlarından oluşmaktadır. Üretici ağ, gerçekleştirilecek uygulamaya göre önceden belirlenmiş oranlarda (x4, x8, x16) üst ölçekleme yaparak süper çözünürlüklü görüntüyü oluşturmaktadır. TSCÇÜA+ modelinin üretici ve ayırt edici ağ kısımlarının mimarileri Şekil 3.14'te gösterilmiştir.



Şekil 3.14. Üretici ve ayırt edici ağlardan oluşan TSCÇÜA+ modeli

Geliştirilen yeni derin ağ modelinde (TSCÇÜA+), TSCÇÜA modelinde kullanılan yığın normalleştirme katmanları çıkartılmış olup, daha hızlı ve stabil bir eğitim süreci gerçekleştirilmiştir. Böylece önerilen yeni modelin başarısının TSCÇÜA modeline göre arttığı gözlenmiştir. Ayrıca, kullanılan swish aktivasyon fonksiyonu sayesinde negatif düzlemde doğrusal olmayan değerler üzerinde de öğrenme sağlanarak gradyanın yok olması (vanishing gradient) probleminin önüne geçilmiştir. Önerilen modelin üretici ağ kısmında Bölüm 3.5.7’de açıklanan bağlantı atlama tekniği uygulanarak hem modelin başarısı artırılmış olup hem de eğitim süreci kolaylaştırılmıştır. Son olarak, TSCÇÜA+ modelinde TSCÇÜA modelinde uygulandığı gibi küçük boyuttaki görüntü yamaları ile eğitim gerçekleştirmek yerine düşük çözünürlüklü ve yüksek çözünürlüklü (gerçek referans) görüntülerin birebir boyutlarındaki görüntü yamaları ile eğitim gerçekleştirilmiş ve daha başarılı sonuçlar elde edilmiştir. Örneğin; 160x120 boyutundaki düşük çözünürlüklü görüntüler için TSCÇÜA modelinde 16x16, TSCÇÜA+ modelinde ise 160x120 boyutundaki görüntü yamaları ile derin ağın eğitim süreci gerçekleştirilmiştir. TSCÇÜA ve TSCÇÜA+ modelleri arasındaki farklar Çizelge 3.3’te verilmiştir.


Ek olarak, gerçekleştirilen süper çözünürlük uygulamalarında kullanılan TSCÇÜA ve TSCÇÜA+ derin ağ modellerinin eğitim süreçleri CPU E5-2680 işlemci ve 32GB GeForce GTX 1080 Ti ekran kartına sahip iş istasyonu kullanılarak tamamlanmıştır.

**Çizelge 3.3.** TSCÇÜA ve TSCÇÜA+ modellerinin farkları

	TSCÇÜA	TSCÇÜA+
Yığın normalleştirme katmanları	✓	—
Artık (kalıntı) blokların sayısı	4	16
Eğitim sürecindeki görüntü yama boyutları	Küçük	Birebir

### 3.5.6. ESA tabanlı sınıflayıcı model

Sınıflama uygulaması için geliştirilen ESA tabanlı sınıflayıcı ağının mimarisi Şekil 3.15'te gösterilmektedir. Ağ mimarisi konvolüsyon, havuzlama ve yoğun (dense) katmanlarından oluşmaktadır (Lai ve Deng, 2018). Aktivasyon fonksiyonu olarak katmanlarda ReLU ve çıkış katmanında sigmoid aktivasyon fonksiyonu kullanılmıştır. Sınıflayıcı ağının parametre listesi Çizelge 3.4'te verilmiştir. Burada görüleceği üzere tam bağlantılı katman üç tane yoğun katmanından oluşmakta ve her katmandaki nöron sayıları sırasıyla 128, 64 ve 32 olarak belirlenmiştir. Ayrıca, seyreltme katmanında ise oran olarak 0,3 değeri seçilmiş ve bağlantıların %30'luk kısmı kaldırılmıştır. Keras kütüphanesi temelli oluşturulan bu sınıflayıcı ağında düşük çözünürlüklü, yüksek çözünürlüklü (gerçek referans) ve yeniden oluşturulmuş olan süper çözünürlüklü görüntü grupları ayrı ayrı eğitilmiş ve test edilmiştir.

**Şekil 3.15.** ESA tabanlı sınıflayıcı ağın mimarisi

**Çizelge 3.4.** ESA tabanlı sınıflayıcı ağ modelinin parametreleri

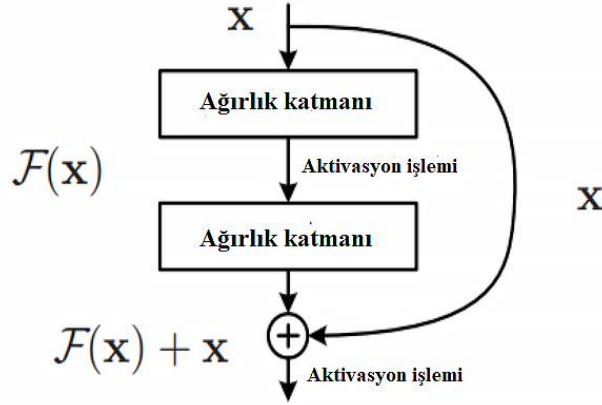
Katman numarası	Katmanlar	Çıkış özelliklerin sayısı	Konvolüsyon katmanı filtre ve maks. havuzlama katmanlarının boyutları
0	Giriş katmanı	1	-
1	Konvolüsyon katmanı	128	3x3x3
2	Maks. havuzlama katmanı	128	2x2x2
3	Konvolüsyon katmanı	64	3x3x3
4	Maks. havuzlama katmanı	64	2x2x2
5	Konvolüsyon katmanı	64	3x3x3
6	Maks. havuzlama katmanı	64	2x2x2
7	Düzleştirme	-	-
8	Tam bağlantılı katman	128	-
9	Tam bağlantılı katman	64	-
10	Tam bağlantılı katman	32	-
11	Seyreltme katmanı	-	-
12	Tam bağlantılı katman	1	-

### 3.5.7. Artık sinir ağları (ResNet50 ve ResNet 101)

Sinir ağlarında gradyanın yok olması problemine çözüm olması için artık (kalıntı) sinir ağları geliştirilmiştir. Belirtilen bu ağlarda bağlantı atlama (İng., skip connection) adı verilmiş olan bir teknik kullanılmaktadır. Atlama bağlantısı, birkaç katman önde yer alan aktivasyon fonksiyonunu şu anki aktivasyon fonksiyonunun girişiyle toplayıp aktive etmektedir. Böylece geçmiş katmanlardaki değerlerin ilerdeki katmanlara daha güçlü bir şekilde iletilmesi sağlanmaktadır. Artık sinir ağlarının katman yapısı Şekil 3.16'da gösterilmiştir. Burada,  $x$  katman girdisini ifade ederken,  $F(x)$  ise aktivasyon fonksiyonunu ifade etmektedir (Zhang ve ark., 2018).

Artık sinir ağları, geliştirilecek derin ağ modellerini geniş bir ağ yerine derin bir ağ yapısına dönüştürmekte ve daha az parametrelili bir ağ yapısı meydana getirmektedirler. Ayrıca atlama bağlantısı eklemenin avantajı, herhangi bir katmanın mimarinin performansına olumsuz etki etmesi durumunda, belirtilen katmanın yapılan

düzenleme sonucu atlanmasıdır. Böylece, kaybolan gradyan problemi olmadan çok derin bir sinir ağlarının (50+ katman) daha hızlı bir şekilde eğitilmesi sağlanmaktadır (He ve ark., 2016).

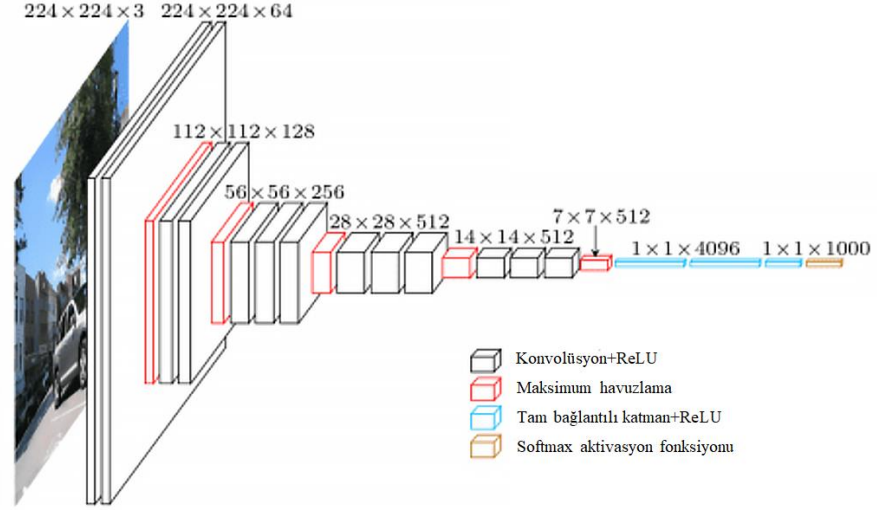


Şekil 3.16. Bağlantı atlama katman yapısı

Yenidoğanlara ait termal görüntü grupları ile gerçekleştirilen çeşitli sınıflama uygulamalarında, artık sinir ağlarının versiyonları olan ResNet50 ve ResNet101 modellerinden yararlanılmıştır. Bu modellerde, ResNet34 gibi daha az katmanlı artık sinir ağlarındaki 2 katmanlı blok yapıları yerini 3 katmanlı blok yapılarına bırakmıştır. ResNet101 modeli, ResNet50 modelinin katmanları artırılarak oluşturulmuş ve daha derin bir artık sinir ağ yapısı meydana getirilmiştir.

### 3.5.8. VGG16 ve VGG19 modelleri

Bu ağ modelleri, birbiri ardına eklenen ve yalnızca  $3 \times 3$  evrişimli katmanları kullanılarak oluşturulan derin sinir ağ modelleri olarak tanımlanmaktadır. Bu modellerde hacimsel boyutu küçültmek için maksimum havuzlama katmanları kullanılmıştır. Ayrıca, her biri 4.096 düğüme sahip iki tam bağlantılı katman ve bu katmanlardan sonra bir softmax sınıflayıcı ile birlikte ağ modelleri sonlanmaktadır. Bu VGG modellerinin mimarisi Şekil 3.17’de gösterilmektedir.



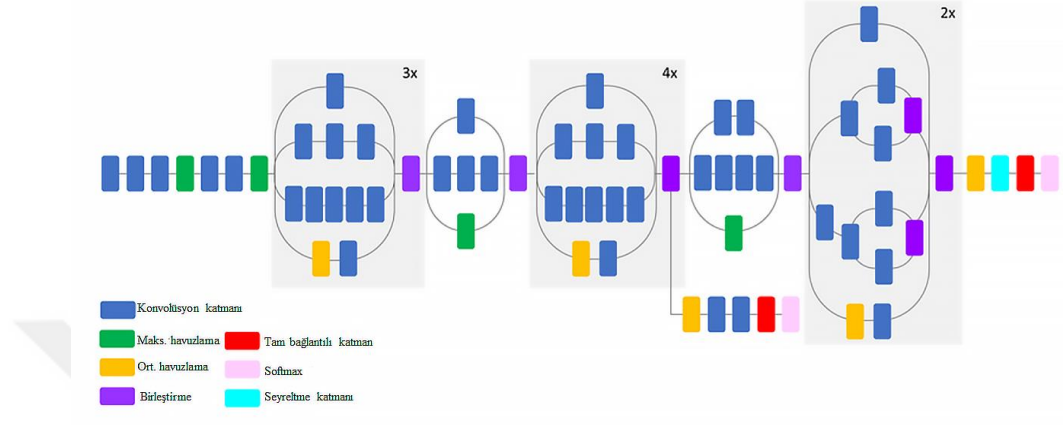
Şekil 3.17. VGG mimarisi

VGG16 ve VGG19 modellerinin her ikisi de ImageNet yarışması için kullanılmıştır. VGG19 ağının VGG 16 ağından tek farkı 3 konvolüsyon katmanı fazla olmasıdır. İlk konvolüsyon katmanına verilen giriş görüntüsü sabit  $224 \times 224$  boyutundaki renkli görüntülerdir. İki ağ modelinde de gizli katmanlarda Relu aktivasyon fonksiyonu tercih edilmiştir. VGG ağ modelleri 1.000 sınıfa ait 1 milyonun üzerinde görüntü ile eğitilmiş ve eğitim işlemi 2-3 hafta boyunca sürmüştür. VGG19 ağı, VGG16 ağına göre %0,2 daha başarılı olup, %6,8'lik bir sınıflama hatası elde etmiş ve nesne sınıflama uygulamasında oldukça başarılı bir sonuç elde etmiştir.

### 3.5.9. InceptionV3 ve Xception modelleri

GoogLeNet (InceptionV1) modelinin tanıtılmasının ardından sırasıyla InceptionV2 ve InceptionV3 modelleri geliştirilmiştir. InceptionV3 modelinin InceptionV2 modelinden farklı olarak yığın normalleştirme (batch normalization) ve tam bağlantılı katmanlar katmanlar kullanılmıştır. InceptionV3 modelinin karakteristik özelliği “Inception” modülüdür. Bu modül, farklı boyutlardaki filtre çekirdekleri tarafından oluşturulan özellik haritalarını birleştirmektedir. Şekil 3.18’de InceptionV3 ağ modelinin mimarisi gösterilmektedir. “Inception” modülleri kavramsal olarak evrimsel iken, az parametre ile zengin özellik çıkarma özelliğine sahiptir. Geleneksel bir evrişim katmanı, 2 uzamsal boyut (genişlik ve yükseklik) ve kanal boyutu olmak üzere 3 boyutlu uzayda filtreleri öğrenmeye çalışmaktadır. Burada, tek bir konvolüsyon

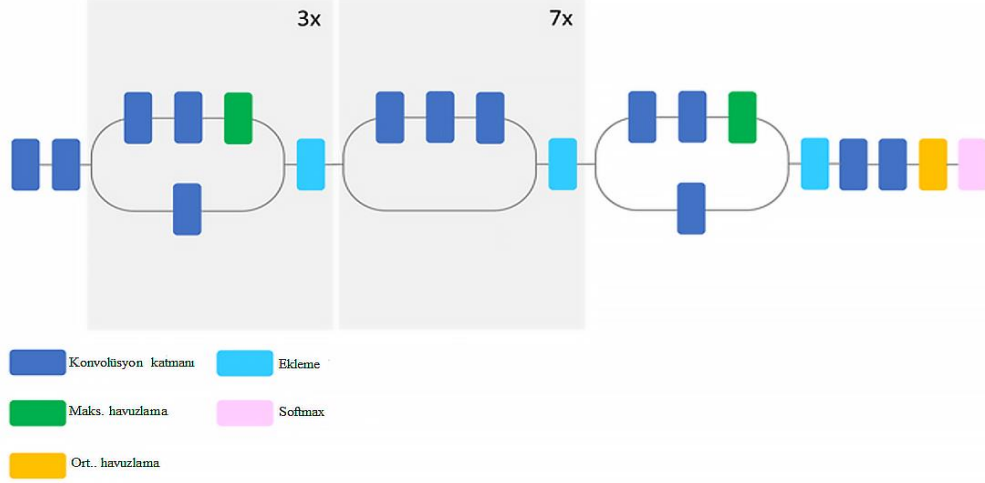
çekirdeği görevlendirilmiş olup, kanallar arasındaki ve uzamsal korelasyonları eşleme işlemleri eş zamanlı olarak gerçekleştirilmiştir. Google tarafından ImageNet yarışması için geliştirilen InceptionV3 modeli, sınıflama uygulamasında %93,7 doğruluk elde ederek önemli bir başarı göstermiştir.



