



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

**EVRIŞİMSEL SİNİR AĞLARI İLE 3D CAD MODELLER ÜZERİNDE
BENZERLİK ANALİZİ**

YÜKSEK LİSANS TEZİ

Rukiye TİPİ

Akıllı Sistemler Mühendisliği Anabilim Dalı

Akıllı Sistemler Mühendisliği Tezli Yüksek Lisans Programı

MAYIS 2025

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

**EVRIŞİMSEL SİNİR AĞLARI İLE 3D CAD MODELLER ÜZERİNDE
BENZERLİK ANALİZİ**

YÜKSEK LİSANS TEZİ

**Rukiye TİPİ
(21434998016)
ORCID: 0009-0008-2045-7450**

**Akıllı Sistemler Mühendisliği Anabilim Dalı
Akıllı Sistemler Mühendisliği Tezli Yüksek Lisans Programı**

**Danışman: Dr. Öğr. Üyesi Koray ALTUN
ORCID: 0000-0003-0357-9495**

MAYIS 2025



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Rukiye TİPİ

İmzası:

X X X X X



Aileme,

ÖNSÖZ

Tez çalışma süresi boyunca bana desteklerini esirgemeyen danışman hocam Dr. Öğr. Üyesi Koray ALTUN'a ve eğitim sürecim boyunca desteklerini esirgemeyen aileme sonsuz teşekkürlerimi sunuyorum.

Mayıs 2025

Rukiye TİPİ
(Yazılım Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER.....	viii
KISALTMALAR.....	x
SEMBOLLER.....	xi
ÇİZELGE LİSTESİ.....	xii
ŞEKİL LİSTESİ.....	xiii
ÖZET.....	xiv
SUMMARY.....	xvi
1. GİRİŞ.....	1
1.1 Tezin Amacı.....	3
1.2 Tezin Katkısı.....	4
1.3 Literatür Araştırması.....	4
2. DERİN ÖĞRENME.....	14
2.1 Evrişimsel Sinir Ağları.....	15
2.1.1 Evrişimsel katmanlar.....	16
2.1.1.1 Aktivasyon katmanları.....	17
2.1.1.2 Yığın normalizasyonu.....	18
2.1.2 Havuzlama katmanları.....	19
2.1.2.1 Global ortalama havuzlama.....	20
2.1.3 Tam bağlantılı katmanlar.....	20
2.1.3.1 Yoğun katmanlar.....	21
2.1.3.2 Dropout katmanı.....	21
2.1.4 Çıkış katmanı.....	22
2.1.4.1 Softmax.....	23
2.1.4.2 Çoklu sınıflandırma.....	24
2.2 Modern Evrişimsel Sinir Ağı Mimarileri.....	24
2.2.1 ResNet50.....	24
2.2.2 EfficientNet.....	25
2.2.3 Xception.....	26
2.2.4 MobileNetV2.....	26
2.2.5 InceptionResNetV2.....	27
2.2.6 DenseNet121.....	27
2.2.7 CNN mimarilerinin karşılaştırılmalı analizi.....	28
2.3 Değerlendirme Ölçütleri.....	30
2.3.1 Model performans metrikleri.....	30
2.3.1.1 Genel doğruluk.....	30
2.3.1.2 Makro F1 skoru.....	30
2.3.1.3 Ağırlıklı ortalama.....	32
2.3.1.4 Sınıf bazlı F1 skoru.....	33
2.3.2 Eğitim karakteristik metrikleri.....	33

2.3.2.1 Eğitim doğruluğu	33
2.3.2.2 Validasyon doğruluğu	34
2.3.2.3 Eğitim süresi	35
3. METOT VE ANALİZ	36
3.1 Veri Seti Ve Karakteristikleri	36
3.1.1 Veri toplama süreci.....	37
3.1.2 Görüntü oluşturma metodolojisi	38
3.1.3 Veri seti bölümlendirmesi	41
3.2 Kullanılan Platform Ve Donanım	43
3.3 CNN Mimarileri İle Elde Edilen Bulgular	43
3.3.1 Eğitim parametreleri.....	43
3.3.2 Mimarilerin performans sonuçları	45
4. SONUÇLAR VE ÖNERİLER.....	50
4.1 Sonuçlar	50
4.2 Öneriler	51
KAYNAKLAR	53
ÖZGEÇMİŞ	58

KISALTMALAR

2D	: 2 Boyutlu Uzay
3B	: 3 Boyutlu
3D	: 3 Boyutlu Uzay
AE	: Otokodlayıcılar
BN	: Yığın Normalizasyonu
B-rep	: Sınır Gösterimi
CAD	: Bilgisayar Destekli Tasarım
CNN	: Evrimsel Sinir Ağı
CPU	: Merkezi İşlem Birimi
DL	: Yoğun Katmanlar
DVM	: Destek Vektör Makinesi
ELM	: Extreme Learning Machine
GAP	: Global Ortalama Havuzlama
GPU	: Grafik İşlem Birimi
Grad-CAM	: Gradient Ağırlıklı Sınıf Aktivasyon Haritalama
MB	: Model Boyutu
MBConv	: Mobil Ters Darboğaz Konvolüsyonu
MPI	: İşleme Süreci Tanımlama
MRI	: Manyetik Rezonans Görüntüleme
NAS	: Nöral Mimari Arama
OBJ	: Nesne
RAM	: Rastgele Erişimli Bellek
RBM	: Sınırlı Boltzmann Makineleri
ReLU	: Doğrultulmuş Lineer Birim
RNN	: Tekrarlayan Sinir Ağları
SGDR	: Stokastik Gradyan İnişi ile Sıcak Yeniden Başlatma
STL	: Standart Üçgen Dili
UKSB	: Uzun Kısa Süreli Bellek
XCception	: Extreme Inception
WA	: Ağırlıklı Ortalama

SEMBOLLER

e	: Euler sayısı
$f(\mathbf{x})_i$	: Sınıfın tahmin olasılığı
m_i	: Sınıf metrik değeri
n	: Toplam sınıf adedi
x_i	: Ham skoru
w_i	: Örnek sayısı

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 2.1 : CNN mimarilerinin karşılaştırma tablosu	29
Çizelge 3.1 : Her bir açı sınıfındaki görsel dağılımı.....	42
Çizelge 3.2 : CNN mimarilerinin eğitim parametreleri karşılaştırması.	45
Çizelge 3.3 : Derin öğrenme modellerinin mimari özellikleri ve parametre detayları	46
Çizelge 3.4 : Sınıf bazlı F1 skor karşılaştırması.	47
Çizelge 3.5 : Modellerin eğitim karakteristikleri	48
Çizelge 3.6 : Modellerin veri artırma eğitim sonuçları	49

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1 : Evrişimsel sinir ağı mimarisi.	16
Şekil 2.2 : EfficientNet mimarisi	25
Şekil 2.3 : DenseNet mimarisi.	28
Şekil 3.1 : Bir STL dosyasının x düzleminde, (a) 0, (b) 45, (c) 90, (d) 135, (e) 180, (f) 225, (g) 270 dereceden açıları.....	39
Şekil 3.2 : Bir STL dosyasının y düzleminde, (a) 0, (b) 45, (c) 90, (d) 135, (e) 180, (f) 225, (g) 270 dereceden açıları.....	40
Şekil 3.3 : Bir STL dosyasının z düzleminde, (a) 0, (b) 45, (c) 90, (d) 135, (e) 180, (f) 225, (g) 270 dereceden açıları.....	41
Şekil 3.4 : Modellere göre doğruluk grafiği	47
Şekil 3.5 : Model performans karşılaştırması	48
Şekil 3.6 : Eğitim verisine uygulanan örnek data artırma	49

EVRIŞİMSEL SİNİR AĞLARI İLE 3D CAD MODELLER ÜZERİNDE BENZERLİK ANALİZİ

ÖZET

Yapay zeka teknolojilerindeki önemli ve büyük gelişmeler, özellikle görüntü işleme ve nesne tanıma alanlarında önemli ilerlemelere tanık olmaktadır. Bu gelişmelerin merkezinde yer alan Evrişimsel Sinir Ağları (CNN), endüstriyel tasarım ve üretim süreçlerinde işlenerek alana yeni ufuklar açmaktadır. Özellikle 3D CAD modellerinde benzerlik analizi konusu, geleneksel metotların çok ilerisinde, verimli ve yenilikçi çözüm yolları sunmaktadır.

Bu araştırmada, altı farklı CNN mimarisinin (ResNet-50, EfficientNet, Xception, MobileNetV2, InceptionResNetV2 ve DenseNet121) detaylı bir şekilde karşılaştırmalı olarak analizi gerçekleştirilmiştir. Çalışmadaki veri setini oluşturan 5859 tane CAD model görüntüsü x, y ve z olmak üzere üç düzlemdeki yedi farklı açıdan (0°, 45°, 90°, 135°, 180°, 225°, 270°) kapsamlı olarak görüntüleri alınarak detaylı bir şekilde analizi yapıp incelenmiştir. Veri setindeki %80'lik bölüm eğitim sürecinde kullanılırken, diğer kalan %20'lik kısım test aşamasında kullanılmak üzere ayrılmıştır. Bu ayırım, çıkan sonuçların güvenilir ve genellenebilir olmasını güvence altına almaktadır.

Araştırmadaki sonuçlar, her mimarinin kendisine has güçlü yönlerini ortaya koymuştur. Mimarilerde yedi farklı açıdan doğruluk oranları elde edilmiştir. Her bir açıdan çıkan farklı sonuçlar ve ortalama doğruluk oranı çalışmaya farklı bir bakış açısı kazandırmaktadır. İlk olarak ResNet50 mimarisi, yenilikçi "residual learning" mekanizmasıyla %73,22 gibi bir doğruluğa ulaşırken, Xception modeli, %69,73'lük bir performansla öne çıkmaktadır. InceptionResNetV2 mimarisinin %69,63'lük doğruluk oranı, MobileNetV2 modelinin %68,84'lük performansı, DenseNet121 mimarisinin %71,38'lik doğruluk oranı ve son olarak EfficientNet mimarisinin %72,83'lük sonucu, her mimarinin farklı işleyiş senaryolarına uygunluğunu göstermiştir. Özellikle dikkat çeken bulgulardan biri, tüm mimarilerdeki 0° görüntüleme açısında en yüksek performansı göstermesi olmuştur.

Model karmaşıklığındaki analiz, ilginç ve beklenmedik bir şekilde farklı sonuçlar ortaya koymuştur. Bir modelde fazla parametreye sahip olmanın her zaman çok daha iyi performans göstereceği anlamına gelmediği net bir şekilde tespit edilmiştir. Örnek olarak, 56.4M parametreye sahip InceptionResNetV2 mimarisinin, 24.7M parametreye sahip ResNet-50 mimarisinden daha düşük performans göstermesi, bu duruma çarpıcı bir örnek oluşturmaktadır. EfficientNet mimarisinin yalnızca 4.8M parametreyle elde ettiği %72,83'lük genel başarı oranı, verimli model tasarımının önemini ve optimizasyonun önemini vurgulayan dikkat çekici bir bulgudur.