Şekil 3.18. InceptionV3 mimarisi

Xception modeli ise yine Google ekibi tarafından sunulmuş olup, Inception modelinin geliştirilmiş versiyonudur ve filtreleme ile havuzlama işlemlerinin eş zamanlı gerçekleştirilmesi temeline dayanmaktadır (Szegedy ve ark., 2015). ImageNet yarışmasında %94,5 sınıflama doğruluğu elde ederek Inception modeline göre daha başarılı olduğu görülmektedir. Xception modelinin diğer ağlara göre başarılı olmasının sebebi konvolüsyonel kısımdaki yeniliklerdir. Burada, InceptionV3 modeline ek olarak geliştirilen derinlemesine konvolüsyon (depthwise convolution) ve noktasal konvolüsyon (pointwise convolution) yaklaşımları uygulanmıştır. Şekil 3.19'da Xception ağının mimarisi gösterilmektedir. Xception modelinde derinlemesine ayrılabilir konvolüsyon katmanları (depthwise separable convolution) standart "Inception" modüllerinin yerini almıştır. Burada, girdi verilerini birkaç sıkıştırılmış parçaya bölmek yerine her bir çıktı kanalı için uzamsal korelasyonlar ayrı ayrı eşlenmekte ve ardından kanallar arası korelasyonu elde edebilmek için 1x1 noktasal konvolüsyon uygulanmaktadır. Bu süreç, önce 2 boyutlu uzayda daha sonra 1 boyutlu uzayda korelasyonların elde edilmesi olarak değerlendirilmektedir.





Şekil 3.19. Xception mimarisi

### 3.6. Transfer Öğrenme

Makine öğreniminde kullanılan transfer öğrenme, önceden eğitilmiş bir modelin yeni bir problem üzerinde yeniden kullanılmasıdır. Transfer öğrenmede, oluşturulmuş bir model bir önceki bir görevden edindiği bilgiyi başka bir görevdeki genellemeyi geliştirmek için kullanmaktadır. Örneğin, bir görüntünün yiyecek içerip içermediğini tahmin etmek için bir sınıflandırıcıyı eğitirken, eğitim sırasında edindiği bilgileri içecekleri tanımak için kullanabilirsiniz. Genel olarak uygulamalarda, bir modelin çok sayıda etiketli eğitim verisi içeren bir görevden öğrendiği bilgi, fazla veri içermeyen yeni bir görevde kullanılmaktadır. Böylece öğrenme sürecini sıfırdan başlatmak yerine, ilgili bir görevi çözerken öğrenilen kalıplardan faydalanılmaktadır (Pan ve Yang, 2010).

Transfer öğrenimi, büyük miktarda hesaplama yoğunluğu gerektiren bilgisayarlı görü ve duygu analizi gibi doğal dil işleme görevlerinde yaygın olarak uygulanmaktadır. Örneğin; bilgisayarlı görmede, sinir ağları genellikle ilk katmanlarda kenarları, orta katmanda şekilleri ve sonraki katmanlarda göreve özgü bazı özellikleri algılamaya çalışır. Transfer öğrenmede genellikle ilk katmanlar ve orta katmanlar kullanılmaktadır. Yani, başlangıçta eğitildiği görevin etiketli verilerinden yararlanarak sadece son katmanlar yeniden eğitilmektedir.

Transfer öğreniminin avantajları; eğitim süresinin azaltılması, uygulamaya göre değişmekle birlikte genellikle daha iyi performans göstermesi ve çok fazla veriye ihtiyaç duyulmamasıdır. Genellikle, bir sinir ağını sıfırdan eğitmek için çok fazla veriye ihtiyaç duyulur, ancak bu verilere erişim her zaman mümkün değildir. Transfer öğrenimi ile

model zaten önceden eğitilmiş olduğundan, nispeten az eğitim verisi ile başarılı bir makine öğrenimi modeli oluşturulabilmektedir. Ek olarak, derin bir sinir ağını karmaşık bir görev üzerinde eğitmek bazı durumlarda çok uzun zaman alabileceğinden, transfer öğrenme tekniği eğitim süresi azaltma açısından da büyük fayda sağlamaktadır (Tan ve ark., 2018).

### 3.7. Başarı Değerlendirme Kriterleri

Tez çalışması kapsamında gerçekleştirilen bütün süper çözünürlük uygulamalarının sonuçları TSGO (tepe sinyal gürültü oranı) ve YBİ (yapısal benzerlik indeksi) görüntü kalite metriklerinden faydalanarak değerlendirilmiştir. Bu metrik değerleri hesaplanırken orijinal yüksek çözünürlüklü (gerçek referans) termal görüntüler referans görüntüler olarak dikkate alınmaktadır. TSGO değeri bir görüntüdeki gürültü miktarını yansıtmaktadır. TSGO değeri arttıkça görüntüdeki gürültü miktarı azalmaktadır ve daha kaliteli görüntüler ortaya çıkmaktadır. TSGO değeri Denklem 3.10'da verilen formülle hesaplanmaktadır. Burada,  $I_0$  referans görüntüyü,  $I$  çıktı görüntüyü, OKH ise ortalama kare hatayı temsil etmektedir (Javaid ve ark., 2013).

$$TSGO = 20 \times \log_{10} (255 \sqrt{OKH(I, I_0)}) \quad (3.10)$$

YBİ değeri daha çok yapısal benzerliği ölçmeye dayalı bir metrik değeridir. YBİ değerinin yüksek olması yapısal olarak bozulmasının az olduğunu göstermektedir ve referans ile çıktı görüntüleri arasındaki yapısal benzerliğin yüksekliğini göstermektedir. YBİ değeri Denklem 3.11'de verilen formülle hesaplanmaktadır. Burada,  $\mu_{I_R}(n)$  ve  $\mu_{I_D}(n)$  sembolleri, referans( $I_R$ ) ve bozuk( $I_D$ ) görüntü dizisinin n. çerçevesinin ortalamasını temsil etmektedir. Ayrıca,  $\sigma_{I_R}(n)$  ve  $\sigma_{I_D}(n)$ , referans( $I_R$ ) ve bozuk ( $I_D$ ) görüntü dizisinin n. çerçevesinin standart sapmasını temsil etmektedir.  $C_1=(0,01*255)^2$ ,  $C_2=(0,03*255)^2$  değerleri ise kararsızlıktan kaçınmak için kullanılan sabitlerdir (Javaid ve ark., 2013).

$$YBI = \frac{[2\mu I_R(n)\mu I_D(n) + C1][2\sigma I_R I_D(n) + C2]}{[\mu I_R^2(n) + \mu I_D^2(n) + C1][\sigma I_R^2(n) + \sigma I_D^2(n) + C2]} \quad (3.11)$$

Tez çalışması kapsamında, bahsedilen görüntü kalite metriklerine ek olarak görev-tabanlı değerlendirme yapabilmek amacıyla hasta-sağlıklı sınıflama uygulamaları gerçekleştirilmiştir (Lai ve Deng, 2018). Böylece elde edilen süper çözünürlüklü görüntülerin başarısı TSGO ve YBI değerlerinin yanı sıra sınıflama uygulamaları üzerinde de test edilmiştir. Bu uygulamaları gerçekleştirebilmek amacıyla ESA tabanlı bir sınıflayıcı model geliştirilmiştir. Ayrıca bu sınıflayıcı üzerinde önceden eğitilmiş modeller kullanılarak transfer öğrenme yöntemi uygulanmış ve karmaşıklık matrisleri elde edilmiştir. Karmaşıklık matrisleri, sınıflama başarısını değerlendirebilmek için kullanılan doğruluk, kesinlik, duyarlılık ve F1 skoru değerlerinin hesaplanabilmesi için gerekli verileri sunmaktadır (Miranda ve ark., 2016). Karmaşıklık matrisinin yapısı Şekil 3.20’de gösterilmektedir. Burada, doğru pozitif (DP) değeri hasta bebeklerin kaçının hasta olarak (pozitif) tahmin edildiğini, doğru negatif (DN) değeri ise sağlıklı bebeklerin kaçının sağlıklı olarak (negatif) tahmin edildiğini belirtmektedir. Ayrıca yanlış pozitif değeri (YP) değeri sağlıklı bebeklerden kaçının hasta olarak tahmin edildiğini, yanlış negatif (YN) değeri ise hasta bebeklerden kaçının sağlıklı olarak tahmin edildiğini belirtmektedir (Xin ve Wang, 2019). Karmaşıklık matrisinden elde edilen bu değerler kullanılarak doğruluk, kesinlik, duyarlılık ve F1 skoru metrik değerlerinin nasıl hesaplandığı ile ilgili formüller Çizelge 3.5’te verilmiştir. Kesinlik değeri hasta olarak tahmin edilen bebeklerden kaçının gerçekten hasta olduğunu gösterirken, duyarlılık değeri ise hasta olarak tahmin edilmesi gereken bebeklerden kaçının hasta olarak tahmin edildiğini göstermektedir. Burada, F1 skoru değeri kesinlik ve duyarlılık değerlerinin harmonik ortalaması alınarak hesaplanmaktadır. Genellikle test veri setinin dengesiz bir dağılıma sahip olduğu uygulamalarda doğruluk değerinin sınıflama başarısını değerlendirmede yetersiz kalması sebebiyle F1 skoru değeri de kullanılmaktadır (Loussaief ve Abdelkrim, 2018).

		Tahmin Edilen Değerler	
		Negatif	Pozitif
Gerçek Değerler	Negatif	DN	YP
	Pozitif	YN	DP

Şekil 3.20. Karmaşıklık matrisi

Çizelge 3.5. Sınıflama metriklerinin formülleri

Doğruluk (%)	$\frac{DP + DN}{DP + DN + YP + YN} \cdot 100$
Duyarlılık (%)	$\frac{DP}{DP + YN} \cdot 100$
Kesinlik (%)	$\frac{DP}{DP + YP} \cdot 100$
F1 Skoru (%)	$2x \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \cdot 100$

### 3.8. Bulut Ortamı

Bulut bilişim, esnek kaynak yönetimi ve ekonomik ölçeklendirme amacıyla sunucular, depolama, veri tabanları, ağ iletişimi, yazılım, analitik ve makine zekası dahil olmak üzere tüm bilgi işlem hizmetlerinin internet üzerinden sunulması olarak ifade edilmektedir. Bulut bilişimin avantajları şu şekilde sıralanabilir:

- Veriler bulut ortamında depolandıktan sonra, bulutu kullanarak bu verileri yedeklemek ve geri yüklemek çok kolaydır.

- Bulut uygulamaları, belirli bir çalışma grubundaki kişilerin gerekli bilgileri hızlı ve kolay bir şekilde paylaşmasına olanak tanıyarak işbirliğini geliştirmektedir.
- Bulut bilişim, tüm bulut verilerine mobil cihazlar aracılığıyla kolayca erişilmesini sağlamaktadır.
- Bulut ortamı, belge, resim, ses, video vb. gibi önemli verilerin tek bir yerde depolanması için kullanıcılara büyük miktarda depolama kapasitesi sağlamaktadır. (Doad ve Gupta, 2021).

Tez çalışması kapsamında, süper çözünürlük sisteminin bulut ortamında çalıştırılması için Google Colaboratory uygulaması tercih edilmiştir. Google Colaboratory (Colab), Google tarafından sağlanan ücretsiz bir “Jupyter notebook” ortamıdır ve kullanıcının tamamen bulut ortamında kodları çalıştırmasına ve verileri Google Drive'da saklamasına olanak sağlamaktadır. Colab not defterleri proje ekibiyle vs. kolayca paylaşılabilir ve not defterleri üzerinde istenilen düzenlemeler gerçekleştirilebilmektedir. Colab ile popüler Python kütüphanelerinin (keras vb.) tüm avantajlarından yararlanarak uygulamalar yürütülebilmektedir. Colab not defterleri Google'ın bulut sunucularında kod yürütmektedir. Yani makine gücünden bağımsız olarak, GPU'lar ve TPU'lar dahil Google donanımının gücünden yararlanılabilmektedir (Google, 2021).

## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, tez çalışması kapsamında gerçekleştirilen termal görüntülerin çözünürlüğünün artırılmasına yönelik süper çözünürlük uygulamaları ile ilgili detaylı bilgiler paylaşılmıştır. Burada, süper çözünürlük uygulamalarında kullanılan veri setleri, derin ağ modelleri ve sınıflama uygulamalarında kullanılan evrişimli sinir ağları tabanlı modeller ile ilgili bilgiler verilmiştir. Ayrıca, termal yüz görüntüleri üzerinde gerçekleştirilen süper çözünürlük uygulamasının bulut ortamında çalıştırılmasıyla ilgili geliştirilen sistem detaylı bir şekilde açıklanmıştır.

### 4.1. Termal Görüntüler Üzerinde Gerçekleştirilen Sınıflama Uygulamalarında Derin Öğrenme Tabanlı Süper Çözünürlük Yaklaşımının Etkileri

Bu çalışma, yenidoğan bebeklerin termal görüntülerinden oluşan bir veri kümesi üzerinde gerçekleştirilen süper çözünürlük uygulamaları için yeni bir derin öğrenme tabanlı yaklaşım önermektedir. Bu veri seti, geleneksel süper çözünürlük çalışmalarında olduğu gibi yenidoğan bebeklerin termal görüntülerinin (YÇ-gerçek referans) boyutlarının küçültülmesiyle oluşturulmuştur. Böylece yüksek çözünürlüklü (YÇ) ve düşük çözünürlüklü (DÇ) termal görüntülerden oluşan bir veri seti elde edilmiştir. Uygulamalar sonucunda düşük çözünürlüklü görüntülerden yeniden oluşturulmuş süper çözünürlüklü görüntüler; düşük çözünürlüklü, biküçük interpolasyon görüntüleri ve SRGAN, MedSRGAN, TherISurnet modelleri kullanılarak elde edilen süper çözünürlüklü görüntüler ile karşılaştırılmıştır.

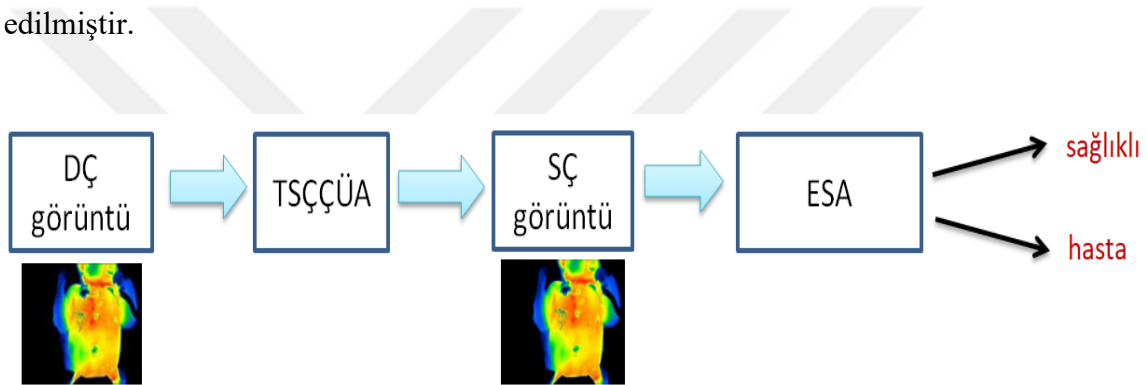
#### 4.1.1. Kullanılan veri seti

Gerçekleştirilen çalışmada, 640x480 termal çözünürlüğe sahip Variocam HD termal kamera kullanılarak elde edilen yenidoğan bebeklere ait 100 tane prematüre (sağlıklı) ve 100 tane konjenital kalp hastası (KKH) bebeklerin termal görüntüleri kullanılmıştır. Bu görüntüler 480x360 görüntü boyutuna sahiptir ve yüksek çözünürlüklü (gerçek referans) termal görüntüler olarak değerlendirilmiştir. Daha sonra bu görüntüler Matlab ortamında 1/4 oranında alt ölçeklenerek 120x90 görüntü boyuna sahip düşük çözünürlüklü görüntüler elde edilmiştir (Şenalp ve Ceylan, 2020). Böylece

200 tane yüksek çözünürlüklü ve 200 tane düşük çözünürlüklü görüntü çiftinden oluşan veri seti hazır hale getirilmiştir.

#### 4.1.2. Deneysel sonuçlar

Bölüm 4.1.2.1’de yeni doğan bebeklere ait termal görüntüler ile gerçekleştirilen süper çözünürlük uygulaması hakkında detaylı bilgiler yer almaktadır. Bölüm 4.1.2.2’de ise gerçekleştirilen süper çözünürlük uygulamasının sınıflama başarısı üzerindeki etkisini gözlemleyebilmek amacıyla bir çalışma yapılmıştır. Gerçekleştirilen her iki çalışmanın akış şeması Şekil 4.1’de gösterilmiş ve sonraki bölümlerde açıklanmış olan yenidoğan termal görüntüleriyle gerçekleştirilen uygulamalarda da bu yaklaşım tercih edilmiştir.



Şekil 4.1. Yenidoğan görüntüleri üzerinde TŞÇÇÜA ile yapılan süper çözünürlük ve sınıflama uygulaması

##### 4.1.2.1. Yenidoğan termal görüntüler için süper çözünürlük uygulaması


Bu çalışmada, hasta ve sağlıklı bebeklere ait 200 yüksek çözünürlüklü ve 200 düşük çözünürlüklü termal görüntü kullanılmıştır. Bu görüntü çiftlerinden 160 (80 sağlıklı ve 80 hasta) tanesi eğitim veri seti olarak ayrılmış olup, 40 (20 sağlıklı ve 20 hasta) tanesi ise test aşamasında kullanılmıştır. Bu uygulama sırasında 5-katlamalı çapraz doğrulama (İng., k-fold cross-validation) yönteminden yararlanarak eğitim ve test görüntüleri birbirinden farklı olacak şekilde 5 farklı grup için çalışmalar gerçekleştirilmiştir. Böylece tüm veri seti aynı zamanda test görüntüsü olarak kullanılmış olup, sonuçlar her biri 40’ar görüntüden oluşan 5 farklı grup için değerlendirilmiştir. Derin ağların eğitim işlemleri 30.000 iterasyon boyunca sürdürülmüş ve TŞÇÇÜA modelinin eğitim süreci yaklaşık 63 saat sürmüştür.

Düşük çözünürlüklü test görüntüleri 120x90 görüntü boyutuna sahiptir. Bu görüntüler TSCÇÜA derin ağ modeli ile x4 üst ölçeklenerek 480x360 boyutlarında süper çözünürlüklü görüntüler elde edilmiştir. Şekil 4.2'de yukardan aşağıya sırasıyla düşük çözünürlüklü görüntüler, bikübik interpolasyon, SRGAN (Ledig ve ark., 2017), TherISuRNet (Chudasama ve ark., 2020) , MedSRGAN (Gu ve ark., 2020) ve tez çalışmasında önerilen TSCÇÜA modellerinin uygulanması sonucu elde edilen süper çözünürlüklü ve yüksek çözünürlüklü (gerçek referans) görüntüler yer almaktadır. Ayrıca elde edilen görüntülere ait bütün sonuçlar TSGO ve YBİ görüntü kalite metrikleri ile karşılaştırılmıştır. TSGO ve YBİ sonuçları 5 farklı grup için ayrı ayrı hesaplanmıştır ve sonuçlar Çizelge 4.1'de verilmiştir. Önerilen ağda VGG kaybı ile birlikte OKH kaybının geri besleme yöntemine dahil edilmesi sonucunda TSGO değerlerinde SRGAN ağına göre yaklaşık 0,5 dB'lik, YBİ değerlerinde ise yaklaşık %2'lik bir artış gözlemlenmiştir. Ayrıca önerilen ağın sonuçları düşük çözünürlüklü termal görüntüler ve bikübik interpolasyon sonucu elde edilen görüntüler ile karşılaştırılmış ve TSGO değerinde yaklaşık 3 dB artış meydana gelirken, YBİ değerinde yaklaşık %10'luk iyileşme elde edilmiştir. Ayrıca önerilen yöntemin başarısı, SRGAN, TherISuRNet ve MedSRGAN modelleriyle karşılaştırıldığında açıkça görülmektedir. Burada, TSCÇÜA modeli en iyi ikinci TSGO ve en iyi YBİ değerleri elde edilmiştir.

Çizelge 4.1. Elde edilen TSGO ve YBİ sonuçları

Grup No	DÇ		Bikübik		SRGAN		TherISuRNet		MedSRGAN		TSCÇÜA (önerilen)	
	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ
1	23,773	0,764	24,123	0,814	26,180	0,887	26,535	0,903	26,834	0,905	26,620	0,911
2	23,832	0,767	24,662	0,807	26,472	0,888	26,818	0,901	27,056	0,908	26,961	0,910
3	24,652	0,799	24,984	0,831	27,540	0,899	27,852	0,916	28,175	0,915	28,028	0,922
4	24,910	0,784	25,575	0,823	28,279	0,906	28,620	0,921	28,906	0,922	28,795	0,927
5	25,019	0,791	25,682	0,828	27,990	0,894	28,349	0,905	28,512	0,908	28,468	0,914
<b>Ortalama</b>	<b>24,437</b>	<b>0,781</b>	<b>25,005</b>	<b>0,821</b>	<b>27,292</b>	<b>0,895</b>	<b>27,635</b>	<b>0,909</b>	<b>27,897</b>	<b>0,912</b>	<b>27,774</b>	<b>0,916</b>





Şekil 4.2. Elde edilen sonuçlara ait örnek görüntüler

Ek olarak, önerilen TŞÇÜA modelinin farklı veri setleri üzerinde de uygulanabilirliğini kanıtlamak için termal görüntülerden oluşan iki farklı standart veri seti kullanılmıştır. Burada, PBVS eğitim veri setine ait GT eğitim veri seti (Rivadeneira ve ark., 2020), uygulamanın eğitim aşamasında x4 üst ölçekleme faktörü için kullanılmıştır. Bu çalışmada adil bir değerlendirme yapabilmek için veri setlerinde aynı sayıda görüntü (951 eğitim görüntüsü) kullanılmıştır. Ardından test aşamasında GT test veri seti (50 görüntü) ve KAIST (Hwang ve ark., 2018) test veri seti (500 görüntü) kullanılmıştır (Hwang ve ark., 2018). GT ve KAIST veri setlerine ait termal görüntüler gri ölçekli olup, cadde ve sokak görüntüleridir. Bu veri setlerine ait örnek termal görüntüler Şekil 4.3'te gösterilmiştir. İlgili görüntüler 640x480 boyutundadır. Hem eğitim hem de test veri setlerinde referans görüntülerinin boyutu 640x480 iken, düşük çözünürlüklü görüntülerin boyutu 160x120'dir. Elde edilen süper çözünürlüklü görüntülerin sonuçları, TSGO ve YBİ görüntü kalitesi metrikleri kullanılarak SRResNet (Ledig ve ark., 2017), SRFeat-M (Park ve ark., 2018), MSRN (Li ve ark., 2018),

EDSR (Lim ve ark., 2017), RCAN (Zhang ve ark., 2018), TEN (Choi ve ark., 2016) ve TherISuRNet (Chudasama ve ark., 2020) modelleri ile karşılaştırılmıştır. Bu çalışmanın sonuçları Çizelge 4.2'de gösterilmiştir. TSCÇÜA modelinin standart veri setleri üzerinde de başarılı sonuçlar elde ettiği ve literatürde yer alan diğer süper çözünürlük yaklaşımlarına göre daha üstün olduğu gözlemlenmiştir.



Şekil 4.3. Üst satırda GT, alt satırda KAIST veri setine ait örnek termal görüntüler

Çizelge 4.2. GT ve KAIST veri setleri üzerinde gerçekleştirilen uygulamaların TSGO ve YBİ değerleri ile karşılaştırılması (*En iyi değerler kalın yazılmıştır*)

Veri seti	Metotlar									TSCÇÜA (önerilen)
	Metrik	Bikübik	SRResNet	MSRN	SRFeat	EDSR	RCAN	TEN	TherISuRNet	
GT	TSGO	32,665	33,124	34,471	34,124	34,485	34,420	33,623	34,495	<b>34,662</b>
	YBİ	0,862	0,9018	0,9076	0,900	0,906	0,9072	0,891	<b>0,910</b>	0,903
KAIST	TSGO	32,464	32,078	32,973	32,866	<b>33,054</b>	32,996	32,540	32,699	32,961
	YBİ	0,870	0,865	0,879	0,877	0,879	0,880	0,875	0,879	<b>0,887</b>

#### 4.1.2.2. Süper çözünürlüklü görüntüler üzerinde gerçekleştirilen sınıflama uygulamaları

Bu bölümde, yenidoğanlara ait termal görüntüler kullanılarak gerçekleştirilen hasta- sağlıklı sınıflama uygulaması hakkında detaylı bilgiler yer almaktadır. Bu çalışmanın amacı, düşük çözünürlüklü termal görüntülerin süper çözünürlük yaklaşımıyla çözünürlüğünün artırılması ve sınıflama uygulamalarında kullanılabilir

hale getirilmesidir. Bu sebeple, Bölüm 3.5.6'da detayları açıklanan sınıflayıcı ağ modeli kullanılarak düşük çözünürlüklü, yüksek çözünürlüklü (gerçek referans) ve yeniden oluşturulmuş süper çözünürlüklü termal görüntü grupları her uygulama için ayrı olacak şekilde eğitilmiş ve test edilmiştir. Test aşamasında 4 farklı uygulama gerçekleştirilmiş olup, düşük çözünürlüklü, SRGAN ile elde edilen süper çözünürlüklü, TSCÇÜA ile elde edilen süper çözünürlüklü ve yüksek çözünürlüklü görüntüler ayrı ayrı değerlendirilmiştir. Bu görüntü grupları kullanılarak elde edilen sınıflama sonuçlarına ait karmaşıklık matrisleri Çizelge 4.3'te gösterilmiştir. Bununla birlikte Çizelge 4.4'te bütün görüntü grupları için doğruluk oranlarının karşılaştırması verilmiştir. Sonuçlar incelendiğinde önerilen ağın uygulanması sonucu elde edilen süper çözünürlüklü görüntülerin hasta ve sağlıklı bebekleri doğru sınıflayabilme oranı düşük çözünürlüklü görüntülere kıyasla %5,5 değerinde artış göstermiştir. Ayrıca SRGAN ile elde edilen süper çözünürlüklü görüntülerin sınıflama başarısı ile karşılaştırıldığında %2,5 oranında bir artış gözlemlenmiştir. Elde edilen sonuçlar değerlendirildiğinde önerilen yöntemin sınıflama başarısı, yüksek çözünürlüklü görüntülerle gerçekleştirilen sınıflama sonuçlarına oldukça yaklaşmıştır. Böylece, süper çözünürlük yaklaşımları sayesinde düşük çözünürlüklü görüntülerin sınıflama uygulamalarında etkin olarak kullanılabileceği görülmüştür.

Daha sonra bu çalışmaya ek olarak tasarlanan ESA tabanlı sınıflandırıcı üzerinde transfer öğrenme tekniği uygulanarak InceptionV3 (Szegedy ve ark., 2015), Xception (Chollet, 2017), VGG16 (Simonyan ve Zisserman, 2014) ve ResNet50 (He ve ark., 2016) modelleri kullanılmıştır. Elde edilen sonuçlar Çizelge 4.5'te karşılaştırılmıştır. Buna göre, transfer öğrenme tekniklerinin uygulanmasının sınıflama başarısını arttırdığı görülmektedir. Özellikle önceden eğitilmiş ResNet50 modelinin kullanılması ile sınıflama başarısında yaklaşık %3'lük bir artış sağlanmıştır. Elde edilen tüm sonuçlar değerlendirildiğinde, önerilen yöntemin (TSCÇÜA) sınıflama başarısı, yüksek çözünürlüklü görüntüler kullanılarak elde edilen sınıflama sonuçlarına çok yakın olduğu gözlemlenmiştir. Bu durum, süper çözünürlük tekniklerini kullanarak sınıflama problemlerinin başarısını artırmak için alternatif bir çözüm sağlamaktadır.

Ek olarak, bütün sınıflama uygulamalarının eğitim süreçleri, Tesla K80 donanımı sağlayan Google Colab ortamında 100 iterasyon boyunca çalıştırılarak tamamlanmıştır. Sınıflayıcı modellerin eğitim süreci yaklaşık 30 dakikadır.

**Çizelge 4.3.** Karmaşıklık matrisleri

Görüntü grupları Sınıflama sonucu Gerçek sınıf	DÇ		SRGAN		TSCÇÜA (önerilen)		YÇ (referans)	
	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta
Sağlıklı	93	7	91	9	97	3	98	2
Hasta	15	85	7	93	8	92	6	94

**Çizelge 4.4.** Sınıflayıcı modellerin doğruluk oranlarının karşılaştırılması (*Kalın şekilde gösterilen değerler en iyi değeri göstermektedir*)


Elde edilen görüntü grupları	Sınıflayıcı model				
	Inception	VGG16	ResNet50	Xception	ESA tabanlı
	Doğruluk oranları (%)				
DÇ	91	90,5	<b>92,5</b>	91,5	89
SRGAN	93,5	92,5	94,5	<b>95</b>	92
TSCÇÜA (önerilen)	96	95	<b>97,5</b>	96,5	94,5
YÇ (referans)	98	97,5	<b>99</b>	97,5	96

#### 4.2. Farklı Üst Ölçekleme Oranları için Yenidoğan Termal Görüntüleri ile Gerçekleştirilen Süper Çözünürlük ve Sınıflama Uygulamaları

Bu çalışma kapsamında, 640x480 termal çözünürlüğe sahip Variocam HD termal kamera kullanılarak elde edilen yenidoğan bebeklere ait yüksek çözünürlüklü (gerçek referans) 250 prematüre (sağlıklı) ve 250 konjenital kalp hastası (hasta) bebeğin termal görüntüleri kullanılmıştır. Termal kamera ile elde edilen bu yüksek çözünürlüklü termal görüntüler 640x480 görüntü boyutuna sahiptir ve referans görüntüler olarak dikkate alınmaktadır. Daha sonra yüksek çözünürlüklü termal görüntüler 1/2, 1/4 ve 1/8 oranlarında alt ölçeklenerek sırasıyla 320x240, 160x120, 80x60 görüntü boyutlarına sahip düşük çözünürlüklü görüntüler elde edilmiştir. Böylece 500 yüksek çözünürlüklü ve 500 düşük çözünürlüklü görüntü çiftinden oluşan 3 farklı veri seti elde edilmiştir. Bu veri setine ait termal görüntüler içinden 1/8, 1/4, 1/2 oranlarında yeniden boyutlandırılmış düşük çözünürlüklü (DÇ) görüntülerden örnekler ve bu örnek görüntülere karşılık gelen yüksek çözünürlüklü (gerçek referans) görüntüler Şekil 4.4'te

gösterilmektedir. Burada, görüntü boyutlarının küçültme derecesi artırıldıkça veri kaybından dolayı görüntü kalitesindeki bozulmaların da o derece arttığı görülmektedir.