Her bir mimari, endüstriyel alandaki uygulamaların farklı ihtiyaçlarına cevap olabilen kendine has avantajlar sunmaktadır. ResNet50 mimarisinin genel doğruluk oranı, karmaşık geometrik yapılarının tanınmasında iyi bir başarı sergilerken, MobileNetV2 mimarisinin hızlı işlem süresinin olması, gerçek zamanlı uygulamalarda öne

ıkmaktadır. EfficientNet mimarisi ise kaynak verimlilięi ile sınırlı donanım kaynaklarına sahip sistemlerde uygun bir seenek olarak karřımıza ıkmaktadır.

Bu arařtırma, CNN tabanlı benzerlik analizinin endüstriyel tasarım ve üretim süreçlerindeki pratik uygulanabilir olmasını net bir şekilde sunmaktadır. Ortaya ıkan sonuçlar, CAD modelleri arasındaki benzerlik analizinin derin öğrenme tekniklerinde uygulanabilir olabileceğini başarılı bir şekilde sergilemektedir.

Anahtar kelimeler: Evriřimsel sinir aęları, CAD, Benzerlik analizi, Derin öğrenme.



SIMILARITY ANALYSIS ON 3D CAD MODELS WITH CONVOLUTIONAL NEURAL NETWORKS

SUMMARY

Significant and major developments in artificial intelligence technologies have witnessed significant advances, especially in the field of image processing and object recognition. Convolutional Neural Networks (CNN), which are at the center of these developments, open new horizons in the field by being processed in industrial design and production processes. In particular, similarity analysis in 3D CAD models offers efficient and innovative solutions far beyond traditional methods.

In this research, a detailed comparative analysis of six different CNN architectures (ResNet-50, EfficientNet, Xception, MobileNetV2, InceptionResNetV2 and DenseNet121) was carried out. The 5859 CAD model images constituting the dataset in the study were analyzed and analyzed in detail by taking comprehensive images from seven different angles (0° , 45° , 90° , 135° , 180° , 225° , 270°) in three planes (x, y and z). While 80% of the dataset is used in the training process, the remaining 20% is reserved for the testing phase. This separation ensures that the results are reliable and generalizable.

The results of the study revealed the unique strengths of each architecture. Accuracy rates were obtained from seven different aspects of the architectures. The different results from each aspect and the average accuracy rate give a different perspective to the study. First, the ResNet50 architecture achieves an accuracy of 73,22% with its innovative residual learning mechanism, while the Xception model stands out with a performance of 69,73%. The 69,63% accuracy of the InceptionResNetV2 architecture, the 68,84% performance of the MobileNetV2 model, the 71,38% accuracy of the DenseNet121 architecture and finally the 72,83% result of the EfficientNet architecture demonstrate the suitability of each architecture for different operational scenarios. One particularly noteworthy finding was that all architectures showed the highest performance at 0° viewing angle.

The analysis on model complexity revealed interesting and unexpectedly different results. It was clearly established that having more parameters in a model does not necessarily mean that it will perform much better. As an example, the InceptionResNetV2 architecture with 56.4M parameters underperforms the ResNet-50 architecture with 24.7M parameters. The overall success rate of 72,83% achieved by the EfficientNet architecture with only 4.8M parameters is a remarkable finding that emphasizes the importance of efficient model design and optimization.

Each architecture offers its own advantages that can address the different needs of industrial applications. The overall accuracy of the ResNet50 architecture shows good success in recognizing complex geometric structures, while the fast processing time of the MobileNetV2 architecture stands out in real-time applications. EfficientNet

architecture, on the other hand, with its resource efficiency, is a suitable option for systems with limited hardware resources.

This research clearly demonstrates the practical applicability of CNN-based similarity analysis in industrial design and manufacturing processes. The results successfully demonstrate the applicability of similarity analysis between CAD models in deep learning techniques.

Keywords: Convolutional neural networks, CAD, Similarity analysis, Deep learning.



1. GİRİŞ

Endüstriyel tasarım ve üretimin günümüz dünyasında karşılaştığı en önemli zorluklardan biri, projelerin başlangıç süreçlerinin etkin ve verimli bir şekilde yönetilmesidir. Tasarımcılar ve mühendisler, her yeni projeye başlarken kapsamlı bir araştırma sürecinden geçmek zorundadır. Bu süreçler, geleneksel yöntemlerle yürütüldüğünde hem zaman alıcı olmakta hem de önemli maliyet kalemleri oluşturmaktadır.

Modern endüstriyel projelerin giderek artan karmaşıklığı, tasarımcıları ve ilgili paydaşları daha fazla bilgiye, daha kısa sürede ulaşma baskısıyla karşı karşıya bırakmaktadır. Proje süresinin büyük bir bölümü, benzer çalışmaların ve ürünlerin araştırılması gibi tekrarlayan faaliyetlerle geçmektedir. Bu zaman alıcı süreçler, projelerin toplam maliyetini artırmakta ve inovasyon potansiyelini önemli ölçüde sınırlamaktadır.

2016'da Gonçaves ve arkadaşlarının gerçekleştirdiği bir çalışma, tasarımcıların yaklaşık %71'inin dijital platformlarda benzer ürün araştırmasına yöneldiğini ortaya koymuştur. Her bir proje için ortalama 15 ila 20 saatlik araştırma süresi harcandığı belirtilmiş ve bu sürecin, tasarım ekiplerinin kaynaklarının büyük bir kısmını tükettiği vurgulanmıştır [1]. Cross'un 2011 yılında yayımladığı çalışmada ise, tasarım süreçlerinde dikkat çekici bir zaman dağılımı gözlemlenmiştir. Buna göre, tasarımcılar zamanlarının yaklaşık %20'sini problemin analizi ve araştırmasına, %15-20'sini ise pazar araştırması ve benzer ürün incelemelerine ayırmaktadır [2].

Benzer şekilde, Dell'Era ve arkadaşlarının 2025 yılında gerçekleştirdiği kapsamlı bir araştırma, tasarım odaklı inovasyon projelerinde zamanın çok büyük bir kısmının, çözüm alanını anlamaya yönelik araştırmalara ayrıldığını göstermektedir. 221 projeyi kapsayan bu çalışmada, ortalama 7,5 ay süren projelerin yaklaşık üçte birinin problem tanımı, kullanıcı ihtiyaçlarını anlama ve pazar doğrulama gibi araştırma faaliyetleriyle geçtiği tespit edilmiştir [3]. Bu bulgular, proje başlangıç sürecinde yapılan

arařtırmaların hem zaman hem kaynak ynetimi aısından ne kadar kritik olduėunu aıka ortaya koymaktadır.

Tasarım srelerinde elde edilen bařarının, byk lde bu bařlangı ařamasında yrtlen arařtırma faaliyetlerinin kalitesine baėlı olduėu sylenebilir. Bu baėlamda, tasarımcıların karřılařtıėı en byk zorluklardan biri de daha nce yapılmıř benzer projelere ulařmak ve bu bilgileri anlamlı bir řekilde yeniden kullanabilmektir. Ne yazık ki geleneksel yntemlerle yapılan arařtırmalar oėu zaman yetersiz kalmakta ve projenin ilerleyen ařamalarında ciddi sorunlara neden olabilmektedir.

Yapay zeka teknolojisi, zellikle evriřimsel sinir aėları mimarisi, bu tr zorluklara karřı yeniliki zmler sunmaktadır. Grsel benzerlik analizine dayalı sistemler, tasarım srelerinin bařında tasarımcılara kapsamlı bir bilgi havuzu sunarak, daha nce yapılmıř alıřmalara hızlı ve etkili eriřim imkânı saėlamaktadır. Bylece tekrarlayan arařtırma srelerinin nne geilerek kaynak kullanımı optimize edilmektedir.

CNN mimarilerinin endstriyel tasarım ve retim srelerinde saėladıėı bu katkı, projelerdeki genel verimliliėi artırmakta, maliyetleri dřrmekte ve toplam proje sresini kısaltmaktadır. Bu sistemler, tasarımcılara daha nce benzeri olmayan bir analiz kapasitesi ve sre optimizasyonu sunarak nemli bir rekabet avantajı kazandırmaktadır.

Yapay zekâ tabanlı grsel analiz teknolojilerinin, endstriyel tasarım alanındaki etkisi giderek artmaktadır. zellikle CNN mimarileri ile gerekleřtirilen grsel benzerlik analizleri, projelerin sre optimizasyonuna nemli katkılar saėlamaktadır. Bu alanda yapılan eřitli arařtırmalar, derin ėrenme mimarilerinin gcn ortaya koymaktadır. rneėin, He ve arkadaşlarının 2016 yılında geliřtirdiėi ResNet mimarisi, grnt sınıflandırma alanında byk bařarılar elde etmiřtir [4]. Tan ve Le'nin 2019 yılında ortaya koyduėu EfficientNet mimarisi, parametre verimliliėi ile dikkat ekerken; Chollet'in 2017 yılında sunduėu Xception mimarisi, ayrılabilir evriřim mantıėı ile yeniliki bir yaklařım sergilemiřtir [5,6]. Aynı yıl Huang ve arkadaşlarının geliřtirdiėi DenseNet mimarisi, katmanlar arası yoėun baėlantı yapısı ile derin zellik ıkarımında bařarılı sonular sunmuřtur [7]. Sandler ve arkadaşlarının 2018 tarihli MobileNetV2 mimarisi ise, zellikle mobil ve gml sistemler iin optimize edilmiř yapısıyla sınırlı kaynaklı ortamlarda etkili zmler sunmaktadır [8].

Bu araştırma özelinde, birbirinden farklı altı CNN mimarisinin (ResNet-50, EfficientNet, Xception, MobileNetV2, InceptionResNetV2 ve DenseNet121) benzerlik analiz performansları karşılaştırılacaktır. Her bir mimarinin kendine has güçlü yönlerinden yararlanılarak, tasarım süreçlerini daha optimize edebilecek ve bu süreçlere yön verebilecek kapsamlı bir benzerlik analizi yapılması amaçlanmaktadır.

1.1 Tezin Amacı

Bu tez çalışması, endüstriyel üretim ve tasarım süreçlerinin optimizasyonu için yenilikçi bir yaklaşım sunmaktadır. Araştırmadaki temel hedef, tasarım süreçlerinin başlangıç aşamasında kullanılabilecek derin öğrenme tabanlı benzerlik analizi ile başarılı sonuçlar elde etmiş olup tasarım süreçlerine yön vererek optimize etmektir.