Bu çalışmada süper çözünürlük uygulamaları için Bölüm 4.1.2’de açıklanmış olan TSCÇÜA modeli kullanılmıştır. Tüm uygulamalarda üretici ağının girişinde görüntü yama boyutları (16, 16, 3) iken ayırt edici ağın girişine x2, x4, x8 süper çözünürlük uygulamalarına göre sırasıyla (32, 32, 3), (64, 64, 3), (128, 128, 3) boyutlarında görüntü yamaları oluşturularak iletilmektedir. Yani üretici ağın çıkışında üst ölçeklemeyi sağlayan alt-piksel (sub-pixel) konvolüsyon katmanlarının sayısı (üst ölçekleme oranı:  $2^n$ ,  $n= 1, 2$  ve  $3$ ) gerçekleştirilecek uygulamaya göre ayarlanmaktadır (Shi ve ark., 2016). Ayrıca ağın eğitim işlemleri 15.000 iterasyonda yaklaşık 100 saatte tamamlanmıştır.




Şekil 4.4. Örnek görüntüler (Soldan sağa sırasıyla 1/8, 1/4, 1/2, gerçek referans)

#### 4.2.1. Gerçekleştirilen süper çözünürlük uygulamaları

Bu çalışmada kullanılan veri setindeki görüntü çiftlerinden 400 adet görüntü çifti (200 sağlıklı+200 hasta) eğitim veri seti olarak ayrılmış olup, 100 adet görüntü çifti (50 sağlıklı+50 hasta) ise test veri seti olarak tanımlanmıştır. Burada, eğitim ve test

görüntüleri birbirinden bağımsız olacak şekilde düzenlenmiştir. Elde edilen süper çözünürlüklü görüntüler ile gerçek referans görüntüler aynı boyutlara sahiptir ve 640x480 boyutundadırlar. Oluşturulan derin ağ modeli (TSCÇÜA) ve SRGAN ağı, üç farklı veri seti (1/8, 1/4 ve 1/2 oranlarında alt ölçeklenerek elde edilen) için ayrı ayrı olacak şekilde altı farklı eğitim ve test sürecinden geçirilmiştir. Elde edilen sonuçlardan sağlıklı ve hasta bebeklere ait örnek termal görüntüler sırasıyla düşük çözünürlüklü; biküvik interpolasyon, SRGAN ve TSCÇÜA modelleri ile oluşturulan süper çözünürlüklü ve yüksek çözünürlüklü görüntülere ait olacak şekilde Şekil 4.5'te gösterilmektedir. Ayrıca elde edilen görüntülere ait bütün sonuçlar TSGO ve YBİ görüntü kalite metrikleri ile değerlendirilmiştir. Burada referans olarak yüksek çözünürlüklü görüntüler kullanılmıştır. TSGO ve YBİ değerleri daha önce bahsedilen üç farklı veri seti için ayrı ayrı hesaplanmış ve sonuçlar Çizelge 4.5'te gösterilmiştir. Önerilen derin ağ modelinde daha önceden bahsedilen VGG kaybının yanı sıra OKH kaybının da geri yayılım yönteminde kullanılması neticesinde TSGO değerlerinde SRGAN ağına göre ortalama olarak 0,6 dB, YBİ değerlerinde ise ortalama olarak %3 civarında bir artış görülmüştür. Ayrıca elde edilen sonuçlar düşük çözünürlüklü termal görüntüler ve biküvik interpolasyon sonucu elde edilen görüntüler ile karşılaştırılmış olup, TSGO değerlerinde sırasıyla yaklaşık 3,5 dB ve 2 dB, YBİ değerlerinde ise sırasıyla yaklaşık %12 ve %5 bir artış gözlemlenmiştir.



Şekil 4.5. Süper çözünürlük uygulamaları sonucu elde edilen görüntüler (Soldan sağa sırasıyla düşük çözünürlüklü, bikübik interpolasyon, SRGAN, TSCÇÜA ve gerçek referans)

Çizelge 4.5. Süper çözünürlük uygulamaları için TSGO ve YBİ sonuçları

Görüntü setleri	DÇ		Bikübik		SRGAN		TSCÇÜA (önerilen)	
	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ
X2	30,614	0,9	32,584	0,918	33,946	0,945	34,585	0,966
X4	25,449	0,795	26,862	0,834	28,408	0,854	28,960	0,904
X8	21,330	0,659	22,729	0,736	24,074	0,821	24,472	0,843

#### 4.2.2. Sınıflama uygulamalarının başarısında süper çözünürlük metotlarının etkilerinin incelenmesi

Bu bölümde, farklı alt ölçekleme oranları ile oluşturulan veri setleri ve çeşitli süper çözünürlük teknikleri kullanılarak elde edilen süper çözünürlüklü termal görüntüler üzerinde hasta ve sağlıklı olarak sınıflama çalışmaları gerçekleştirilmiştir. Yerine getirilen çalışmalar neticesinde düşük çözünürlüklü termal görüntülere uygulanan süper çözünürlük metodunun hastalık teşhisindeki etkisinin belirlenmesi

hedeflenmiştir. Sınıflama uygulamaları için Bölüm 4.1.3.2’de detaylı bir şekilde açıklanan ESA tabanlı sınıflayıcı ağı kullanılmıştır. Böylece, x4 üst ölçekleme oranı için elde edilen sınıflama başarısı ile bir karşılaştırma yapılmış ve ağı eğitiminde kullanılan görüntü sayısını artırmanın etkisi gözlemlenmiştir. Burada, sınıflayıcı ağı kullanılarak düşük çözünürlüklü, yüksek çözünürlüklü ve yeniden oluşturulmuş olan süper çözünürlüklü görüntü grupları ayrı ayrı eğitilmiş ve test edilmiştir. Test aşamasında, 3 farklı veri seti için gerçekleştirilen uygulamalar sonucunda düşük çözünürlüklü, orijinal SRGAN ile elde edilen süper çözünürlüklü, önerilen TSCÇÜA yöntemi ile elde edilen süper çözünürlüklü ve yüksek çözünürlüklü termal görüntüler ayrı ayrı değerlendirmeye alınmıştır. Test aşaması tamamlandıktan sonra elde edilen sınıflama sonuçlarına ait karmaşıklık matrisleri Çizelge 4.6’da gösterilmektedir. Ayrıca, tüm veri setleri için hesaplanan doğruluk, kesinlik, geri çağırma ve F1 skoru Çizelge 4.7’de verilmiştir.

**Çizelge 4.6.** Farklı veri grupları için elde edilen karmaşıklık matrisleri

a) x2 veri grubu								
Sınıflama sonucu Gerçek sınıf	DÇ		SRGAN		TSCÇÜA (önerilen)		YÇ (referans)	
	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı
Hasta	42	8	45	5	49	1	48	2
Sağlıklı	5	45	5	45	4	46	0	50

b) x4 veri grubu								
Sınıflama sonucu Gerçek sınıf	DÇ		SRGAN		TSCÇÜA (önerilen)		YÇ (referans)	
	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı
Hasta	40	10	46	4	47	3	48	2
Sağlıklı	2	48	3	47	1	49	0	50


c) x8 veri grubu								
Sınıflama sonucu Gerçek sınıf	DÇ		SRGAN		TSCÇÜA (önerilen)		YÇ (referans)	
	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı
Hasta	44	6	42	8	46	4	48	2
Sağlıklı	8	42	0	50	3	47	0	50



Çizelge 4.7. Üç farklı veri seti için sınıflama sonuçları

Üst ölçekleme metodu	Görüntü setleri	Doğruluk(%)	Kesinlik(%)	Duyarlılık(%)	F1 Skoru(%)
x2	DÇ	87	89,4	84	86,6
	SRGAN	90	90	90	90
	TSCÇÜA (önerilen)	95	92,5	98	95,2
	HR (gerçek referans)	98	100	96	97,9
x4	DÇ	88	95,2	80	86,9
	SRGAN	93	93,9	92	92,9
	TSCÇÜA (önerilen)	96	97,9	94	95,9
	HR (gerçek referans)	98	100	96	97,9
x8	DÇ	86	84,6	88	86,3
	SRGAN	92	100	84	91,3
	TSCÇÜA (önerilen)	93	93,9	92	92,9
	HR (gerçek referans)	98	100	96	97,9

Üç farklı veri kümesine ait sınıflama metriklerinin karşılaştırılması, Şekil 4.6'da gösterilmiştir. Doğruluk oranları ve F1 skorları dikkate alındığında, önerilen TSCÇÜA modeli ile elde edilen süper çözünürlüklü görüntülerin düşük çözünürlüklü görüntülere göre %7 daha doğru sınıflandığı görülmüştür. Ek olarak, SRGAN ile elde edilen süper çözünürlüklü termal görüntülerin sınıflama başarısı ile karşılaştırıldığında ortalama %3'lük bir artış gözlenmiştir. Bu sonuçlar göz önüne alındığında, önerilen yöntemin sınıflama başarısı, yüksek çözünürlüklü (gerçek referans) görüntüler kullanılarak yapılan sınıflama çalışmasının sonuçlarına büyük ölçüde yaklaşmıştır. Ayrıca önerilen TSCÇÜA ağı ile x8 üst ölçekleme faktörü için oluşturulan süper çözünürlüklü görüntülerin kesinlik değerlerinde, düşük çözünürlüklü görüntülerin kesinlik değerlerine göre %10 artış görülmüştür. Yani hasta olarak tanımlanması gereken bebeklerin %10 daha başarılı şekilde hasta olarak tahmin edilebildiği görülmüştür.



Şekil 4.6. Sınıflama metriklerinin karşılaştırılması


### 4.3. Termal Yüz Görüntülerini İçeren Yeni Bir Veri Seti Üzerinde Süper Çözünürlük Uygulaması

Literatürde genellikle hazır bir veri seti ve bu veri setinden alt ölçekleme yöntemiyle elde edilen yüksek-düşük çözünürlüklü görüntü çiftleri kullanılarak öğrenme tabanlı süper çözünürlük uygulamaları gerçekleştirilmiştir (Chudasama ve ark., 2020). Bu çalışmada ise iki farklı termal kameradan faydalanarak elde edilen yüksek çözünürlüklü ve düşük çözünürlüklü termal yüz görüntü çiftleri üzerinde süper çözünürlük teknikleri uygulanmıştır. Görüntü çözünürlüklerinin iyileştirilmesine yönelik çalışmalarda, kenar (yüksek frekans) bilgilerinin ortaya çıkarılması ve görüntülerdeki bulanıklığın yok edilmesi gibi hususlar büyük önem arz etmektedir. Bu çalışmanın amacı, düşük maliyetli bir termal kameradan elde edilen termal görüntülerin çözünürlüğünü artırarak yüksek maliyetli bir termal kameradan elde edilen termal görüntülerin çözünürlüğüne yaklaşılmasıdır.

#### 4.3.1. Termal yüz görüntülerine ait iki farklı veri seti


Bu çalışma kapsamında, Bölüm 3.2’de bahsedilen veri tabanına ait termal yüz görüntüleri kullanılmıştır. Bu veri tabanından 20 farklı kişiye ait RGB formatında 450 adet yüksek çözünürlüklü ve 450 adet düşük çözünürlüklü termal yüz görüntüleri süper çözünürlük uygulamalarında kullanılmıştır. Yüksek çözünürlüklü (gerçek referans)

termal görüntülerin boyutu 640x480'dir. Düşük çözünürlüklü görüntülerin boyutu ise 160x120'dir. Uygulamalarda kullanılan ham görüntülere ait örnekler Şekil 4.7'de gösterilmiştir. Sol sütundaki görüntüler Flir One Pro kamera ile elde edilen düşük çözünürlüklü termal görüntüleri gösterirken, sağ sütundaki görüntüler ise Variocam HD kamera ile elde edilen daha yüksek çözünürlüklü termal görüntüleri göstermektedir.



**Şekil 4.7.** Variocam HD termal kamera ile elde edilen düşük çözünürlüklü ve yüksek çözünürlüklü termal yüz görüntüleri

Daha sonra süper çözünürlük uygulamalarında yüz bölgelerine odaklanmak için mevcut termal görüntüler kırılarak, 120x160 boyutunda yüksek çözünürlüklü termal görüntüler ve 30x40 boyutuna sahip düşük çözünürlüklü termal görüntüler elde edilmiş ve bu şekilde yeni bir veri seti oluşturulmuştur. Şekil 4.8'de ham görüntülerin kırılması sonucu elde edilen veri setinden bazı örnek görüntüler verilmiştir. Burada, sol sütundaki görüntüler düşük çözünürlüklü ham görüntülerin, sağ sütundaki görüntüler ise yüksek çözünürlüklü orijinal görüntülerin kırılmasıyla elde edilmiştir.




Şekil 4.8. Flir One Pro termal kamera ile elde edilen düşük çözünürlüklü ve yüksek çözünürlüklü kırılmış termal yüz görüntüleri

#### 4.3.2. Termal yüz görüntüleri üzerindeki süper çözünürlük uygulamaları

Bu çalışmada kullanılan veri setinden 400 adet yüksek-düşük çözünürlüklü termal görüntü çifti eğitim veri seti olarak, 50 adet yüksek-düşük çözünürlüklü termal görüntü çifti ise test veri seti olarak belirlenmiş ve derin ağ modeli olarak TSCÇÜA kullanılmıştır. Derin ağın eğitim ve test aşamalarında kullanılan görüntüler birbirinden tamamen bağımsızdır. Gerçekleştirilen ilk çalışmada, düşük çözünürlüklü test görüntülerinin boyutu 160x120'dir. Bu görüntüler eğitim işlemi tamamlanan TSCÇÜA modeli ile x4 üst ölçeklenerek 640x480 boyutlarında süper çözünürlüklü termal yüz görüntüleri oluşturulmuştur. Bu termal yüz görüntülerinden bazı örnekler sırasıyla bikübik interpolasyon görüntüsü, SRGAN ve TSCÇÜA modelleri ile elde edilen süper çözünürlüklü görüntüler, yüksek çözünürlüklü (gerçek referans) görüntü olacak şekilde Şekil 4.9'da verilmiştir. Uygulamalar sonucunda elde edilen TSGO ve YBİ değerleri Çizelge 4.8'de yer almaktadır. Süper çözünürlüklü termal görüntülerin TSGO ve YBİ sonuçları düşük çözünürlüklü termal görüntülerle karşılaştırıldığında görüntü kalite metriklerinde artış beklenmesine rağmen bikübik interpolasyon ve SRGAN metotlarının TSGO değerlerinde ciddi bir gelişme göstermediği görülmüştür. Buna karşın önerilen TSCÇÜA modeli ile elde edilen süper çözünürlüklü termal görüntüler düşük çözünürlüklü görüntülere göre TSGO değerlerinde yaklaşık 0,2 dB'lik bir artış

göstermiştir. Ayrıca YBİ değerleri dikkate alındığında SRGAN modeline göre %2 ve biküçük interpolasyon metoduna göre %3 artış tespit edilmiştir.




**Şekil 4.9.** Elde edilen ham görüntüler ile gerçekleştirilen süper çözünürlük uygulamasına ait örnek termal yüz görüntülerinin soldan sağa sırasıyla gösterimi (biküçük interpolasyon, SRGAN, TSCÇÜA, gerçek referans)

**Çizelge 4.8.** Düşük ve süper çözünürlüklü görüntülerin TSGO ve YBİ sonuçları

DÇ		Biküçük interpolasyon		SRGAN		TSCÇÜA (önerilen)	
TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ
11,041	0,315	11,086	0,328	11,104	0,334	11,217	0,352

Gerçekleştirilen diğer uygulamada kırılmış termal yüz görüntüleri kullanılmıştır. Burada, düşük çözünürlüklü termal yüz görüntüleri 30x40 boyutundadır. Bu görüntüler TSCÇÜA modeli ile x4 üst ölçeklenerek 120x160 boyutlarına sahip olan süper çözünürlüklü termal yüz görüntüleri elde edilmektedir. Şekil 4.10'da termal yüz görüntülerine ait bazı örnekler sırasıyla biküçük interpolasyon görüntüleri, SRGAN ve TSCÇÜA modelleri ile oluşturulan süper çözünürlüklü görüntüler ve yüksek

çözünürlüklü (gerçek referans) görüntüler olacak şekilde gösterilmiştir. Ayrıca, düşük çözünürlüklü görüntülere ve süper çözünürlüklü tüm görüntü setlerine ait TSGO ve YBİ değerleri Çizelge 4.9'da verilmiştir.



**Şekil 4.10.** Soldan sağa sırasıyla kırılmış termal yüz görüntüleri (bikübik interpolasyon, SRGAN, TSCÇÜA, gerçek referans)

Elde edilen sonuçlar, düşük çözünürlüklü (DÇ) termal görüntüler ile mukayese edildiğinde bikübik interpolasyon ve SRGAN metotlarının TSGO değerlerinde ciddi bir başarı göstermediği görülmüştür. Buna karşın TSCÇÜA modeli ile elde edilen süper çözünürlüklü termal görüntüler, TSGO değerlerinde yaklaşık 0,3 dB'lik bir artış göstermiştir. Ayrıca YBİ değerleri dikkate alındığında SRGAN modeline göre %3 ve bikübik interpolasyon metoduna göre %4 artış gözlemlenmiştir.

**Çizelge 4.9.** Kırılmış termal yüz görüntüleri için TSGO ve YBİ sonuçları

DÇ		Biküvik interpolasyon		SRGAN		TSCÇÜA (önerilen)	
TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ
13,159	0,3956	13,181	0,407	13,203	0,418	13,406	0,4455

Gerçekleştirilen her iki uygulamanın da sonuçları incelendiğinde, kırma işlemi sonucu sadece yüz bölgesine odaklanılarak gerçekleştirilen süper çözünürlük uygulamasının sonuçlarının, ham görüntülerle gerçekleştirilen süper çözünürlük uygulamasının sonuçlarından daha başarılı olduğu (TSGO ve YBİ değerleri dikkate alındığında) görülmüştür. Ayrıca, görsel değerlendirme yapabilmek amacıyla en az lisans mezunu ve görüntüler hakkında ön bilgi sahibi olmayan 10 farklı kişi tarafından görüşler alınarak ortalama görüş puanı (mean opinion score) hesaplanmıştır. Bu gözlemcilerle ait detaylı bilgiler Çizelge 4.10'da yer almaktadır. Ortalama görüş puanı hesaplanırken, her kişi 4 adet ham ve 4 adet kırılmış termal görüntüyü 1 ile 5 değerleri arasında görsel kalitelerine göre puanlamıştır. Burada, yüksek çözünürlüklü referans görüntüler için 5 değeri kabul edilmiş ve diğer modellerin uygulanması sonucu elde edilen süper çözünürlüklü görüntüler de buna göre değerlendirilmiştir. Farklı veri grupları ve modeller için hesaplanan ortalama görüş puanları Çizelge 4.11'de verilmiştir. Sonuçlar incelendiğinde, kırılmış görüntüler üzerindeki iyileşmenin ham görüntülere göre fazla olduğu gözlenmiştir. Bu durum, hedef kısımlara odaklanmanın süper çözünürlük uygulamalarının başarısını artırdığını göstermiştir. Ayrıca düşük çözünürlüklü termal görüntüler, renk tonları ve yapıları bakımından yüksek çözünürlüklü (gerçek referans) termal görüntülere ne kadar yakın bir biçimde elde edilebilirse görüntülerdeki iyileşmenin TSGO ve YBİ gibi görüntü kalite metrikleri ile ispatlanabilmesi de buna uygun olarak mümkün olmaktadır. Burada, ham görüntülerle gerçekleştirilen çalışmada eğitim süresi 112 saat, kırılmış görüntülerde ise 98 saattir.

**Çizelge 4.10.** Gözlemcilerin kişisel özellikleri

Gözlemci	Meslek	Eğitim düzeyi	Cinsiyet	Yaş
1	Elk. Elt. Mühendisi	Lisans	Erkek	30
2	Makine Mühendisi	Lisans	Erkek	30
3	Kimya Mühendisi	Yüksek Lisans	Erkek	31
4	Elk. Elt. Mühendisi	Lisans	Erkek	28
5	Ziraat Mühendisi	Doktora	Erkek	46
6	Makine Mühendisi	Yüksek Lisans	Erkek	34
7	Akademisyen	Yüksek Lisans	Kadın	27
8	Mimar	Yüksek Lisans	Kadın	33
9	Akademisyen	Doktora	Kadın	44
10	Eczacı	Lisans	Kadın	53

**Çizelge 4.11.** İki farklı görüntü grubu için ortalama görüş puanları

Metot	Ham termal görüntüler	Kırpılmış termal görüntüler
Bikübik interpolasyon	1,65	1,63
SRGAN	2,48	2,56
TSCÇÜA	3,55	3,78
YÇ (gerçek referans)	5	5


#### 4.4. Termal Yenidoğan (Neonatal) Görüntülerinden Oluşan Yeni Bir Veri Seti için Derin Öğrenme Tabanlı Süper Çözünürlük Uygulaması

Bu çalışma kapsamında, büyük üst ölçekleme oranları için süper çözünürlük uygulamaları gerçekleştirilmiş ve sınıflama başarıları üzerindeki etkileri gözlemlenmiştir. Burada, derin ağ modeli olarak TSCÇÜA modelinin geliştirilmiş versiyonu olan TSCÇÜA+ modeli kullanılmıştır. TSCÇÜA+ modeli ile elde edilen süper çözünürlüklü görüntüler, bikübik interpolasyon, SRGAN ve TSCÇÜA modelleri kullanılarak elde edilen süper çözünürlüklü görüntüler ile karşılaştırılmış ve daha başarılı olduğu görülmüştür. Ayrıca, bu çalışma neticesinde TSCÇÜA ve TSCÇÜA+ modellerinin büyük üst ölçekleme oranlarında da uygulanabilirliği kanıtlanmıştır.



#### 4.4.1. Farklı üst ölçekleme oranları için gerçekleştirilen süper çözünürlük uygulamalarında kullanılan veri setleri

Kullanılan veri setindeki gerçek referans termal görüntüler 256x256 boyutuna sahiptirler. Burada, toplam 676 adet termal yenidoğan bebek görüntüsü mevcuttur ve yüksek çözünürlüklü (gerçek referans) veri seti olarak kullanılmıştır. Bu görüntülerden hasta ve sağlıklı yenidoğanlara ait örnek termal bebek görüntüleri Şekil 4.11’de gösterilmektedir. Üst satırdaki termogramlar hasta bebeklere, alt satırdaki termogramlar ise sağlıklı bebeklere aittir. Daha sonra termal görüntüler 1/4, 1/8, 1/16 oranlarında alt ölçeklenerek sırasıyla 64x64, 32x32 ve 16x16 boyutlarında üç farklı düşük çözünürlüklü termal görüntülerden oluşan veri setleri elde edilmiştir. Böylece yüksek çözünürlüklü-düşük çözünürlüklü görüntü çiftlerinden oluşan üç ayrı veri seti oluşturulmuş ve farklı süper çözünürlük uygulamalarında kullanılmıştır.




Şekil 4.11. Süper çözünürlük uygulamalarında kullanılan veri setine ait örnek termogramlar

#### 4.4.2. Farklı üst ölçekleme oranları için süper çözünürlük uygulamaları

Bu çalışma kapsamında, yenidoğan bebeklere ait 676 adet düşük çözünürlüklü - yüksek çözünürlüklü termal görüntü çiftinden oluşan veri seti kullanılmıştır. Gerçekleştirilen bütün uygulamalar için eğitim ve test görüntüleri birbirinden farklı

olacak şekilde düzenlenmiştir. Burada, 576 adet düşük çözünürlüklü - yüksek çözünürlüklü görüntü çifti eğitim, 100 adet düşük çözünürlüklü - yüksek çözünürlüklü görüntü çifti (50 hasta+50 sağlıklı) ise test veri seti olarak belirlenmiştir. Gerçekleştirilen üç farklı süper çözünürlük uygulaması için TSCÇÜA+ modeli kullanılmış ve sonuçlar bikübik interpolasyon, SRGAN (Ledig ve ark., 2017), TSCÇÜA (Senalp ve Ceylan, 2021) modelleri ile karşılaştırılmıştır. x4, x8, x16 üst ölçekleme faktörleri için gerçekleştirilen süper çözünürlük uygulamaların tamamında eğitim süreçleri ayrı ayrı gerçekleştirilmiştir. Bu uygulamalar sonucunda farklı modellerin oluşturduğu süper çözünürlüklü ve orijinal düşük çözünürlüklü - yüksek çözünürlüklü görüntülere ait bazı örnekler Şekil 4.12’de gösterilmiştir. Elde edilen görüntüler incelendiğinde üst ölçekleme faktörünün artması görüntülerdeki iyileşmeyi zorlaştırmaktadır. Burada, TSCÇÜA+ modeli ile elde edilen süper çözünürlüklü termal görüntülerin, TSCÇÜA ve SRGAN modeli ile elde edilen süper çözünürlüklü termal görüntülere göre daha yüksek derecede iyileşme gösterdiği gözlemlenmiştir. Görsel olarak değerlendirmenin yanı sıra elde edilen bütün sonuçlar görüntü kalite metrikleri ile karşılaştırılmıştır. TSGO ve YBİ değerleri hesaplanırken orijinal yüksek çözünürlüklü görüntüler referans görüntü olarak belirlenmiştir. Elde edilen TSGO ve YBİ sonuçları Çizelge 4.12’de gösterilmiştir. Burada, x4 üst ölçekleme faktörü için gerçekleştirilen uygulama için TSGO değeri, TSCÇÜA modeline kıyasla yaklaşık 1,5 dB, SRGAN modeline kıyasla ise yaklaşık 2 dB değerinde artış göstermiştir. YBİ değeri ise TSCÇÜA modeline kıyasla %1 artış göstermiştir. Ayrıca, x8 ve x16 üst ölçekleme faktörleri için yerine getirilen çalışmaların sonuçları incelendiğinde önerilen modelin TSCÇÜA modeline kıyasla TSGO değerlerinde yaklaşık 1 dB, YBİ değerlerinde ise yaklaşık %3 artış gösterdiği gözlemlenmiştir. TSCÇÜA modelinin 10.000 iterasyonda eğitim süresinin yaklaşık 74 saat sürdüğü gözlemlenirken, TSCÇÜA+ modelinin eğitim süresi yaklaşık 63 saat sürmüştür. İki model arasındaki eğitim sürelerinin farklı olmasının sebebi, TSCÇÜA+ modelinde yığın normalleştirme katmanlarının kullanılmamasıdır.



Şekil 4.12. Farklı üst ölçekleme metotları için gerçekleştirilen süper çözünürlük uygulamaları ile elde edilen örnek termal görüntüler

Çizelge 4.12. Süper çözünürlük uygulamalarının TSGO ve YBİ sonuçları

Metot	Görüntü setleri					
	x4		x8		x16	
	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ
DÇ	20,071	0,865	18,811	0,835	17,998	0,810
Bikübik interpolasyon	23,354	0,914	21,363	0,889	19,865	0,839
SRGAN	24,467	0,961	22,053	0,927	20,652	0,877
TSÇÇÜA	25,131	0,962	22,686	0,938	21,150	0,913
TSÇÇÜA+(önerilen)	<b>26,817</b>	<b>0,973</b>	<b>23,753</b>	<b>0,957</b>	<b>22,186</b>	<b>0,942</b>

#### 4.4.3. Sınıflama uygulamaları

Bu bölümde açıklanan yenidoğanlara ait termal görüntüler üzerindeki sınıflama uygulamaları, süper çözünürlük tekniklerinin sınıflama başarısı üzerindeki etkilerini gözlemleyip, düşük çözünürlüklü görüntülerin sınıflama uygulamalarında etkin bir şekilde kullanılabilmesini sağlamak amacıyla gerçekleştirilmiştir. Bu çalışmalarda yenidoğanlar sağlıklı ve hasta olarak sınıflandırılmıştır. Burada, Bölüm 3.5.6'da açıklanmış olan ESA tabanlı sınıflayıcı kullanılmış ve düşük çözünürlüklü, yüksek çözünürlüklü ve süper çözünürlüklü termal görüntüler üzerinde sınıflama uygulamaları gerçekleştirilmiştir. Sınıflama uygulamaları için gerçekleştirilen eğitim ve test süreçleri bütün veri setleri için ayrı ayrı dikkate alınarak karmaşıklık matrisleri elde edilmiş ve Çizelge 4.13'te verilmiştir.

**Çizelge 4.13.** Sınıflama sonuçları için karmaşıklık matrisleri

a) x4 veri grubu											
Sınıflama sonucu Gerçek sınıf		DÇ		SRGAN		TSCÇÜA		TSCÇÜA+		YÇ (referans)	
		Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı
Hasta		48	2	47	3	48	2	49	1	49	1
Sağlıklı		9	41	7	43	4	46	2	48	0	50

b) x8 veri grubu											
Sınıflama sonucu Gerçek sınıf		DÇ		SRGAN		TSCÇÜA		TSCÇÜA+		YÇ (referans)	
		Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı
Hasta		46	4	44	6	46	4	47	3	49	1
Sağlıklı		10	40	5	45	3	47	1	49	0	50

c) x16 veri grubu											
Sınıflama sonucu Gerçek sınıf		DÇ		SRGAN		TSCÇÜA		TSCÇÜA+		YÇ (referans)	
		Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı	Hasta	Sağlıklı
Hasta		42	8	45	5	44	6	43	7	49	1
Sağlıklı		10	40	8	42	5	45	1	49	0	50

Bütün görüntü setleri için ayrı ayrı hesaplanan sınıflama metriklerinin değerleri Çizelge 4.14'te verilmiştir. Sonuçlar incelendiğinde süper çözünürlüklü görüntülerin düşük çözünürlüklü görüntülere kıyasla oldukça yüksek bir sınıflama başarısına sahip

olduğu görülmektedir. Ayrıca önerilen TSCÇÜA+ modelinin TSCÇÜA modeline göre yaklaşık %3 daha başarılı sınıflama yapabildiği gözlemlenmiştir. Sınıflama doğruluk değerleri x4 ve x8 veri setlerine göre daha düşük değerlerde olmasına rağmen x16 üst ölçekleme faktörü için gerçekleştirilen uygulamalar sonucunda elde edilen süper çözünürlüklü görüntülerin düşük çözünürlüklü görüntülere kıyasla yaklaşık %10 daha yüksek sınıflama başarısına sahip olduğu görülmüştür. Gerçekleştirilen bu sınıflama uygulamalarına ek olarak transfer öğrenme yöntemiyle sınıflama başarılarının artırılması hedeflenmiştir. İlk olarak Xception ve ResNet101 modelleri kullanılarak gerçekleştirilen uygulamalara ait sonuçlar sırasıyla Çizelge 4.15'te ve Çizelge 4.16'da verilmiştir. Sonuçlar değerlendirildiğinde en iyi sınıflama başarısının ResNet101 modeli ile elde edildiği görülmüştür.