Çalışmada kullanılacak altı farklı modern CNN mimari modellerinin (ResNet-50, EfficientNet, Xception, MobileNetV2, InceptionResNetV2 ve DenseNet121) performansları detaylı olarak analizi yapılacaktır. Bu altı mimarinin endüstriyel ürün görsellerindeki benzerlik analiz tespit yetenekleri karşılaştırmalı bir şekilde değerlendirilecektir.

Tasarım süreçlerinin karmaşık yapısı ve zaman alıcı nitelikleri göz önünde alındığında, yapılacak olan çalışma önemli avantajlar sunmaktadır. Tasarımcılar ve bu alanda çalışan kişiler, benzer olan çalışmalarını hızlı bir şekilde bulabilecek ve tasarım projesinin yönlerini erken aşamada tespit edebileceklerdir.

Önerilen bu yaklaşım, tasarım süreçlerinde hem süre hem de maliyet optimizasyonu gözeterek anlamlı sonuçlar çıkararak bu alanda çalışanlara farklı bir perspektif sağlamayı hedeflemektedir. Bununla birlikte tasarımcılar, projedeki rutin araştırma süreçlerine daha az zaman ayırarak önemli çalışmalara odaklanma fırsatı bulacaklardır.

Çalışma, endüstriyel tasarım alanında yapay zeka teknolojilerinin kullanımına yönelik yenilikçi bir bakış açısı sunmaktadır. Bu yaklaşım, geleneksel olan tasarım süreçlerinin moderleşmesinde önemli bir adım olarak değerlendirilmektedir.

1.2 Tezin Katkısı

Bu tez çalışması, endüstriyel tasarım ve üretim süreçlerindeki modern CNN mimarilerinin kullanımı ile 3D CAD modellerinde benzerlik analiz performanslarını inceleyerek literatüre özgün katkılar sağlamaktadır.

Birbirinden farklı altı CNN mimarisinin (ResNet-50, EfficientNet, Xception, MobileNetV2, InceptionResNetV2 ve DenseNet121) detaylı olarak performans analizi, gelecekte yapılacak benzer araştırmalar için sağlam bir altyapı oluşturmaktadır.

Çalışmadaki metodolojik yaklaşım, resim verilerinden gerçek CAD modellerine doğru uzanan sistemli bir eğitim süreci sunmaktadır. Bu yenilikçi yaklaşım, CNN modellerindeki öğrenme kapasitesini optimize ederken sonuçların endüstriyel uygulamalardaki başarısını da garantilemektedir.

Bu çalışma, tasarım süreçleri ile üretim süreçleri arasında köprü görevi görmektedir. Tasarımcılar, bu çalışma ile mevcut CAD modelleri arasındaki benzer çalışmaları hızlıca belirleyecektir. Bu yenilikçi özellik, projelerde erken aşamada önemli kararların alınmasını kolaylaştıracak ve kaynak optimizasyonu sağlayacaktır.

Yapılan testler ve sonuçlar, sistemin endüstriyel alandaki güvenilirliğini ve başarısını doğrulamaktadır. Yaklaşım, tasarımcıların süreçlerde kritik adımlara daha fazla odaklanabilmesini sağlarken, endüstriyel tasarım uygulamalarının dijital dönüşümüne önemli katkılar sağlamaktadır.

1.3 Literatür Araştırması

Son yıllarda teknolojiye yaşanan gelişmeler neticesinde derin öğrenme modellerinin eğitim süreleri kısalmış ve çok sayıda veri ile eğitilen modellerin başarı oranlarında önemli ölçüde artışlar yaşanmıştır. Bu gelişmeler ile ülkemizde ve dünyada yapay zekâ uygulamaları ile derin öğrenme uygulamalarına olan ilgi artmıştır. Yapılmış akademik çalışmalara bakıldığında artan ilginin akademik çalışmalara yansıdığı da tespit edilmiştir.

Reudiger-Flore ve arkadaşlarının, 2023 yılında yayınlamış oldukları çalışmada üretim sektöründe parça sınıflandırması için farklı bir çalışma yapmışlardır. Özellikle çalışma, ufak partili ve özel üretimler için derin öğrenme tabanlı görüntü sınıflandırma

metotları önermektedir. Ancak bu sistemler çok fazla etikete sahip veriye ihtiyaç duymaktadır. Bu durum az üretilen parçalarda büyük sorun yaratmaktadır. Bu araştırmacılar, CAD verilerinden gerçek olan görüntüler üreterek ilgili soruna çözüm üretmiştir. Transfer öğrenme yöntemlerini kullanarak sınıflandırmadaki başarısını artırmayı hedeflemişlerdir.

Standart üçgen dili (STL) ve nesne (OBJ) dosyalarını Blender yazılımını kullanarak parametrik görüntü üretim sistemi geliştirmişlerdir. Bu yaklaşım ile oluşturdukları gerçekçi görüntüler, ResNet, EfficientNet ve VGG gibi derin öğrenme mimarilerinde başarılı sonuçlar vermiştir. Transfer öğrenme ile az veri olmasına rağmen yüksek doğruluk oranları elde edilmiştir. Endüstriyel bir yapı üzerinde yöntemin işe yaradığı kanıtlanmıştır. Bu farklı yaklaşım, üretimde parça sınıflandırması için ekonomik çözüm sunmaktadır. Manuel bir şekilde veri toplama işini azaltıp, açıklanabilir bir veri artırımı sağlamaktadır. Özellikle ufak partili üretim ve tekrarlı üretim süreçlerinde verimli bir yöntem sunmuşlardır [9].

Farahmand'ın tez çalışmasında temel olarak arıcılıktan, arı kovanları ve peteklerinden, bir bal peteğindeki görüntülerin elde etme yaklaşımından ve bu görüntülerin etiketlenmesinden söz etmiştir. Elde edilen etiketlenmiş görüntülerin sınıflandırılması için kullanılabilecek metotlar ve değerlendirme metotlarını incelemiştir. Tez çalışmasında, yedi sınıftan oluşan toplam 103.451 eğitim görüntüsü ve 25.863 test görüntüsü içeren bal peteği veri seti oluşturulmuştur. Bu çalışmada bal peteğin sınıflandırması için derin öğrenme yaklaşımları sunulmuştur. Derin öğrenme yaklaşımlarının başarısı probleme göre değişebilmektedir. Bu çalışmada, önceden eğitilmiş CNN algoritmalarından, VGG16, VGG19, Inception-V3, AlexNet, self-structure CNN ve iki derin sinir ağı birleşimi olan ağ (ResNet50V2+Xception) kullanılarak sınıflandırma yapılmıştır. Sınıflandırma işleminin sonucunda en yüksek başarı oranı AlexNet algoritması %95 başarı oranı elde edilmiştir [10].

2021 yılında Bozkurt'un yaptığı çalışmada, COVID-19 virüsünün sebep olduğu viral pnömoni ve normal akciğer X-Ray görüntülerini sınıflandırmak için 11 farklı derin öğrenme modeli kullanarak derin bir çalışma yapmıştır. Modeller arasında DenseNet121 mimarisi en yüksek doğruluk değerine ulaşmış ve %97.17 doğruluk, %97.31 kesinlik, %97.23 duyarlılık, %97.26 F1-skoru elde etmiştir. Diğer öne çıkan modeller arasında Derin-Evrişimli Ağ %96.02, VGG16 mimarisi %95.76, AlexNet mimarisi %95.76, Xception mimarisi %95.50, VGG19 mimarisi %95.50 ve ResNet50

mimarisi %93.32 olarak sonuçlar bulunmuştur. En düşük performans %90.62 doğrulukla Sığ-Tam Bağlı Ağ modeline aittir. DenseNet121 modeli, veri setindeki üç sınıf (COVID-19, viral pnömoni, normal) için de yüksek sınıflandırma başarısı göstermiştir. Bu nedenle, önerilen modelin COVID-19 teşhisi için etkili bir yardımcı sistem olarak kullanılabileceği düşünülmektedir [11].

Ezzat (2020) tarafından yaptığı tez çalışmasında, akciğer BT görüntülerinde tümörlerin sınıflandırılması için altı farklı CNN modeli eğitilmiştir. Çalışmada kullanılan modeller; VGG16, ResNet50, AlexNet, GoogLeNet, LeNet ve özel olarak geliştirilen CNN-3 mimarileridir. Orijinal veriler üzerinde yapılan deneylerde en yüksek doğruluk oranı %99.8 ile VGG16 modelinden elde edilmiş, ResNet50 %99.6, GoogLeNet %98.7, AlexNet mimarisi %98.4, CNN-3 %97.2 ve LeNet mimarisi %96.5 doğruluk göstermiştir. Görüntülere bölütleme işlemi uygulandığında ise en iyi sonuç %99.4 doğruluk oranı ile ResNet50 modelinden alınmış, bunu VGG16 mimarisi %99.0, GoogLeNet %98.1, AlexNet %97.6, CNN-3 %96.4 ve LeNet mimarisi ise %96.2 oranı ile takip etmiştir. Elde edilen sonuçlar, hem uygun model seçiminin hem de veriye yapılan ön işlemlerin sınıflandırma performansını doğrudan etkilediğini göstermektedir. CNN modellerinin medikal görüntülerde yüksek doğruluk oranlarıyla sınıflandırma başarısı gösterdiğini ortaya koymuştur [12].

2023 yılında Öner tarafından yürütülen çalışmada, klinik ortamda toplanan otoendoskopik görüntüler üzerinde derin öğrenme algoritmaları kullanılarak dış kulak ve orta kulak hastalıklarının tespitini gerçekleştirmiştir. Çalışmada 10 farklı kulak hastalığı sınıfına sahip 2.125 görüntüden oluşan bir veri seti kullanılmış; çeşitli ön işleme ve veri artırımı teknikleri uygulanmıştır. Transfer öğrenimi yöntemiyle önceden eğitilmiş modeller kullanılarak sınıflandırma yapılmıştır.

EfficientNetB2, EfficientNetB3, InceptionV3, ResNet50, ResNet50V2, ResNet101, ResNet101V2, VGG-16, Xception ve InceptionResNetV2 gibi on farklı CNN tabanlı model değerlendirilmiştir. Yapılan eğitimlerde Adam optimizör algoritması en iyi sonucu vermiş, en yüksek doğruluk ise 40 epoch ve 32 batch size parametreleri ile yapılan çalışmada EfficientNetB2 ve ResNet50 modelleri ile %96 doğruluk oranı olarak elde edilmiştir. En iyi tanıma başarısı gösteren hastalık sınıfları ise Adesiv ve Opere olmuştur. Bu sonuçlar, derin öğrenme mimarilerinin kulak hastalıklarının otomatik ve doğru bir şekilde teşhis edilmesinde etkin bir yöntem sunduğunu göstermektedir [13].