**Çizelge 4.14.** Üç farklı veri seti için sınıflama sonuçları (ESA tabanlı model)

Üst ölçekleme oranı	Görüntü setleri	Doğruluk(%)	Kesinlik(%)	Duyarlılık(%)	F1 Skoru (%)
<b>x4</b>	DÇ	89	84,2	96	89,7
	SRGAN	90	87	94	90,6
	TSCÇÜA	94	92,3	96	94,1
	TSCÇÜA+	97	96,1	98	97
	YÇ ( gerçek referans)	99	100	98	99
<b>x8</b>	DÇ	86	82,1	92	86,8
	SRGAN	89	89,8	88	88,9
	TSCÇÜA	93	93,9	92	92,9
	TSCÇÜA+	96	98	94	96
	YÇ ( gerçek referans)	99	100	98	99
<b>x16</b>	DÇ	82	80,8	84	82,4
	SRGAN	87	80	90	84,7
	TSCÇÜA	89	93,9	88	90,9
	TSCÇÜA+	92	97,9	86	91,6
	YÇ ( gerçek referans)	99	100	98	99

**Çizelge 4.15.** Üç farklı veri seti için sınıflama sonuçları (Xception modeli ile transfer öğrenme)

Üst ölçekleme oranı	Görüntü setleri	Doğruluk(%)	Kesinlik(%)	Duyarlılık(%)	F1 Skoru (%)
<b>x4</b>	DÇ	89	89,8	90	89,9
	SRGAN	93	89,1	86	87,5
	TSCÇÜA	97	98	94	96
	TSCÇÜA+	97	96,1	96	96,1
	YÇ ( gerçek referans)	98	98	98	98
<b>x8</b>	DÇ	87	87,8	86	86,9
	SRGAN	93	92,2	94	93,1
	TSCÇÜA	94	95,8	92	93,9
	TSCÇÜA+	98	96,2	100	98,1
	YÇ ( gerçek referans)	98	98	98	98
<b>x16</b>	DÇ	85	81,8	90	85,7
	SRGAN	86	86	86	86
	TSCÇÜA	95	95,9	94	94,9
	TSCÇÜA+	94	92,3	96	94,1
	YÇ ( gerçek referans)	98	98	98	98

**Çizelge 4.16.** Üç farklı veri seti için sınıflama sonuçları (ResNet101 modeli ile transfer öğrenme)

Üst ölçekleme oranı	Görüntü setleri	Doğruluk(%)	Kesinlik(%)	Duyarlılık(%)	F1 Skoru (%)
<b>x4</b>	DÇ	90	88,5	92	90,2
	SRGAN	94	94	94	94
	TSCÇÜA	97	100	94	96,9
	TSCÇÜA+	99	100	98	99
	YÇ ( gerçek referans)	99	98	100	99
<b>x8</b>	DÇ	86	89,1	82	85,4
	SRGAN	92	88,9	96	92,3
	TSCÇÜA	95	92,5	98	95,1
	TSCÇÜA+	98	98	98	98
	YÇ ( gerçek referans)	99	98	100	99
<b>x16</b>	DÇ	84	84	84	84
	SRGAN	90	89,1	90	89,6
	TSCÇÜA	94	92,3	96	94,1
	TSCÇÜA+	95	95,9	94	94,9
	YÇ ( gerçek referans)	99	98	100	99

#### 4.5. Termal Yüz Görüntüleri İçin Bulut Tabanlı Süper Çözünürlük Uygulaması


Termal yüz görüntüleri kullanılarak gerçekleştirilen çalışmada, 25 farklı kişiye ait 485'er adet yüksek ve düşük çözünürlüklü renkli formattaki görüntülerden yararlanılmıştır. Düşük çözünürlüklü termal görüntüler üzerinde x4 üst ölçekleme tekniğine dayanarak süper çözünürlük çalışması yapılmıştır. Burada, derin ağ mimarisi olarak TSCÇÜA+ modeli kullanılmış ve süper çözünürlüklü görüntüler elde edilmiştir.

Daha sonra, akıllı telefon için geliştirilen Android arayüz yardımıyla bulut ortamında çalıştırılan bir süper çözünürlük sistemi tasarlanmıştır.

#### **4.5.1. TSCÇÜA+ modeli kullanılarak termal yüz görüntüleri üzerinde süper çözünürlük uygulaması**

Bu çalışmada kullanılan veri seti, 485 adet yüksek çözünürlüklü ve 485 adet düşük çözünürlüklü olmak üzere 970 adet termal yüz görüntüsü içermektedir. Bu görüntülerden 435 yüksek-düşük çözünürlüklü görüntü çifti eğitim veri seti olarak, 50 yüksek-düşük çözünürlüklü görüntü çifti ise test veri seti olarak kullanılmıştır. Ayrıca eğitim ve test görüntüleri birbirinden farklı olacak şekilde düzenlenmiştir. Düşük çözünürlüklü test görüntüleri 16x16 görüntü boyutuna sahiptir. Bu görüntüler TSCÇÜA+ derin ağ modeli ile x4 üst ölçeklenerek, 64x64 boyutlarında süper çözünürlüklü termal yüz görüntüleri elde edilmektedir. Yüksek çözünürlüklü (gerçek referans) görüntüler de aynı şekilde 64x64 görüntü boyutlarına sahiptir. Gerçekleştirilen süper çözünürlük uygulamalarına ait TSGO ve YBİ sonuçları SRGAN, TherISuRNet, TSCÇÜA modelleri ile karşılaştırılarak Çizelge 4.17'de verilmiştir. Sonuçlar değerlendirildiğinde TSCÇÜA modeline göre başarının büyük ölçüde arttığı gözlemlenmiş ve TSGO değeri 0,45 dB artarken YBİ değeri ise yaklaşık %5 artmıştır. Ayrıca SRGAN ve TherISuRNet modellerine göre TSCÇÜA+ modelinin oldukça başarılı sonuçlar elde ettiği gözlemlenmiştir. Elde edilen sonuç görüntülerine ait örnekler Şekil 4.13'te gösterilmektedir. Bu termal görüntüler incelendiğinde ve TSGO-YBİ değerleri baz alındığında, yüksek maliyetli termal kamera ile elde edilen termal görüntü kalitesine yaklaşma hedefinin kenar bilgilerini elde etme ve bulanıklık giderme etmenleri bakımından gerçekleştiği görülmüştür.

Gerçekleştirilen uygulamalarda eğitim işlemi 10.000 iterasyon yapılmıştır. TSCÇÜA modelinin eğitim süresi yaklaşık 41 saat iken, TSCÇÜA+ modelinde bu süre yaklaşık 32 saattir.



Şekil 4.13. Farklı süper çözünürlük metotları ile oluşturulan termal yüz görüntüleri (soldan sağa sırasıyla DC, Bikübik, SRGAN, TherISuRNet, TSCÇÜA, TSCÇÜA+ ve gerçek referans)

Çizelge 4.17. Termal yüz görüntülerinden elde edilen TSGO ve YBİ sonuçları

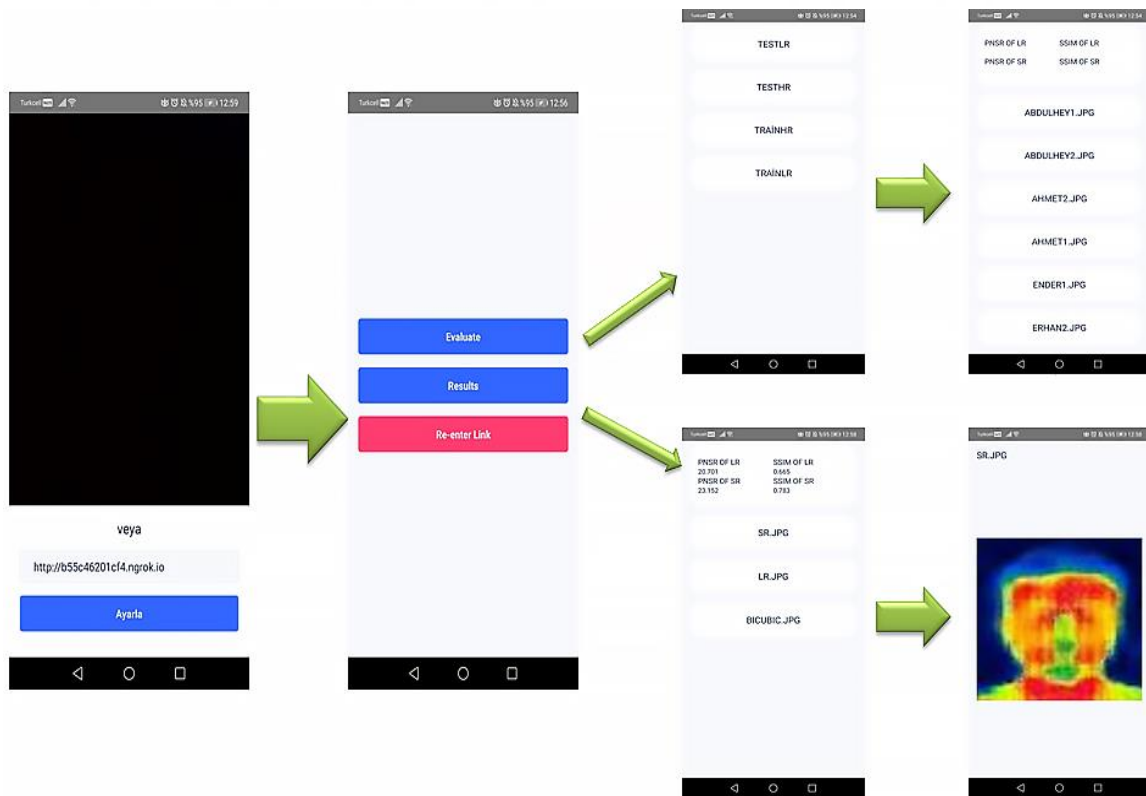
DC		Bikübik interpolasyon		SRGAN		TherISuRNet		TSCÇÜA		TSCÇÜA + (önerilen)	
TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ	TSGO	YBİ
13,665	0,533	13,743	0,549	13,832	0,565	14,076	0,571	13,988	0,589	14,412	0,637

#### 4.5.2. Süper çözünürlük modelinin bulut ortamında çalıştırılması

Bu bölümde ayrıntılı bir şekilde açıklanan bulut tabanlı sistem, gerçekleştirilen herhangi bir süper çözünürlük uygulamasının bulut ortamında da çalıştırılması ve kullanıcılara kolay erişim olanağı sağlaması amacıyla tasarlanmıştır. Burada, Android akıllı telefonlar için geliştirilen bir arayüz programı aracılığıyla bulut ortama erişim sağlanmıştır. Bu çalışmada, akıllı telefon olarak Huawei P20 Pro cihazı kullanılmış



olup, bu cihaz 8 çekirdek Kirin işlemciye, 6 gb sistem belleğine ve 128 gb dahili hafızaya sahiptir. Ayrıca, bulut ortamı olarak Bölüm 3.6’da açıklanan Google Colab tercih edilmiştir. Colab ortamında çalıştırılan program, ngrok yazılımı vasıtasıyla tünellenerek (port açma işlemi) internet ortamına çıkarılmıştır. Geliştirilen Android uygulama içerisinde ngrok adresi girilerek Colab’ta çalışan sisteme erişim sağlanmaktadır. Bulut tabanlı sistemin çalışmasına dair akıllı telefonda alınan ekran görüntüleri Şekil 4.14’te verilmiştir. “Evaluate” bölümü test veri setlerini ve bu veri setlerinden istenilen görüntünün seçilmesini sağlamaktadır. Daha sonra arka planda çalışmakta olan program vasıtasıyla seçilen görüntüden süper çözünürlüklü görüntü oluşturulmaktadır. Elde edilen bu süper çözünürlüklü görüntü ise ana menüde yer alan “Results” bölümüne kaydedilmektedir. Elde edilen görüntülerin TSGO ve YBİ değerleri de bu kısımda yer almaktadır. Böylece termal görüntülerin çözünürlüğündeki iyileşme, görselliğin yanı sıra TSGO ve YBİ metriklerinin de kullanılmasıyla mobil uygulama içerisinde gösterilmiştir. Ayrıca, ngrok adresinin değişmesi durumunda ana menüde yer alan “Re-enter Link” vasıtasıyla yeni bir ngrok adresi girilerek bulut ortamında çalışan programa yeniden erişim sağlanabilmektedir.



Şekil 4.14. Bulut tabanlı sistemin Android arayüzü

## 5. SONUÇLAR VE ÖNERİLER

### 5.1. Sonuçlar

Tez çalışmaları kapsamında, derin öğrenme modelleri kullanılarak termal görüntülerin çözünürlüğünün iyileştirilmesi ve geliştirilen modellerin çalıştırıldığı bulut tabanlı bir sistem geliştirilmesi hedeflenmiştir. Gerçekleştirilen uygulamalarda, termal yenidoğan ve yüz görüntülerine ait iki farklı veri tabanı kullanılmıştır.

İlk uygulamada, yenidoğan bebeklere ait sınırlı bir termal veri seti (200 adet termal görüntü) kullanılarak x4 üst ölçekleme faktörü için süper çözünürlük uygulaması yürütülmüştür. Burada, eğitim veri setindeki görüntüleri test aşamasında da kullanmak amacıyla 5 katlı çapraz doğrulama tekniği uygulanmıştır. Ayrıca, TSCÇÜA modelinin performansı termal görüntü ile ilgili çalışmalarda sıklıkla kullanılan 2 veri seti (GT ve KAIST) ile de test edilmiştir. Elde edilen tüm sonuçlar TSGO ve YBİ değerleri dikkate alınarak literatürde yer alan diğer modeller ile karşılaştırılmış ve bu değerlerde önemli miktarda artışlar gözlenmiştir. Böylece, süper çözünürlüklü görüntülerde hem gürültü miktarında azalma hem de çerçeve yapısındaki benzerlikte artış olduğu görülmüş ve termal görüntülerin görsel kalitesinde de iyileşmeler elde edilmiştir. Ayrıca, süper çözünürlüğün sınıflama başarısı üzerindeki etkisini gözlemlemek amacıyla düşük çözünürlüklü, yüksek çözünürlüklü, SRGAN ve TSCÇÜA modelleri ile oluşturulan süper çözünürlüklü görüntüler kullanılarak sınıflama uygulamaları gerçekleştirilmiştir. Bu görüntü gruplarına ait karmaşıklık matrisleri ESA tabanlı sınıflayıcı model ile elde edilmiş ve doğruluk oranları hesaplanmıştır. Daha sonra, transfer öğrenme tekniği uygulandığında sınıflama başarısının arttığı gözlemlenmiştir. ResNet50 ve Xception modelleri, sınıflama doğruluğunu yaklaşık olarak %2-3 aralığında artırmıştır. Ayrıca süper çözünürlüklü görüntüler ile gerçekleştirilen uygulamada, hasta ve sağlıklı bebekleri doğru sınıflayabilme oranının düşük çözünürlüklü görüntülere göre %5 daha fazla olduğu görülmüştür.