Elitok ve arkadaşlarının çalışmasında, göğüs röntgen görüntülerinden pnömoni tespiti için iki farklı yaklaşım önerilmiştir. İlk yaklaşımda, MobileNetV2 modeli kullanılarak 1280 boyutlu öznitelik vektörleri çıkarılmış ve bu öznitelikler Destek Vektör Makinesi (DVM) ile Uzun Kısa Süreli Bellek (UKSB) modelleriyle sınıflandırılmıştır. DVM, %97,22 doğruluk ve 8,2 milisaniye tahmin süresiyle en yüksek performansı gösterirken, UKSB %90,35 doğruluk ve 9,78 saniye tahmin süresi elde etmiştir. İkinci yaklaşımda ise, MobileNetV2 ile çıkarılan öznitelikler t-SNE algoritması ile 3 boyuta indirgenmiş ve sınıflandırıcılara beslenmiştir. Bu durumda DVM %94,64 doğruluk ve 3,2 milisaniye tahmin süresi, UKSB ise %94,83 doğruluk ve 8,62 saniye tahmin süresi sağlamıştır. t-SNE kullanımı, DVM'nin tahmin süresini %61 oranında azaltırken doğruluğu hafif düşürmüştür; UKSB'de ise hem doğruluğu artırmış hem de tahmin süresini kısaltmıştır. Bu çalışmada önerilen yöntemler, veri artırma teknikleri kullanılmadan önce MobileNetV2 ile %97,22 doğruluk ve milisaniye seviyesinde tahmin süreleriyle rekabetçi sonuçlar sunmuştur. Özellikle t-SNE ile öznitelik boyutu azaltımının, DVM ve UKSB'nin hız ve doğruluk dengesini iyileştirmesi, klinik uygulamalarda hızlı ve güvenilir tanı sistemleri geliştirmek için önemli bir avantaj sağlamaktadır [14].

Özçelik ve arkadaşlarının 2024 yılında yapmış oldukları bu çalışmada, panoramik diş röntgen görüntülerinden otomatik diş segmentasyonu için UNet, FPN ve PSPNet gibi derin öğrenme mimarilerinin performanslarını karşılaştırmışlardır. 313 adet piksel seviyesinde etiketlenmiş panoramik görüntü kullanılarak yapılan deneylerde, VGG16 ağına sahip UNet modeli %93,74 F1 skoru, %88,22 Kesişim Üzerinden Birleşim (KüB) ve %98,25 doğruluk ile en yüksek performansı göstermiştir. EfficientNet ağı ile bu değerler %93,91 F1 skoru, %88,52 KüB ve %98,26 doğruluk seviyesine ulaşmıştır. Diğer ağlarından ResNet50 %93,85 F1 skor, InceptionV3 mimarisi %93,81 F1 skor ve MobileNetV2 mimarisi %93,79 F1 skor değerleri dengeli sonuçlar sunarken, PSPNet ve FPN modelleri daha düşük performans sergilemiştir.

Çalışma, UNet'in diş segmentasyonunda üstünlüğünü ve veri artırma teknikleri ile derin ağı seçiminin kritik rolünü vurgulamaktadır. Bu çalışma, UNet ve EfficientNet mimarilerinin kombinasyonunun literatürdeki diğer yöntemlerle rekabet edebilen sonuçlar sunduğunu ortaya koymaktadır. Ayrıca, derin öğrenme tabanlı metotların manuel segmentasyona kıyasla 25 saniye gibi kısa bir sürede yüksek doğruluk sağladığı ve klinik uygulamalarda zaman tasarrufu ile hata oranını azaltma potansiyeli

taşıdığı belirtilmiştir. Gelecek çalışmalar, daha geniş ve çeşitli veri setleri ile dış anomalilerinin otomatik tespiti üzerine odaklanmayı önermektedir [15].

2022 yılında Demir'in tez çalışmasında, COVID-19'un akciğer bilgisayarlı tomografi görüntülerinden derin öğrenme metotları ile tespit edilmesi amaçlanmıştır. RT-PCR testlerinin zaman alıcı ve erken evrelerde düşük doğruluk sorunlarını aşmak için 313 adet COVID-19 pozitif ve negatif BT görüntüsünden oluşan bir veri seti kullanılmıştır. İki ana yaklaşım izlenmiştir. Birinci yaklaşımda Basit-CNN ve VGG16 modelleriyle ağ derinliğinin performansa etkisi incelenmiş ve VGG16 mimarisi %98,25 doğruluk sağlamıştır. İkinci yaklaşımda ise transfer öğrenme ile VGG19, MobileNet ve DenseNet modelleri test edilmiştir. DenseNet201 mimarisi %99 test doğruluğu ile en yüksek performansı göstermiştir. Çalışma, derin öğrenmenin BT görüntülerinde COVID-19 tespitinde yüksek hız ve doğruluk gösterdiğinin ortaya koymuştur. Bu çalışma, DenseNet201'in klinik ortamlarda manuel segmentasyona kıyasla 25 saniye gibi kısa bir sürede yüksek doğruluk sağlamasıyla dikkat çekmektedir. Elde edilen bulgular, derin öğrenme tabanlı sistemlerin radyologların iş yükünü azaltma ve erken tanıya katkı sağlama potansiyelini vurgulamaktadır. Gelecek çalışmalar, daha geniş ve çeşitli veri setleri ile diğer akciğer patolojilerinin entegre analizi üzerine odaklanmayı önermektedir.[16].

Jha ve Pant'ın 2021 yılındaki çalışmasında, 33 farklı patojenik mikrop türünün mikroskopik görüntülerden otomatik sınıflandırılması için ResNet50, DenseNet121, Inception-ResNet-V2 ve MobileNetV2 gibi derin öğrenme mimarileri kullanılarak bir çalışma oluşturulmuştur. DIBaS veri seti (33 sınıf, yaklaşık 3.000 görüntü) üzerinde uygulanan Stokastik Gradyan İnişi ile Sıcak Yeniden Başlatma (SGDR) ve Ayırt Edici İnce Ayar teknikleriyle modellerin performansı optimize edilmiştir. Eğitim sonuçlarına göre, Inception-ResNet-V2 mimarisi her iki teknikte de %100 doğruluk sağlarken, MobileNetV2 SGDR ile %100, Ayırt Edici İnce Ayar ile %96.88 doğruluk elde etmiştir. ResNet50 ve DenseNet121 modelleri ise SGDR uygulandığında %100 doğruluğa ulaşmıştır. Ayrıca çalışma özellikle, hem daha fazla sınıf sayısı hem de daha yüksek doğruluk oranları ile öne çıkmaktadır. Hata analizinde, benzer morfolojik özellikler gösteren türlerde (örn. veri setindeki Lactobacillus alt türleri) sınırlı yanlış sınıflandırmalar gözlemlenmiştir. Çalışma, derin öğrenme tabanlı otomasyonun patojen tanımlamada insan uzmanlara kıyasla hız ve doğruluk avantajı sunduğunu

kanıtlamıştır. Gelecek çalışmalarda veri seti çeşitliliğinin artırılması ve hibrit mimarilerin test edilmesi önerilmiştir [17].

Pattanaik ve arkadaşlarının çalışmasında, meme kanserinin mamografi görüntülerinden sınıflandırılması için DenseNet121 tabanlı Hibrit Extreme Learning Machine (ELM) modeli önerilmiştir. Digital Database for Screening Mammography veri seti kullanılarak, 11.000 görüntü (7.700 eğitim verisi, 3.300 test verisi) üzerinde çalışılmıştır. Önerilen modelde, DenseNet121 mimarisinin tam bağlı katmanı ELM ile değiştirilmiş ve ağırlık optimizasyonu için AdaGrad algoritması uygulanmıştır. Batch boyutu 128 için %99.47 eğitim doğruluğu, %99.14 test doğruluğu, %99.37 özgüllük ve %99.94 duyarlılık elde edilirken, hesaplama süresi ise 159.77 dakika olarak ölçülmüştür. Diğer batch boyutlarında (32 ve 64) da hemen hemen benzer performans gösteren model, VGG19, MobileNet, Xception gibi geleneksel CNN mimarilerini tüm metriklerde geride bırakmıştır. Özellikle InceptionResNetV2 (%98.58) ve DenseNet201 (%98.98) gibi derin modellerle karşılaştırıldığında, DenseNet121+ELM'in daha az eğitim kaybı ve daha hızlı yakınsama süresi dikkat çekmektedir.

Çalışma, ELM'in özellik çıkarımı ve sınıflandırma aşamalarında sağladığı avantajlar ile klinik tanı süreçlerinde otomasyon potansiyelini vurgulamaktadır. Modelin en önemli sınırlaması, yüksek hesaplama süresine rağmen, meme kanseri teşhisinde insan hatalarını azaltma ve erken tanıya katkı sağlama yeteneğidir. Gelecek çalışmalarda, bu mimarinin karaciğer tümörü veya beyin lezyonları gibi diğer tıbbi görüntüleme veri setlerine uyarlanması planlanmaktadır [18].

2022 yılında yapılan başka bir çalışmada ise Breve, COVID-19'un akciğer X-ray (CXR) görüntülerinden tespiti için 21 farklı CNN mimarisini (VGG16, ResNet50, DenseNet169, EfficientNetB0-B3, InceptionResNetV2 vb.) kullanarak birbirleriyle karşılaştırmıştır. COVIDx8B veri seti (16.352 görüntü, 51 farklı ülkeden) üzerinde yapılan çalışmada, modeller ImageNet ön eğitilmiş ağırlıklarla transfer öğrenme yöntemi ile eğitilmiştir. DenseNet169 mimarisi, tek başına %98.15 doğruluk ve %98.12 F1 skoru ile en yüksek performansı gösterirken, EfficientNetB2 mimarisi (%97.56) gibi düşük parametrelili modeller de etkili sonuçlar vermiştir. Bir grup yöntemlerle (5 DenseNet169 örneği birleşimi) doğruluk %99.25'e, F1 skoru %99.24'e çıkarılmıştır. Bu sonuçlar, COVID-Net CXR-2 (%95.5) ve BaseNet (%95.5) gibi özel tasarımı modelleri geride bırakmıştır. Çalışma, heterojen veri setlerinde derin

öğrenmenin gücünü kanıtlarken, EfficientNet gibi hafif mimarilerin klinik uygulamalar için pratikliğine dikkat çekmiştir [19].

Su ve arkadaşlarının 2015 yılında yapmış oldukları “Multi-view Convolutional Neural Networks for 3D Shape Recognition” adlı çalışmalarında 3B şekil tanıma alanına kritik bir yaklaşım sunmaktadır. Araştırmacılar, bu görünüm tabanlı ve doğrudan 3B formatlarındaki etkinliği karşılaştıran kapsamlı analiz gerçekleştirmişlerdir.

Önerilen çoklu görünüm tabanlı bu CNN yaklaşımı, 3B nesnelerin farklı açılardan elde edilmiş 2B görüntülerini kullanarak yenilikçi bir çözümü sunmaktadır. Her bir görüntü, ilk olarak bağımsız CNN'ler tarafından işlenmekte ve sonrasında özel tasarlanan görünüm havuzlama katmanında birleştirilmektedir. Araştırmanın deneysel sonuç ve bulguları, beklenmedik bir şekilde etkileyici olarak gözlemlenmektedir. Tek bir görünüm bile mevcut 3B tanımlayıcılarından daha üstün performans göstermektedir. ModelNet40 veri setinden elde edilen %90,1 sınıflandırma doğruluğu, %70,4 geri alma mAP değerleri sistemin başarısını da kanıtlamaktadır. Bu çalışma ile görünüm temelli yaklaşımın 3B şekil tanıma alanında üstün bir metot olduğunu ortaya koymaktadır. Geliştirilen özgün CNN mimarisi, çoklu görüntüleri etkili bir şekilde birleştirerek alanda yeni standart belirlemiştir. Makaledeki en önemli katkı, 2B görüntü ile 3B şekil tanıma alanları arasında kurduğu köprüdür. Bu yaklaşım ile birlikte her iki alanın birbirinden yararlanmasını sağlayarak, bilgisayar ile görü alanında da yeni ufuklar açmaktadır [20].

2021 yılında Rajpal ve arkadaşları bu çalışmada, COVID-19'un göğüs röntgeni görüntülerinden tespitini iyileştirmek amacı ile, ResNet50 derin evrişimli sinir ağı ile birlikte geleneksel görüntü işleme yöntemlerinden elde edilen bir dizi el yapımı özelliğin bir araya getirildiği yeni bir çok sınıflı sınıflandırma çerçevesi sunmuşlardır. Bu çerçeve, üç temel modülden oluşmaktadır.

İlk modülde, önışlenmiş göğüs röntgeni görüntüleri ResNet50 ağına girdi olarak verilerek, bu ağın transfer öğrenimi yeteneklerinden faydalanılmış ve 2048 özellikli bir vektör elde edilmiştir. İkinci modülde, göğüs röntgeni görüntülerinden çıkarılan 252 el yapımı özellik, temel bileşen analizi ile 64 özelliğe indirgenmiştir. Ardından bir ileri beslemeli sinir ağı ile 16 özelliğe düşürülmüştür. Bu el yapımı özellikler, görüntülerin dokusal ve frekans alanına ait özelliklerini içermektedir. Üçüncü modülde ise, ilk iki modülden elde edilen özellikler birleştirilerek (toplamda 2064

özellik), bir yoğun katmana ve ardından sınıflandırma için bir softmax katmanına verilmiştir.

Önerilen modelin etkinliğini doğrulamak için 10 katlı çapraz doğrulama kullanılmış ve modelin $97,4 \pm 0,02$ genel sınıflandırma doğruluğu elde ettiği belirtilmiştir. Sınıflara özgü performans değerlendirmesinde ise, COVID-19, normal ve zatürre sınıfları için sırası ile $98,7 \pm 0,05$, $96,3 \pm 0,05$ ve $97,3 \pm 0,04$ duyarlılık değerleri elde edilmiştir. Ayrıca, modelin bağımsız bir göğüs röntgeni kohortu üzerinde yapılan doğrulama testinde $97,9$ 'luk bir sınıflandırma doğruluğu sergilediği ifade edilmiştir [21].

Çalışma Salim ve arkadaşlarının 2023 yılında yapmış olduğu, önceden eğitilmiş derin öğrenme modellerinin meyve sınıflandırması için etkinliğini incelemişlerdir. Meyve sınıflandırması için iki farklı veri kümesi kullanılmıştır: Fruits-360 ve Meyve Tanıma veri kümesi. Deneylerde, mimarileri ve özellikleri temel alınarak dört adet önceden eğitilmiş model seçilmiştir: DenseNet-201, Xception, MobileNetV3-Small ve ResNet-50. Fruits-360 veri kümesinde tüm modeller yaklaşık 99 veya daha yüksek doğruluk elde etmiştir. Meyve Tanıma veri kümesinde ise DenseNet-201 ve Xception modelleri yaklaşık 98 doğruluk elde etmiştir. Özellikle DenseNet-201'in Fruits-360 ve Meyve Tanıma veri kümelerinde sırası ile 99.87 ve 98.94 doğruluk oranlarına ulaşması dikkat çekici bir sonuç olarak öne çıkmaktadır. Xception modeli de aynı veri kümelerinde sırasıyla 99.13 ve 97.73 doğruluk oranları elde etmiştir [22].

Özdemir yapmış olduğu tez çalışmasında, limon görüntülerinin EfficientNet ve ResNet50 gibi derin öğrenme modelleri ile sınıflandırılmasını incelemiştir. EfficientNet yaklaşık olarak 70 gibi bir başarı oranı yakalarken, ResNet50 modeli $98,84$ gibi daha yüksek bir başarı oranı elde etmiştir. AlZamily ve Abu Naser 2019 yılında benzer bir çalışmada, CNN ağılarıyla $99,48$ başarı elde etmiştir. Bu çalışmada ResNet50 modelinin yüksek başarı oranını ile düşük kayıp fonksiyonunu (0.047) gözlemlemiştir.

Veri artırım teknikleri ile farklı derin öğrenme modelleri kullanarak başarı oranını daha da çok artırma imkanı vurgulanmıştır. Çalışma, ResNet50 modelindeki üstün başarı oranı ve doğruluğuyla dikkat çekmiştir. Küflü limonların yanlış sınıflandırılması problemi, veri setinin genişletilmesiyle çözülebilir olacağını ifade

etmiştir. Literatür taramasında ise benzer çalışmalara ülkemizde rastlanmamış olup, bu çalışmanın yeni araştırmalara kritik katkılar sağlayabileceği vurgulanmıştır [23].

Koyuncu ve arkadaşlarının yapmış olduğu “A New Breakpoint to Classify 3D Voxels in MRI: A Space Transform Strategy with 3t2FTS-v2 and Its Application for ResNet50-Based Categorization of Brain Tumors” adlı çalışmalarında, 3D manyetik rezonans görüntüleme (MRI) verileri ile tümör sınıflandırması yapılmaktadır. Mevcut yaklaşımlardan farklı olarak, 3t2FTS-v2 ismi verilen yeni bir metot sunulmaktadır. Bu metot, 3D verilerini iki boyutlu alana indirgeyerek geleneksel makine öğrenimi algoritmalarının kullanımını da sağlamaktadır. Özellikle ResNet50 mimarisi, yüksek ve düşük dereceli glioma tümörlerinin sınıflandırılmasında da kullanılmış, ayrıca %99,64 doğruluk oranı elde edilmiştir.

Çalışma, 3t2FTS-v2'nin beyin tümörü sınıflandırmasında da yüksek performans sağladığını ve gelecekte bu metodun daha geniş veri setleri ile farklı hastalık sınıflandırmalarında da uygulanabileceğini vurgulamaktadır. Makalede 3D MR görüntülerindeki voksel verilerini de 2D görüntülere dönüştürmeyi hedefleyen bir uzay dönüşüm yöntemi olan "3t2FTS-v2" yöntemini tanıtmaktadır. Beyin tümörlerinin sınıflandırılmasında bu dönüştürme işlemi, ResNet50 derin öğrenme modelindeki etkinliğini artırmak için kullanılmaktadır. 3t2FTS-v2 uzay dönüşüm yöntemi, MR görüntülerinde 3B verileri 2B düzlemlere dönüştürmek için hesaplama yükünü azaltırken aynı zamanda ResNet50 modelinin 2B görüntüler üzerinde etkin bir şekilde çalışmasını sağlamaktadır. Bu yaklaşım ile beyin tümörlerinin sınıflandırılmasında daha hızlı, etkili ve daha doğru sonuçlar elde edilmesini mümkün kılmaktadır [24].

Shin ve arkadaşlarının 2016 yılında yapmış olduğu “Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics, and Transfer Learning” adlı çalışmalarında CNN modellerinin tıbbi görüntüleme alanındaki kullanımı ile kritik bir araştırma yapmıştır. Tıbbi görüntü verilerinin kısıtlı olması sebebiyle, günlük fotoğraflar için eğitilen CNN modellerini transfer öğrenimi ile tıbbi alana uyarlamayı başarmışlardır.

Araştırmada iki temel sorun ele alınmaktadır: torako-abdominal lenf nodu bulma ile interstisyel akciğer hastalığını sınıflandırmadır. Lenf nodu tespitinde %86 gibi etkileyici başarı yakalanmış, bu da önceki metotlardan daha iyi sonuç vermektedir. ILD sınıflandırmasında da, sınırlı veri olmasına karşın transfer öğrenimi ile %87

doğruluk oranı elde edilmiştir. AlexNet, GoogLeNet ve CifarNet gibi farklı CNN yapıları ile test edilmiş ve ilginç bir sonuç ortaya çıkmıştır: Transfer öğrenimini uygulayan modeller, sıfırdan eğitilenlere göre çok daha başarılı olmuştur. Bu çalışmanın sonuçları, tıbbi görüntü analizini ve bilgisayarlı teşhis sistemleri için başarılı sonuçlar göstereceğini işaret etmiştir [25].



2. DERİN ÖĞRENME

Derin öğrenme teknolojisi, günümüzde hızla gelişen bir teknoloji ve türlü alanlarda uygulanabilirliği çokça artan yapay zeka metotlarından biridir. Çok katmanlı yapay sinir ağları ile verilerden üst seviye özellikleri otomatik bir şekilde çeşitlendiren bu teknik, özellikle çok büyük veri setleri içerisindeki karmaşık modelleri tespit etmede başarılı sonuçları vermektedir [26]. Bu başarılı sonuçlardan biri olan konvolüsyonel sinir ağları ise görüntü işleme alanı ve bilgisayarlı görme alanında önemli bulgu ve sonuçlar üreterek ilgili alanlardaki çalışmaları kritik bir ölçüde ilerletmiştir [27]. Yapay zeka teknolojisinin en yenilikçi ve en dinamik alanlarından biri olarak gösterilen veri yapılarını derinlemesine çözümleyebilen ve karmaşık örüntüleri bulup hesaplamalı olan sistemlerin geliştirilmesinde de kritik bir öneme sahiptir. Bu sistemler insan beynindeki bilgiyi işleme düzeneklerini özümseyerek, çok katmanlı bu sinir ağları ile veri analizi görevini ve örüntü tanıma görevini başarılı olarak yerine getirmektedir. 2000 yıllarının başında literatüre giren derin öğrenme kalıbı, özellikle 2012 yılında AlexNet mimarisinin ImageNet yarışmasında olan büyük başarısı ile birlikte araştırmacılarda ilgi noktası haline gelmiştir [28].