İkinci çalışma da ise, TSCÇÜA modeli kullanılarak üç farklı termal veri seti üzerinde süper çözünürlük uygulamaları gerçekleştirilmiştir. Yüksek çözünürlüklü (gerçek referans) görüntülerin (500 adet termal görüntü) boyutları 3 farklı uygulama için sabit iken düşük çözünürlüklü görüntüler de 1/2, 1/4 ve 1/8 oranlarında alt ölçeklendiği için farklı boyutlara sahiptir. Elde edilen sonuçlar, ilk uygulamadaki gibi TSGO-YBİ değerleri ve sınıflama başarıları dikkate alınarak değerlendirilmiştir.

Burada, bütün sonuçlar SRGAN modeli ile karşılaştırılmıştır. SRGAN modelinin literatürdeki önemi, termal görüntüler üzerinde gerçekleştirilen süper çözünürlük uygulamalarında ilk kez çekişmeli üretici ağların kullanıldığı derin ağ modeli olmasıdır. Özellikle görsel olarak evrişimli sinir ağları tabanlı modellere göre daha yüksek çözünürlüklü görüntüler oluşturabilmesidir. Sınıflama sonuçları değerlendirilirken doğruluk oranının yanı sıra kesinlik, duyarlılık ve F1 skoru değerleri de hesaplanmıştır. Elde edilen TSGO ve YBİ değerleri incelendiğinde TSCÇÜA modeli ile elde edilen süper çözünürlüklü görüntülerin, düşük çözünürlüklü görüntülere göre yaklaşık 3,5 dB, SRGAN ile elde edilen süper çözünürlüklü görüntülere göre de 0,5 dB artış gösterdiği görülmüştür. TSCÇÜA ile elde edilen süper çözünürlüklü görüntülerin sınıflama doğrulukları karşılaştırıldığında; x2 ve x4 üst ölçekleme tekniklerinin sonuçları düşük çözünürlüklü görüntülere göre %8 civarında artış gösterirken, x8 üst ölçekleme tekniğinin sonuçları %7 civarında artmıştır. Ayrıca TSCÇÜA ile üretilen süper çözünürlüklü görüntüler, SRGAN ile üretilen süper çözünürlüklü görüntüler ile karşılaştırıldığında x2, x4 ve x8 üst ölçekleme teknikleri için sırasıyla yaklaşık %5, %3 ve %1 oranlarında TSCÇÜA modelinin daha başarılı olduğu görülmüştür.

Tez çalışmalarında yer alan üçüncü uygulamada, termal yüz görüntüleri üzerinde iki farklı süper çözünürlük çalışması, derin ağ modeli TSCÇÜA kullanılarak gerçekleştirilmiştir. Elde edilen sonuç görüntüleri incelendiğinde, sadece yüz bölgelerine odaklanıldığında ham görüntülere göre hem TSGO ve YBİ değerleri hem de görsel değerlendirme kriterleri açısından üstünlük gözlenmiştir. Bu durum, hedef bölgeye odaklanmanın ve görüntüdeki arka fon gibi alanların kırılmasının, derin öğrenme tabanlı süper çözünürlük modelinin başarısını artırdığını göstermektedir.

Bir diğer çalışmada ise tez kapsamında önerilen TSCÇÜA modeli temel alınarak geliştirilen TSCÇÜA+ modeli kullanılmıştır. Veri seti olarak 676 adet termal bebek görüntüsü (gerçek referans) ve bu görüntülerden 1/4, 1/8, 1/16 oranlarında küçültülerek elde edilen üç farklı düşük çözünürlüklü veri seti kullanılmıştır. Süper çözünürlük uygulaması sonucu elde edilen görüntüler ile hesaplanan TSGO ve YBİ değerleri dikkate alındığında, TSCÇÜA+ modelinin TSCÇÜA modeline göre TSGO değerlerinde 1-1,5 dB, YBİ değerlerinde ise yaklaşık %2'lik bir artış sağladığı gözlemlenmiştir. Sonuç olarak, süper çözünürlüklü termal görüntülerdeki gürültü oranının azaldığı ve kenar (yüksek frekans) bilgilerinin daha iyi elde edildiği görülmüştür. Dolayısıyla, düşük çözünürlüklü görüntülere göre daha berrak ve keskin geçişlere sahip süper çözünürlüklü görüntüler ortaya çıkmıştır. Bunun yanı sıra, x16 üst ölçekleme faktörü

için oluşturulan süper çözünürlüklü görüntüler, bu uygulamadaki düşük çözünürlüklü görüntülerin piksel sayısının daha az olmasından dolayı, x4 ve x8 üst ölçekleme faktörü için elde edilen süper çözünürlüklü görüntülere göre daha düşük çözünürlüğe sahiptir. Ek olarak, düşük çözünürlüklü, yüksek çözünürlüklü ve süper çözünürlüklü (SRGAN, TSCÇÜA, TSCÇÜA+) termal görüntü setleri üzerinde sınıflama uygulamaları gerçekleştirilmiştir. İlk olarak daha önce bahsedilen ESA tabanlı sınıflayıcı ağı kullanılmıştır. Daha sonra tüm veri setlerindeki sınıflama başarılarını artırabilmek amacıyla Xception ve ResNet101 mimarilerinden yararlanılarak transfer öğrenme yöntemi uygulanmıştır. Karmaşıklık matrislerinden elde edilen sınıflama doğruluk oranları Çizelge 5.1’de verilmiştir. Sonuçlar incelendiğinde en yüksek sınıflama başarısı ResNet101 modeliyle gerçekleştirilen çalışmada elde edilmiş ve TSCÇÜA+ modeli ile elde edilen süper çözünürlüklü görüntülerin TSCÇÜA modeli ile oluşturulan süper çözünürlüklü görüntülere göre yaklaşık %2-3 daha yüksek doğrulukta sınıflandığı gözlemlenmiştir. Ayrıca, x8 ve x16 üst ölçekleme ile oluşturulan süper çözünürlüklü görüntülerin hasta-sağlıklı sınıflama başarısı, düşük çözünürlüklü görüntülere göre yaklaşık %10 artış göstermiştir. Bunun yanı sıra transfer öğrenme yöntemlerinin sınıflama başarılarını %3-4 aralığında artırdığı görülmüştür. Bu veriler dikkate alındığında, geliştirilen sınıflama modelinin transfer öğrenme teknikleriyle daha başarılı hale getirilebildiği sonucuna varılmıştır.

**Çizelge 5.1.** Farklı sınıflama uygulamaları sonucunda elde edilen doğruluk oranları

Veri grupları	Görüntü setleri	Doğruluk oranları (%)		
		ESA	Xception	ResNet101
x4	DÇ	89	89	90
	SRGAN	90	93	94
	TSCÇÜA	94	97	97
	TSCÇÜA+ (önerilen)	97	97	99
	YÇ (gerçek referans)	99	98	99
x8	DÇ	86	87	86
	SRGAN	89	93	92
	TSCÇÜA	93	94	95
	TSCÇÜA+ (önerilen)	96	98	98
	YÇ (gerçek referans)	99	98	99
x16	DÇ	82	85	84
	SRGAN	87	86	90
	TSCÇÜA	89	95	94
	TSCÇÜA+ (önerilen)	92	94	95
	YÇ (gerçek referans)	99	98	99

Gerçekleştirilen son uygulamada, 20 farklı kişiye ait 450'şer adet düşük çözünürlüklü ve yüksek çözünürlüklü termal yüz görüntüleri üzerinde TSCÇÜA+ modeli kullanılarak x4 üst ölçekleme tekniği için süper çözünürlük uygulaması gerçekleştirilmiştir. Elde edilen süper çözünürlüklü görüntülere ait görüntü kalite metrikleri dikkate alındığında görüntü kenar detaylarının netleşmesi ve bulanıklığın azaltılması gibi kriterler bakımından TSCÇÜA modeline göre termal yüz görüntülerin çözünürlüğünün arttığı gözlenmiştir. Daha sonra TSGO ve YBİ değerleri dikkate alındığında, TSCÇÜA+ modelinin TSGO değerinin TSCÇÜA modeline göre yaklaşık 0,5 dB arttığı, YBİ değerinin ise %5 arttığı tespit edilmiştir. Son olarak, gerçekleştirilen süper çözünürlük uygulaması Android bir uygulama aracılığıyla bulut ortamında çalıştırılarak, herhangi bir bilgisayar veya akıllı telefon ile sürekli erişilebilen bir sistem meydana getirilmiştir. Bu sayede süper çözünürlüğün dinamik bir şekilde kullanımı sağlanmıştır.

## 5.2. Öneriler

Termal kameralar, non-invazif, iyonize olmayan, zararsız ve hızlı görüntüleme sistemleri oldukları için geniş bir yelpazede kullanım alanına sahiptirler. Fakat termal kamera sistemlerinin getirdiği yüksek maliyet problemi, birçok alanda yararlanılabilecek bu görüntüleme sistemlerinin kullanımını kısıtlamaktadır. Bu dezavantajı ortadan kaldırabilmek için tez çalışması kapsamında, düşük maliyete sahip düşük çözünürlüklü termal kameradan (Flir One Pro) elde edilen görüntülerin kalitesini artırarak yüksek maliyetli termal kamera (Variocam HD) ile sağlanan görüntülerin kalitesine yaklaşmak hedeflenmiştir. Bu çerçevede, süper çözünürlük uygulamaları için geliştirilen derin ağ modelleri (TSCÇÜA ve TSCÇÜA+) iki farklı veri tabanında bulunan termal görüntülere uygulanmıştır.

Yenidoğan bebeklere ait termal görüntüler üzerinde ilk defa gerçekleştirilen süper çözünürlük uygulamaları sayesinde gerçek hayata yönelik bir uygulamada hem termal görüntülemeye hem de süper çözünürlük tekniklerinden faydalanılmıştır. Gerçekleştirilen hasta-sağlıklı bebekleri sınıflama uygulamaları neticesinde süper çözünürlüğün sınıflama başarısı üzerindeki etkisi vurgulanmıştır. Bu durum, düşük maliyetli ve düşük kalitede görüntüler oluşturan termal kameraların süper çözünürlük teknikleri yardımıyla hastalık teşhisi vb. medikal uygulamalarda kullanılabileceğini göstermektedir. Böylece termal görüntüleme sistemlerinin medikal alanlarda kullanımı

yaygınlaşabilecektir. Sonuç olarak, alternatif bir hastalık teşhis sistemi olarak düşük maliyete sahip bir termal görüntüleme sistemi oluşturulabilecek ve araştırmacılar bu yönde çalışmalar yürütebilecektir.

Farklı termal kameralar kullanılarak gerçekleştirilen süper çözünürlük uygulamaları tez çalışmasının odak noktasıdır. Çünkü geleneksel süper çözünürlük uygulamalarının dışına çıkılmış olup, birbirinden tamamen bağımsız iki farklı termal kamera vasıtasıyla düşük ve yüksek çözünürlüklü termal yüz görüntülerinden oluşan veri setleri oluşturulmuştur. Düşük maliyetli termal kameranın görüntü kalitesini yüksek maliyetli termal kameranın kalitesine yaklaştırarak, maliyet probleminin önüne geçmek esas amaç olarak belirlenmiştir. Elde edilen görüntü kalite metriklerinin değerleri ve bağımsız gözlemciler tarafından yapılan değerlendirme skorları, yerine getirilen süper çözünürlük uygulamalarının önemli başarılar ortaya koyduğunu göstermiştir. Sonuç olarak, termal kameranın farklı ilgi alanlarında ve sektörlerde kullanımının yaygınlaşması öngörülmektedir. Dolayısıyla, araştırmacıların termal görüntüleme süper çözünürlük uygulamalarına odaklanması yönünde teşvik edici bir çalışma ortaya konulmuştur.

Son olarak, gerçekleştirilen süper çözünürlük uygulamaları Android bir program aracılığıyla bulut ortamında çalıştırılarak, internet bağlantısı olan her türlü cihazdan erişilebilen bir sistem geliştirilmiştir. Bu sayede süper çözünürlüğün aktif ve etkin bir şekilde kullanımının önü açılarak çeşitli uygulama alanlarında kolaylıklar sağlayacağı düşünülmektedir. Böylece gerçek hayata yönelik uygulamalarda hem termal görüntüleme hem de süper çözünürlük tekniklerinden daha yaygın ve kolay bir şekilde faydalanılabilecektir.

Gerçekleştirilen bütün süper çözünürlük uygulamalarında veri sayısının artırılmasının başarıyı olumlu etkilediği gözlemlenmiş olup, daha büyük veri tabanlarının elde edilebilmesinin fark ortaya koyacağı göz önünde bulundurulmalıdır. Bunun yanı sıra termal yüz görüntüleri farklı termal kameralardan elde edildiği için düşük-yüksek çözünürlüklü görüntü çiftlerinin renk tonları birebir aynı olmamaktadır. Farklı termal kameralardan sağlanan termal görüntülerin tamamen aynı yapıya kavuşturulmasının, süper çözünürlük uygulamalarının başarılarını görsel olarak önemli ölçüde artıracığı öngörülmektedir.

Ayrıca görüntü çözünürlüğünü iyileştirme çalışmalarında kullanılan çekişmeli üretici ağ tabanlı modellerde, olasılıksal dağılım öneren katman yapısının yer aldığı varyasyonel otokodlayıcı modelinden yararlanması ile daha yüksek çözünürlüklü

görüntüler elde edilebilir. Bunun yanı sıra büyük üst ölçekleme faktörleri (x8, x16 vs.) ile gerçekleştirilecek uygulamalarda, büyük boyutlarda görüntülerden oluşan veri setleri kullanılmasının daha başarılı sonuçlar sağlayabileceği göz önünde bulundurulmalıdır.