Geleneksel makine öğrenmesi tekniklerinden farklı olarak derin öğrenme tekniği, ham olan veriden otomatik olarak özellik çıkarımı gerçekleştirebilmiş uçtan uca bir şekilde öğrenme temelleri sunmaktadır. Gelişen sistemlerde, doğal dil işleme görevi, görüntü tanıma görevi ve ses analizi gibi görevlerde insan gücünü de aşabilen sonuçlar göstermektedir. Derin öğrenmedeki yöntemlerin çok katmanlı olan yapısı, her bir katmanın önceki katmandan almış olduğu bilgiyi alıp işleyerek soyut özellikler ve karmaşık özellikleri de öğrenmesine olanak sunmuştur. Hiyerarşik olan bu yapı, verinin farklı soyutlama seviyelerinde gösterimini mümkün kılıp daha kapsamlı bir analiz sunmaktadır [26].

Derin öğrenme sistemlerindeki üç ana unsur sinerjik bir etkileşime dayanmaktadır. Kapsamlı olan veri kümelerinin erişilebilir bir yapıda olması, yenilikçi optimizasyon algoritmalarının da geliştirilmesi ve ileri seviyede hesaplama kaynaklarının da var olmasını kapsamaktadır. Grafik İşlem Birimi (GPU) teknolojisinin giderek

yaygınlaşması, derin sinir ağlarının da eğitim sürecini önemli bir derecede hızlandırmış ve çok daha karmaşık mimarilerin uygulanabilirliğini artırmaktadır. ReLU aktivasyon fonksiyonu gibi yenilikçi olan bu yaklaşımlar, derin sinir ağlarının eğitimini dengeli ve verimli bir duruma getirmiştir [29].


Derin öğrenme mimarileri, uygulamanın ihtiyaçlarına göre değişik yapılarda da tasarlanabilmektedir. Görüntü işleme uygulamalarında ve bilgisayarlı görü uygulamalarında CNN'ler, zaman serisi analizi alanında RNN ağı ve LSTM ağı, doğal dil işleme kısımlarında ise transformatörler yaygın bir şekilde tercih edilmektedir. Bu özelleştirilen mimariler, gradyan tabanlı öğrenme yöntemlerini kullanarak, her bir görev için uygun parametreleri belirlemeye çalışmaktadır. Modern uygulamalarda ise bu mimarilerin hibrit versiyonları da artarak daha çok kullanılmaktadır [30].

Derin öğrenmedeki eğitim, geleneksel bir şekilde yüksek oranda etiketli veri ihtiyacı gerektiren denetimli öğrenme metoduna dayanmaktadır. Ancak son dönemlerde geliştirilmiş olan transfer öğrenme yaklaşımı ve öz-denetimli öğrenme yaklaşımı, daha az etiketli veri ile etkili modeller geliştirebilmeyi mümkün kılmaktadır. Bu yenilikçi teknikler, derin öğrenmedeki uygulama alanlarını genişletip büyütürken ve bununla birlikte eğitim sürecinin verimliliğini kritik bir ölçüde artırmaktadır. Özellikle endüstriyel alanlardaki bu metotların kullanımı giderek daha da yaygınlaşmaktadır [31].

2.1 Evrimsel Sinir Ağları

İnsanın beyin çalışma sisteminden ilham alınarak geliştirilmiş CNN teknolojisi, görüntüleri anlayıp sentezleme konusunda önemli bir devrim başlatmıştır. Bu akıllı sistemlere duyulan merak, özellikle karmaşık yapıdaki resim ve videoları çözümlemedeki başarılı yetenekleri sebebiyle her geçen gün artmaktadır. Eski tip yapay zeka sistemleri ise büyük boyuttaki görsel verileri işlemekte zorlanarak çok kaynak tüketmesinin yanında CNN'ler daha akıllıca çalışmaktadır. Bunun sırrı ise tıpkı insan gözüne benzeyen görüntülerinin parçalarına odaklanabilmiş olan ve bu bilgileri kalan parçalar ile paylaşabilen özel bir yapıda olmasında yatmaktadır [32]. İnsan gözündeki çalışma prensiplerinden yararlanarak tasarlanabilen CNN sistemleri, görüntüleri katmanlı bir şekilde inceleyerek, basit çizgilerden karmaşık olan şekillere kadar her bir bilgiyi kendi kendine öğrenebilmektedir. Bu teknoloji, yalnızca fotoğraflarda bulunan nesneleri tanımakla kalmayıp doktorların hastalıkları teşhis

edebilmesine, araçların kendi kendine gidebilmesine ve güvenlik kameralarının şüpheli olan durumları da fark edebilmesine yardımcı olmaktadır. Bu alanda çalışanlar ise her geçen gün CNN'leri daha da çok geliştirirken, bu sistemler görüntü işleme alanında yepyeni kapılar açmakta ve gelecekte çok daha etkileyici ve verimli uygulamalara da yön vermektedir.



Şekil 2.1 : Evrişimsel sinir ağı mimarisi [33].

2.1.1 Evrişimsel katmanlar

Evrişimsel katmanlardaki çalışma ilkesi, karmaşık görüntülerdeki analiz sürecini sistematik olarak ele almaktadır. Bu katmanlar, özelleştirilmiş olan filtreler kullanıp görsel verilerdeki kritik desenleri belirlemektedir. Her bir filtre, görüntü üzerinde açık bir yol izleyerek özel olan bu karakteristikleri tanımlamaya çalışmaktadır. Filtrelerin ana görevi ise basit kenar tespitinden karmaşık şekiller tanımaya kadar giden geniş bir analiz alanını kapsamaktadır. Bu analiz sürecinde görüntünün değişik bölgelerinde tekrarlanarak kapsamlı bir şekilde özellik haritası oluşturmaktadır. Söz konusu olan harita, görüntüdeki kritik özelliklerin konumsal olarak dağılımını göstermektedir. Konvolüsyonel katmanlardaki çıktı, giriş görüntüsünün filtrelenmiş olarak bir temsidir. Bu temsilde orijinal görüntüdeki kritik özelliklerin matematiksel olarak bir özetini sunmaktadır. Katmanların üst üste olacak şekilde yerleştirilmesi, daha karmaşık özelliklerin öğrenilmesine de olanak sunmaktadır. Evrişimsel katmanlar ise görüntü işleme sürecinde temel olan özellik çıkarma görevini üstlenmektedir. Bu özellikler arasında basit yapıdaki geometrik şekiller olması gibi, karmaşık dokular ve desenler de bulunabilmektedir. Her bir katman, önceki katmanın çıktısını işleyip kullanarak çok daha soyut özellikleri anlayıp öğrenmeye çalışmaktadır.

Bu süreç ise görsel olan verilerin hiyerarşik bir yapı olarak işlenebilmesini sağlamaktadır. Başlangıç aşamasında basit olan kenarların tespiti ile başlamış analiz,

daha da derin katmanlara doğru karmaşık desenlerin tanınmasına kadar gitmektedir. Bu doğrultuda, görüntü içeriğinin de kapsamlı olarak bir analizi gerçekleştirebilmiş olmaktadır [33].

2.1.1.1 Aktivasyon katmanları

Aktivasyon fonksiyonları, yapay sinir ağlarındaki çalışma ilkesinde ana mekanizmayı oluşturmaktadır. Bu matematiksel yapılarda nöronların çıktı bilgilerini alıp işleyerek doğrusal olmayan transformasyonunu da gerçekleştirmektedir. Sinir ağlarındaki öğrenme genliği, bu fonksiyonlardaki etkin kullanıma bağlı olmaktadır. Modern olan derin öğrenme sistemlerinde ise aktivasyon fonksiyonlarındaki seçim kritik bir önem taşımaktadır. Her bir nöron, almış olduğu girdileri bu fonksiyonlar sayesinde işler ve bir sonraki katmana iletmektedir. Bu süreç ise karmaşık olan örüntülerin tanınmasını da mümkün kılmaktadır.

Gradyan akışındaki düzenlenme, aktivasyon fonksiyonlarının kritik görevlerinden birisidir. Çıktılardaki belirli aralıkların normalize edilme olayı, eğitim sürecinin stable olmasını da artırmaktadır. Bu özellik ise derin ağların etkili ve verimli olarak öğrenebilmesini sağlamaktadır [34]. Uygun bir aktivasyon fonksiyonu, türevlenebilirlik özelliği ve süreklilik gibi matematiksel olan özelliklere sahip olması gerekmektedir. Hesaplama verimliliği göz önüne alınması gereken kritik bir faktör olmaktadır. Aktivasyon katmanlarının monotonluk olan özelliği, gradyan tabanlı optimizasyon süreçlerinin de başarısını etkilemektedir. Eğitim sürecindeki optimizasyon, ideal olan aktivasyon fonksiyonunun seçimi ile doğrudan bir şekilde ilişkilidir. Bu fonksiyonlar ise gradyan hesaplamalarının da etkili olarak yapılmasına etki etmekte ve bu ağın öğrenme performansının da damaksimize edilebilmesini sağlamaktadır [35].

Doğrultulmuş lineer birim (ReLU) aktivasyon fonksiyonu, modern derin öğrenme sistemlerindeki temel yapı taşlarından da birini oluşturmaktadır. Denklem 2.1’de gösterilen matematiksel ifade, bu fonksiyonun işleyişini anlatan bir ifadedir.

$$f(x) = \max(0, x) \quad (2.1)$$

Bu fonksiyonun çalışma ilkesi oldukça açıktır. Negatif olan girdiler sıfır değerine dönüştürülürken, pozitif değerler ise değiştirilmeden aktarılmaktadır. Agarap’ın bu

araştırması, basit yapıdaki derin ağların eğitiminde kritik farklılıklar getirdiğini göstermektedir [36].