## KAYNAKLAR

- Achanta, S. D. M., Karthikeyan, T. ve Vinothkanna, R., 2019, A novel hidden Markov model-based adaptive dynamic time warping (HMDTW) gait analysis for identifying physically challenged persons, *Soft Comput*, 23, 8359–8366.
- Aggarwal, J. ve Kumar, S., 2020, A survey on artificial intelligence, 10.31224/osf.io/47a85.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M. ve Farhan, L., 2021, Review of deep learning: concepts, CNN architectures, challenges, applications, future directions, *J Big Data*, 8(1), 53.
- Anwar, S., Khan, S. ve Barnes, N., 2020, A deep journey into super-resolution: A survey, *ACM Computing Surveys*, 53, 1-34.
- Babu, S., 2016, A study of cloud computing environments for high performance applications, *Proceedings of 2016 International Conference on Data Mining and Advanced Computing (SAPIENCE)*.
- Beiser, A., 2003, Concepts of modern physics, *New York: McGraw Hill*, 6, 52-68.
- Casimiro, M. H., Ferreira, L. M., Leal, J. P., Pereira C. C. L., ve Monteiro, B., 2019, Ionizing radiation for preparation and functionalization of membranes and their biomedical and environmental applications, *Membranes*, 9, 163.
- Ceylan, M., 2009, Bilgisayar tomografili akciğer görüntülerinin değerlendirilmesinde kompleks değerli yeni bir akıllı sistem tasarımı, *Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 154.
- Chen, W.K., 1993, Linear networks and systems, Belmont, 123-135.
- Choi, Y., Kim, N., Hwang, S. ve Kweon, I. S., 2016, Thermal image enhancement using convolutional neural network, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 223–230.
- Chollet, F., 2017, Xception: Deep learning with depthwise separable convolutions, *CVPR*, 1800-1807.
- Chudasama, V., Patel, H., Prajapati, K., Upla, K., Ramachandra, R., Raja, K. ve Busch, C., 2020, TherISuRNet- A computationally efficient thermal image super-resolution network. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Seattle, WA, USA, 388-397.
- Çiftci, S., ve Karaman, M., 2020, Landsat uydu görüntülerinde derin öğrenme tabanlı tek görüntülü süper-çözünürlük deneyleri, *Harran Üniversitesi Muhendislik Dergisi*, 5(3), 194-204.
- Dargan, S., Kumar, M., Ayyagari, M. R. ve Kumar, G., 2019, A survey of deep learning and its applications: A new paradigm to machine learning, *Archives of Computational Methods in Engineering*, 27, 1071-1092.



- Doad, H. ve Gupta, T., 2021, Cloud computing environment, *IJARCCCE*.
- Dong, C., Loy, C. C., He, K. ve Tan, X., 2016, Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38, 295-307.
- Dong, W., Fu, F., Shi, G., Cao, X., Wu, J., Li, G. ve Li, X., 2016, Hyperspectral image super-resolution via non-negative structured sparse representation, *IEEE Transactions on Image Processing*, 25(5), 2337-2352.
- Dosovitskiy, A. ve Brox, T., 2016, Generating images with perceptual similarity metrics based on deep networks, *In Advances in Neural Information Processing Systems (NIPS)*, 658–666.
- Du, W., Addepalli, P. ve Zhao, Y., 2019, The spatial resolution enhancement for a thermogram enabled by controlled sub-pixel movements, *IEEE Transactions on Instrumentation and Measurement*, 69(6), 3566-3575.
- Fan, Z., Bi, D., Xiong, L., Ma, S., He, L. ve Ding, W., 2018 Dim infrared image enhancement based on convolutional neural network. *Neurocomputing*, 272, 396-404.
- FLIR, 2022, Flir One Pro termal kamera, <https://www.flir.com/products/flir-one-pro/?model=435-0007-02> [Ziyaret Tarihi: 7 Ocak 2022].
- Fraivan, L., Alkhodari, M., Ninan, J., Mustafa, B., Saleh, A. ve Ghazal, M., 2017, Diabetic foot ulcer mobile detection system using smart phone thermal camera: A feasibility study, *BioMedical Engineering OnLine*, 16(1), 117.
- Fu, Y., Zhang, T., Zheng, Y., Zhang, D. ve Huang, H., 2019, Hyperspectral image super-resolution with optimized rgb guidance, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 11653-11662.
- Girshick, R., Donahue, J., Darrell, T. ve Malik, J., 2016, Region-based convolutional networks for accurate object detection and segmentation, *TPAMI*, 38(1), 142-158.
- Glasner, D., Bagon, S. ve Irani, M., 2009, Super-resolution from a single image, *IEEE 12th International Conference on Computer Vision*, 349-356.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. ve Bengio, Y., 2014, Generative adversarial networks, *In Advances in Neural Information Processing Systems (NIPS)*, 2672–2680.
- Google, 2021, Google Colaboratory'ye Hoş Geldiniz, [https://www.colab.research.google.com/?utm\\_source=scs-index](https://www.colab.research.google.com/?utm_source=scs-index) [Ziyaret Tarihi: 3 Ocak 2022].
- Gu, Y., Zeng, Z., Chen, H., Wei, J., Zhang, Y., Chen, B., Li, Y., Qin, Y., Xie, Q., Jiang, Z. ve Lu, Y., 2020, MedSRGAN: Medical images super-resolution using generative adversarial networks, *Multimedia Tools and Applications*, 79, 21815-21840.
- Guei, A. ve Akhloufi, M., 2018, Deep learning enhancement of infrared face images using generative adversarial networks. *Applied Optics*, 57(18), 98.

Hansen, M. ve Malchow, D., 2008, Overview of SWIR detectors, cameras and applications, *In Proc. SPIE 3939, Thermosense XXX*, Orlando, Florida.

Hasaltın, E. ve Beşdok, E., 2004, Görüntü dönüşümünde yapay sinir ağları yaklaşımı, *EMO*, 1-5.

He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770–778.

He, Z., Tang, S., Yang, J., Cao, Y., Yang, M. Y. ve Cao, Y., 2019, Cascaded deep networks with multiple receptive fields for infrared image super-resolution. *IEEE Transactions on Circuits and Systems for Video Technology*, 29(8), 2310-2322.

Herschel, W., 1800, XIV. Experiments on the refrangibility of the invisible rays of the sun, *Philosophical Transactions of the Royal Society of London*, 90, 284-292.

Huang, J., 2020, Image super-resolution reconstruction based on generative adversarial network model with double discriminators, *Multimedia Tools and Applications*, 79, 29639–29662.

Hwang, S., Park, J., Kim, N., Choi, Y. ve Kweon, I. S., 2015, Multispectral pedestrian detection: Benchmark dataset and baselines, *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 20.

IBM, 2020, What are convolutional neural networks, <https://www.ibm.com/cloud/learn/convolutional-neural-networks> [Ziyaret Tarihi: 13 Kasım 2021].

InfraTec, 2022, Variocam HD head 600 termal kamera, <https://www.infratec.eu/thermography/infrared-camera/variocam-hd-head-800/> [Ziyaret Tarihi: 7 Ocak 2022].

Ioffe, S. ve Szegedy, C., 2015, Batch normalization: Accelerating deep network training by reducing internal covariate shift, *Proceedings of The 32nd International Conference on Machine Learning (ICML)*, 448–456.

Jabbar, A., Li, X. Ve Omar, B., 2021, A survey on generative adversarial networks: variants, applications, and training, *ACM Computing Surveys*, 54(8), 1-49.

Javaid, H., Babar, T. K., Rasool, A. ve Saghir, R.U., 2013, Video colour variation detection and motion magnification to observe subtle changes, *M.Sc. Thesis*, Blekinge Institute of Technology, Faisalabad, Pakistan.

Johnson, J., Alahi, A. ve Li, F., 2016, Perceptual losses for real-time style transfer and super resolution, *In European Conference on Computer Vision (ECCV)*, 694–711.

Kim, J., Lee, J. K. ve Lee, K. M., 2016, Accurate image super-resolution using very deep convolutional networks, *IEEE CVPR*, 1646–1654.

- Kim, J., Lee, J. K. ve Lee, K. M., 2016, Deeply-recursive convolutional network for image super-resolution, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1637–1645.
- Lai, Z. ve Deng, H., 2018, Medical image classification based on deep features extracted by deep model and statistic feature fusion with multilayer perceptron, *Computational Intelligence and Neuroscience*, 1-13.
- Ledig, C., Theis, L., Huszar, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z. ve Shi, W., 2017, Photo-realistic single image super-resolution using a generative adversarial network, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 105-114.
- Lee, K., Lee, J., Lee, J., Hwang, S. ve Lee, S., 2017, Brightness-based convolutional neural network for thermal image enhancement, *IEEE Access*, 5, 26867-26879.
- Li, J., Fang, F., Mei, K. ve Zhang, G., 2018, Multi-scale residual network for image super-resolution, *Proceedings of the European Conference on Computer Vision (ECCV)*, 517–532.
- Lillesand, T., Kiefer, R. W. ve Chipman, J., 2014, Remote sensing and image interpretation, *John Wiley & Sons, Hoboken*.
- Lim, B., Son, S., Kim, H., Nah, S. ve Lee, K. M., 2017, Enhanced deep residual networks for single image super-resolution, *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 1132–1140.
- Liu, S., Yang, Y., Li, Q., Feng, H., Xu, Z., Chen, Y. ve Liu, L., 2019, Infrared image super resolution using gan with infrared image prior, *IEEE 4th International Conference on Signal and Image Processing (ICSIP)*, 1004–1009.
- Lloyd, J. M., 2013, Thermal imaging systems, *Springer Science & Business Media*.
- Lobanov, A. P., 2005, Resolution limits in astronomical images, *arXiv, preprint astro-ph/0503225*.
- Loussaief, S. ve Abdelkrim, A., 2018, Machine learning framework for image classification, *Advances in Science, Technology and Engineering Systems Journal*, 3(1), 01-10.
- Mandanici, E., Tavasci, L., Corsini, F. ve Gandolfi, S., 2019, A multi-image super-resolution algorithm applied to thermal imagery, *Applied Geomatics*, 11(3), 215–228.
- McCulloch, W. S. ve Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Miranda, E., Aryuni, M. ve Irwansyah, E., 2016, A survey of medical image classification techniques, *International Conference on Information Management and Technology*, 56-61.

- Newell, A. ve Simon, H., 1956, The logic theory machine: A complex information processing system, *IRE Transactions on Information Theory*, 2, 61-79.
- Nguyen, K., Fookes, C., Sridharan, S. ve Denman, S., 2013, Feature-domain super-resolution for iris recognition, *Computer Vision and Image Understanding*, 117(10), 1526-1535.
- Ornek, A. H., Ceylan, M. ve Ervural, S., 2019, Health status detection of neonates using infrared thermography and deep convolutional neural networks, *Infrared Physics & Technology*, 103.
- Pan, S. J., ve Yang, Q., 2010, A survey on transfer learning, *In IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359.
- Park, S. J., Son, H., Cho, S., Hong, K. S. ve Lee, S., 2018, Srfeat: Single image super-resolution with feature discrimination, *Proceedings of the European Conference on Computer Vision (ECCV)*, 439-455.
- Radford, A., Metz, L. ve Chintala, S., 2015, Unsupervised representation learning with deep convolutional generative adversarial networks, *arXiv preprint arXiv:1511.06434*.
- Rasamoelina, A. D., Adjailia, F. ve Sinčák, P., 2020, A Review of Activation Function for Artificial Neural Network, *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, 281-286.
- Rivadeneira, R., Sappa, A. D. ve Vintimilla, B. X., 2020, Thermal image super-resolution: A novel architecture and dataset, *15th International Conference on Computer Vision Theory and Applications*, 111-119.
- Rivadeneira, R., Suarez, P., Sappa, A. D. ve Vintimilla B. X., 2019, Thermal image super resolution through deep convolutional neural network, *International Conference on Image Analysis and Recognition*, 417-426.
- Rosenblatt, F., 1958, The Perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, 65, 386-408.
- Savasci, D., Ceylan, M., Ornek, A. H., Konak, M. ve Soylu, H., 2020, Heart disease detection from neonatal infrared thermograms using multiresolution features and data augmentation, *International Journal of Intelligent Systems and Applications in Engineering*, 8(1), 28-36.
- Senalp, F. M. ve Ceylan, M., 2021, Deep learning based super resolution and classification applications for neonatal thermal images, *Traitement du Signal*, 38(5), 1361-1368.
- Senalp, F. M. ve Ceylan, M., 2022, Effects of the deep learning-based super-resolution method on thermal image classification applications, *Multimedia Tools and Applications*, 81, 9313-9330.
- Shen, P., Zhang, L., Wang, M., 2021, Deeper super-resolution generative adversarial network with gradient penalty for sonar image enhancement, *Multimedia Tools and Applications*, 80, 28087-28107.

- Shi, W., Caballero, J., Huszar, F. ve Totz, J., 2016, Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1874-1883.
- Shi, W., Caballero, J., Theis, L., Huszar, F., Aitken, A., Ledig, C. ve Wang, Z., 2016, Is the deconvolution layer the same as a convolutional layer?.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv 1409.1556*.
- Singh, K., Gupta, A. ve Kapoor, R., 2015, Fingerprint image super-resolution via ridge orientation-based clustered coupled sparse dictionaries, *Journal of Electronic Imaging*, 24(4), 043015.
- Stankevich, S. A., Lubskiy, M. S. ve Forgac, A., 2019, Thermal infrared satellite imagery resolution enhancement with fuzzy logic bandpass filtering, *2019 International Conference on Information and Digital Technologies (IDT)*, 428-432.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9.
- Şenalp, F. M. ve Ceylan, M., 2020, Düşük çözünürlüklü termal yüz görüntü çözünürlüğünün derin öğrenme ile artırılması, *Avrupa Bilim ve Teknoloji Dergisi*, 131-135.
- Şenalp, F. M. ve Ceylan, M., 2022, Termal yüz görüntülerinden oluşan yeni bir veri seti için derin öğrenme tabanlı süper çözünürlük uygulaması, *Politeknik Dergisi*.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C. ve Liu, C., 2018, A survey on deep transfer learning, *ArXiv, abs/1808.01974*.
- Thawakar, O., Patil, P. W., Dudhane, A., Murala, S. ve Kulkarni, U., 2019, Image and video super resolution using recurrent generative adversarial network, *In 2019 16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, 1-8.
- Thevenaz, P., Blu, T., ve Unser, M., 2000, Image interpolation and resampling, *Handbook of Medical Imaging, Processing and Analysis*, Academic Press, San Diego, USA.
- Toyran, M., 2008, Düşük çözünürlüklü görüntülerden süper çözünürlüklü görüntü oluşturma, *Yüksek Lisans Tezi, İTÜ Fen Bilimleri Enstitüsü*, İstanbul.
- Trenkler, G., 1985, Mean square error matrix comparisons of estimators in linear regression, *Communications in Statistics Theory and Methods*, 14(10), 2495–2509.
- Voronin V., Semenishchev, E., Frants, V. ve Agaian, S., 2018, Smart cloud system for forensic thermal image enhancement using local and global logarithmic transform

- histogram matching, *2018 IEEE International Conference on Smart Cloud (SmartCloud) New York*, 153-157.
- Wang, M., Chen, Z., Wu, Q. M. J. ve Jian, M., 2020, Improved face super-resolution generative adversarial networks, *Machine Vision and Applications*, 31, 22.
- Xin, M. ve Wang, Y., 2019, Research on image classification model based on deep convolution neural network, *EURASIP Journal on Image and Video Processing*, 40.
- Yue, L., Shen, H., Li, J., Yuan, Q., Zhang, H. ve Zhang, L., 2018 Image super-resolution: The techniques, applications, and future, *Signal Processing*, 128, 389-408.
- Zhang, X., Li, C., Meng, Q., Liu, S., Zhang, Y. ve Wang, J., 2018, Infrared image super resolution by combining compressive sensing and deep learning, *Sensors (Basel)*, 18(8), 2587.
- Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B. ve Fu, Y., 2018, Image super-resolution using very deep residual channel attention networks, *Proceedings of the European Conference on Computer Vision (ECCV)*, 286–301.
- Zhang, S., Fu, G., Wang, H., Zhao, Y., 2021, Degradation learning for unsupervised hyperspectral image super-resolution based on generative adversarial network, *Signal, Image and Video Processing*, 15, 1695–1703.
- Zhu, J. Y., Park, T., Isola, P. ve Efros, A. A., 2017, Unpaired image-to-image translation using cycle-consistent adversarial networks, *Computer Vision (ICCV), IEEE International Conference*.