ReLU'nun seyrek olan aktivasyon özelliği, öğrenme sürecini de kritik bir ölçüde hızlandırmaktadır. Ağın aşırı uyum problemi ile başa çıkma özelliği, bu fonksiyonu çok daha değerli kılmaktadır. Nair ve Hinton, bu fonksiyonun gradyan sönümlenmesi sorununu çözmedeki başarısını da detaylı olarak incelemiştir [37]. Ölü nöron problemi, ReLU'nun karşılaşmış olduğu temel güçlüklerden biri olarak karşılaşılmaktadır. Negatif değerlerin sıfırlanma olayı, bazı nöronların işlevsiz olarak kalmasına yol açmaktadır. Fakat modern optimizasyon yöntemleri ve özenli hiper parametre ayarlama işlevleri, bu sorunu büyük bir oranda hafifletmektedir. Hesaplama verimliliği bakımından ReLU aktivasyon fonksiyonu, rakipsiz konumda yer almaktadır. Basit olan matematiksel yapısı, karmaşık formdaki hesaplamaları minimize yaparken, ağın öğrenmedeki kapasitesini de maksimize etmektedir. Bu özellikler, fonksiyondaki derin öğrenme uygulamalarının da vazgeçilmez parçası durumuna getirmektedir.

2.1.1.2 Yığın normalizasyonu

Yığın Normalizasyonu (BN), derin öğrenme alanında yenilikçi bir yaklaşım olarak kabul edilen bir özelliktir. Ioffe ve Szegedy'nin ortaya koymuş olduğu bu yöntem, sinir ağlarındaki eğitim sürecini de kökten değiştirmektedir [38]. Her küçük batch içerisindeki verileri normalize edebilme ilkesi, iç değişken kayması problemine etkili bir şekilde çözüm sunmaktadır. Bu işlemde karmaşık yapıdaki matematiksel hesaplamalara karşılık olarak, basit istatistiksel formdaki dönüşümler kullanılmaktadır. Santurkar ve arkadaşlarının çalışmasında bu normalizasyon sürecinin bu ağın adaptasyon özelliğini artırdığını göstermiştir [39]. Tekniğin uygulanması ise derin öğrenme yöntemlerinde birçok pratik yarar sağlamaktadır. Eğitim hızındaki artış, bunların en belirginlerinden bir tanesidir. Başlangıç ağırlıklarına dayanan bağımlılığın azalmasında metotların daha da tutarlı bir performans göstermesini sağlamaktadır. Wu ve He'nin araştırmasında BN'nin düzenleyici etkisini ise detaylı bir şekilde incelemektedir. Bu etkisi modelin aşırı öğrenme durumunu küçültürken, genelleme yeteneğini de optimize etmektedir. Gradyan akışının iyileştirilme durumu, derin ağların stabilite özelliğini artırmaktadır [40]. Çıkarım aşamasındaki bu uygulamalar, eğitim aşamasında toplanan istatistiksel

verilere de dayanmaktadır. Bu yaklaşım ile modelin türlü veri boyutlarında bile birbiri ile tutarlı sonuçlar üretmesini sağlamaktadır. Hareketli ortalama değeri ve varyans değerinin kullanımı, metodun pratik uygulanabilirliğini artırmaktadır.

2.1.2 Havuzlama katmanları

Havuzlama katmanları, evrimsel sinir ağlarının kritik yapı taşlarından birisidir. Bu kritik katmanlar, veri boyutlarının kontrollü olarak azaltılmasını sağlayarak işlemin verimliliğini artırmaktadır. Uzamsal boyutların düşürülme durumu, görüntüdeki piksel matrisinin daha da kompakt bir yapıda temsil edilmesine olanak tanımaktadır. Maksimum havuzlama metodu, belirli bir pencere içerisindeki en büyük değeri seçerek çalışmaktadır. Bu yaklaşım ile kritik özelliklerin korunmasını da sağlarken gereksiz olan detayları elemektedir. Örnek olarak, iki birimlik penceredeki en önemli özelliğini koruyarak boyut azaltımı işlemini gerçekleştirmektedir.

Ortalama havuzlama ise daha farklı bir yön izlemektedir. Bu yöntem ile pencere içerisindeki bütün değerlerin ortalamasını alıp daha çok yumuşak bir temsil oluşturmaktadır. Böylelikle görüntüde bulunan genel karakteristiklerini de korurken ayrıntı seviyesini azaltmaktadır. Havuzlama işlemi ile metodun aşırı öğrenme eğilimini de kontrol altında tutabilmeye yardımcı olmaktadır. Parametrelerdeki sayıyı azaltarak, modelin eğitim verisinde aşırı bir uyum göstermesini engellemektedir. Bununla birlikte, hesaplama yükü hafifler ve model eğitimindeki hızını artırmaktadır. Model dayanıklılığı bakımından havuzlama kritik bir önem taşımaktadır. Özellikle bu maksimum havuzlama tekniği, görüntünün içerisindeki ufak kaymalar veya dönüşümlere karşı olarak modeli daha da dayanıklı ve dirençli bir hale getirmektedir. Bu özellik sayesinde nesne tanıma görevlerinde çok daha tutarlı bir performans elde edilmesini sağlamaktadır. Her iki havuzlama yaklaşımı da kendine has avantajlar sunmaktadır. Maksimum havuzlamadaki en belirgin özellikleri koruyup ortalama havuzlama daha da dengeli bir temsil oluşturmaktadır. Uygulama ihtiyaçlarına da bağlı kalarak, bu metotlardan biri tercih edilebilmektedir. Havuzlama katmanlarındaki yokluk, modelin performansını da olumsuz olarak etkileyebilmektedir. Özellikle görüntü içerisindeki nesne konumlarının değişimlerine karşı hassasiyetini artırmaktadır. Bu durum ise modeldeki genelleme yeteneğini zayıflatıp doğruluk oranlarını da düşürebilmektedir [33].

2.1.2.1 Global ortalama havuzlama

Global Ortalama Havuzlama (GAP), konvolüsyonel sinir ağlarının yapısını basitleştiren önemli bir tekniktir. Lin ve arkadaşlarının ortaya koymuş olduğu bu yaklaşım, karmaşık olan tam bağlı katmanların yerini alıp mimarileri daha da verimli ve etkili bir hale getirmektedir [41]. Tekniğin çalışma ilkesi ise oldukça nettir. Her bir öznitelik haritasında bulunan değerlerin ortalama değeri alınarak tek bir sayıya indirgenmektedir. Zhou ve ekibinin araştırması ise bu basit işlemin bu uzamsal bilgiyi daha etkili bir şekilde özetleme özelliğini de ortaya koymaktadır [42].

GAP'ın evrimsel sinir ağları mimarilerindeki kullanımı ile modellerin hafıza ayak izini kritik bir ölçüde azaltmaktadır. Parametre sayısının bu önemli düşüşü, aşırı uyum riskini minimize edip modeldeki genelleme özelliğini de optimize etmektedir. He ve arkadaşlarının ResNet mimarisi üzerindeki çalışmaları ise GAP'ın modern mimarilerdeki etkinliğini de kanıtlamaktadır. Değişik giriş boyutları ile başa çıkma özelliği de bu tekniği özellikle daha değerli kılmaktadır. Bu esneklikle pratik uygulamalarda büyük bir fayda sağlamaktadır [43]. Hesaplamadaki verimlilik bakımından GAP, geleneksel olan bu yaklaşımların önüne geçmektedir. Eğitim aşaması ve çıkarım aşamasında sağlamış olduğu performans iyileştirme durumu, bu kritik tekniği modern tasarımlarının önemli bir parçası haline getirmektedir.

2.1.3 Tam bağlantılı katmanlar

Tam bağlantılı katmanlar, konvolüsyonel sinir ağlarındaki karar verme düzeneğini oluşturmaktadır. Bu katmanlar ile bir önceki katmanların her bir nöronu ile bağlantı kurarak daha kapsamlı bir analiz gerçekleştirmektedir. Ağın son evrelerinde konumlandırılan bu yapı ise özellik çıkarımı ile sınıflandırma işlemini de yürütmektedir. Bu katmanlardaki temel işlev, bir önceki katmanlardan gelmiş karmaşık olan bu veri yapısını da düzeltmektir. Çok boyutlu tensörler ise tek boyutlu vektörlere dönüştürülüp işlenmektedir. Bu dönüşüm ile görüntüdeki bütüncül analizi sayesinde kritik bir önem taşımaktadır. Yerel özelliklerden global bir anlayışa geçiş ise bu evrede gerçekleşmektedir. Sınıflandırma sürecindeki tam bağlantılı katmanlar ise son karar mekanizması olarak görev yapmaktadır. Önceki katmanların tespit etmiş olduğu özellikleri daha anlamlı çıktılara dönüştürmektedir. Örnek olarak bir hayvan görüntüsünde kedi veya köpek olarak tanımlanabilmesi bu katmanlarda gerçekleşmektedir.

Özellik hiyerarşisi, konvolüsyonel katmanı ve havuzlama katmanının sistematik olarak dizilimi ile oluşmaktadır. Her bir katman, bir önceki katmanın üzerine inşa edilmek üzere daha karmaşık örüntüleri de tespit etmektedir. Basit olan kenarlardan başlamış analiz, karmaşık şekillerin ve desenlerin tanınmasına evrilmektedir. Bu yapı ile derin öğrenme mimarilerinin görsel veriyi anlama yeteneği ve yorumlama yeteneğinin de temelini oluşturmaktadır. Tam bağlantılı katmanlar, bir önceki katmanların çıkarımlarını daha anlamlı sonuçlara evirerek modelin son kararını da şekillendirmektedir [33].

2.1.3.1 Yoğun katmanlar

Yoğun katmanlar (DL), modern yapay sinir ağlarının temel yapı taşlarını oluşturmaktadır. Goodfellow ve arkadaşlarının araştırmasında, bu katmanlardaki öğrenme sürecinin önemli rolünü de ortaya koymaktadır [26]. Her bir nöronun birbirine bağlı olduğu yapıda, karmaşık olan bu örüntüleri yakalama özelliğine sahiptir. Zhang ve ekibinin çalışmaları, dense katmanlarında sınıflandırma görevi ve regresyon görevindeki etkinliğini doğrulamaktadır [44]. Parametre sayısında bulunan üstel artış, bu katmanların en kritik güçlüklerinden biridir. He ve arkadaşları, modern mimarilerinin katman boyutlarının optimize edilmesinin önemli olduğunu vurgulamaktadırlar. Bu optimizasyonda hesaplamadaki verimlilik ve model performansı ile açık bir denge bulunmaktadır [45]. Srivastava ve ekibinin önermiş olduğu dropout yöntemi, yoğun katmanlardaki aşırı öğrenme eğilimini de kontrol altına almaktadır. Bu yaklaşım ile modelde bulunan genelleme özelliğini kritik ölçüde artırmaktadır [46]. Bu katmanlardaki bellek kullanımı ile hesaplama maliyeti, dikkatli bir tasarım gerektirmektedir. Modern uygulamalardaki katman sayısı ve model boyutunun optimize edilmesi, modeldeki başarı için kritik bir öneme sahiptir.

2.1.3.2 Dropout katmanı

Dropout tekniği, derin öğrenmede önemli bir yere sahip olan düzenleştirme metotlarından biridir. Srivastava ve ekibinin çalışması, bu teknikteki aşırı uyum problemine getirmiş olduğu önem arz eden bir çözümü ortaya koymaktadır [46]. Eğitim sürecindeki rastgele nöronların da devre dışı kalması, beklenmedik bir şekilde modelin performansını da artırmaktadır. Hinton ve arkadaşlarının araştırması, bu yaklaşım ile topluluk öğrenmesi etkisi oluşturduğunu göstermektedir. Her bir iterasyonda farklı türde nöron kombinasyonlarındaki kullanım, modelin türlü bakış

açıları da geliştirmesini sağlamaktadır [47]. Ba ve Frey'in çalışmaları, çıkarım evresindeki ölçeklendirme yönteminin önemini de vurgulamaktadır. Bütün nöronların aktif olduğu bu evrede, çıkışların da dropout oranıyla ayarlanması sayesinde modelde tutarlı sonuçlar elde edilmesini sağlamaktadır [48]. Nöronların birbirinden farklı olarak bağımsız özellikler öğrenmesi durumu, metodun en dikkat çeken yönlerinden biridir. Gal ve Ghahramani, modern uygulamalarda da dropout kullanımının, özellikle daha karmaşık modellerde sağlamış olduğu yararları detaylı bir şekilde incelemektedir [49]. Bu teknik ile basit matematiksel temeline karşın, derin öğrenme modellerindeki eğitimde önemli derece sonuçlar üretmektedir. Uygulaması kolay olan ancak etkisi güçlü bu yöntem, modern mimarilerdeki önemli bir durum haline gelmektedir.

2.1.4 Çıkış katmanı

Çıkış katmanı, konvolüsyonel sinir ağlarının son aşamadaki karar verme merkezi olarak işlev görmektedir. Bu katman ile bir önceki işlemlerdeki sonuçları daha anlamlı çıktılara evirme görevini üstlenmektedir. Karmaşık olan özellik haritalarını da yorumlanabilir sonuçlara çevirmektedir. Sınıflandırma sorunlarında softmax aktivasyonu kullanılmaktadır. Bu fonksiyon ile çıktı sonuçlarını olasılık dağılımına dönüştürerek her bir sınıf için olasılık değeri üretmektedir. Toplam olasılık değeri her zaman bir değerine eşit olmalıdır. Bu matematiksel kısıtlama sonuçların daha tutarlı yorumlanabilmesini sağlamaktadır. Regresyon uygulamalarındaki durum ise çok daha farklıdır. Doğrusal aktivasyon veya aktivasyonsuz nöronları kullanarak sürekli değerler üretilmektedir. Bu yapı sayesinde tahmin problemlerinde de daha uygun sonuçlar vermektedir. Çıkış katmanındaki tasarım, çözülecek soruna göre şekillendirilmektedir. Özellik dönüşümü sürecinde ise kritik bir görevi bulunmaktadır. Önceki katmanların çıkarmış olduğu soyut özellikleri daha anlamlı bilgiye dönüştürmektedir. Bu dönüşüm ile modelin pratik olan uygulamalarda kullanılabilir sonuçları üretmesini sağlamaktadır.

Çıkış katmanındaki yapılandırılma, modeldeki başarıyı doğrudan etkilemektedir. Uygun aktivasyon fonksiyonunun seçimi ve nöron sayısının belirlenmesi durumu, performansı optimize etmekte kritik bir öneme sahiptir. Bu seçimler ile birlikte sorunun ana noktasına ve beklenilmiş olan çıktı formatına göre yapılmalıdır [33].

2.1.4.1 Softmax

Softmax aktivasyonlu çıkış katmanı, çok sınıflı olan sınıflandırma problemlerinin çözümünde büyük bir öneme sahiptir. Bridle'in çalışması, bu teknikteki temelleri atmış ve modern derin öğrenmenin önemli bir parçası haline gelmiştir [50]. Bishop'un matematiksel analizleri ile Softmax'ın cross-entropy kayıp fonksiyonu ile birlikte mükemmel uyumunu ortaya koymaktadır. Bu kombinasyon ile gradyan tabanlı optimizasyon için optimum bir zemin oluşturmakta ve maksimum derecede olabilirlik kestiriminin temel bir uzantısı kabul edilmektedir [51]. Liu ve ekibinin araştırmaları, Softmax çıktılarındaki yorumlanabilirliğe dikkat çekmektedir. Bu özellik sayesinde modelin güvenilirliğinin değerlendirilmesi de kritik bir öneme sahip olmuştur. Üretilen bu olasılık değerleri ile belirsizlik tahminlerinde güvenilir sonuçlar sağlamaktadır [52]. Goodfellow ve arkadaşlarının matematiksel çalışmaları, Softmax katmanının sınıflandırmadaki başarısı rolünü kanıtlar nitelikte olduğunu göstermektedir. Gradyan akışının düzenlenmesinde olan bu etkinliği, modern derin öğrenme uygulamalarının da performansını kritik bir değerde artırmaktadır [26]. Her bir sınıf için üretilen bu olasılık değerleri ile modelin değerlendirilmesi bakımından zengin bilgiler sunmaktadır. Bu özellik sayesinde hata analizinin derinlemesine yapılmasına da imkan tanır ve modelin iyileşme sürecine değerli katkılar sağlamaktadır.

$$f(x)_i = e^{x_i} / \sum_j e^{x_j} \quad (2.2)$$

Fonksiyonun matematiksel olarak ifadesi Denklem 2.2'de ifade edilmiştir. Burada, $f(x)_i$ i. sınıftaki tahmin olasılığını temsil ederken, x_i ise ham skoru ifade etmektedir. Euler sayısı e (≈ 2.71828), üstel işlemlerdeki temeli oluşturmaktadır. Paydada bulunan $\sum_j e^{x_j}$ ifadesi ise önemli bir normalleştirme görevi görmektedir. Bütün üstel değerlerin toplam değeri çıktılarıdaki toplam olasılığın her zaman bir değerine eşit olmasını sağlamaktadır. Bu özellik sayesinde olasılık teorisinin temel ilkeleri ile mükemmel bir uyum göstermektedir. Dönüşüm ile elde edilen $[0,1]$ aralığındaki bu değerler, modeldeki tahminlerin daha yorumlanabilir bir hale getirmektedir. En büyük giriş değerindeki sınıfın en yüksek olasılığı alması durumu, sınıflandırmadaki kararların net ve anlaşılır bir şekilde olmasını sağlar. Bu matematiksel yapı ise çok sınıflı sınıflandırma problemlerinin de çözümünde büyük avantajlar sunmaktadır. Normalize

edilmiş olan çıktılar ise modeldeki performansın değerlendirilmesini ve sonuçların da yorumlanmasını kolaylaştırmaktadır.

2.1.4.2 Çoklu sınıflandırma

Çoklu sınıflandırma (Multiclass classification), modern makine öğrenmenin temel yapı taşlarından birisidir. Bishop ve arkadaşlarının detay barındıran bu analizi sayesinde bu yöntemin teorik temellerini de çok daha sağlam bir şekilde ortaya koymaktadır [51]. Deng ve arkadaşlarının ImageNet ile çalışmaları, büyük ölçekli veri setlerinde de çok sınıflı sınıflandırma tekniğinin pratik önemini vurgulamaktadır. Softmax aktivasyonu ile modeldeki çıktıları yorumlanabilir olasılıklara evirerek, tahmindeki süreci anlamlı kılmaktadır [53]. Aly'nin önermiş olduğu performans değerlendirmesindeki yaklaşım, çok sınıflı problemlerdeki karmaşıklığı ele almaktadır. Makro ortalama ve mikro ortalama sayesinde farklı sınıflardaki başarı dengeli olarak değerlendirmeye de imkan tanımaktadır [54]. Zhou ve ekibinin yapmış olduğu araştırma, sınıf dengesizliği problemine ise yenilikçi çözümler sunmaktadır. Ağırlıklı kayıp fonksiyonları ile veri artırma metotları, modeldeki performansı kritik bir ölçüde iyileştirmektedir [55]. Modern uygulamaların hiyerarşik yapılarındaki kullanımı, karmaşık sınıflandırma problemlerinin de çözümüne yeni ufuklar açmaktadır. Özel mimarideki tasarımlar, modelin performansını optimize edip hesaplamaadaki verimliliğini de göz önünde bulundurmaktadır.

2.2 Modern Evrimsel Sinir Ağı Mimarileri

2.2.1 ResNet50

ResNet50 mimarisi, Microsoft Research tarafından 2015 yılında tanıtılmış olan derin öğrenme mimarisini temsil etmektedir. Bu mimari elli katmanlı bir yapıya sahip olmakla birlikte onu türlü görevlerde de güçlü kılmaktadır. Görüntü sınıflandırmada ve nesne algılamada bu mimarideki olağanüstü yetenekler sayesinde sergilemiş olduğu bu yetenekler başlıca uygulamalar içerisinde yer bulmaktadır.


Mimarinin bir diğer ayırt edici özelliği ise artık bağlantıların da uygulanmasında yatmaktadır. Bu bağlantılar ile birlikte ağı daha da derin katmanlar ile bilgi akışını devam ettirmesine yardım edip aynı zamanda bu durum kritik bir zorluk olmaktadır. Belirli katmanları atlamış bağlantılar ile ağ geleneksel mimarilerle kıyaslandığında önemli derecede performans iyileştirmesi elde etmektedir.

Mimarinin büyük önemi ile çok daha karmaşık görsel görevleri verimli ve etkili bir şekilde işleme özelliğinden kaynaklanmaktadır. Dünya genelindeki bilim insanları, tıbbi görüntülemeye başlayıp otonom araç sistemlerine kadar türlü uygulamalar için ResNet50 mimarisini benimsemişlerdir.

2.2.2 EfficientNet

EfficientNet mimarisi, ağ derinliği bakımından, çözünürlüğü ve genişliği içinde optimal derecede bir denge kurmuş olan bileşik ölçeklendirme yöntemini baz alan bir derin öğrenme mimarisidir. Hesaplama daha az kaynak kullanarak çok daha yüksek bir doğruluk elde etmeyi başarmış bir mimaridir.

Nöral Mimari Arama (NAS) yöntemi kullanılarak geliştirilmiş bu mimari, MobileNetV2'nin Mobil Ters Darboğaz Konvolüsyonu (MBConv) yapısını temel alıp, hesaplama kaynaklarının optimizasyonunda yenilikçi bir çığır açmaktadır. EfficientNet mimarisinin en temel hedefi, parametre sayılarını ve flop sayılarını minimize etmiş olurken modelin performansını da maksimize etmektir. Bu bağlam özelinde kullanılan ‘Bileşik Ölçeklendirme’ yaklaşımı, ağırlık genişlik parametresi, derinlik parametresi ve çözünürlük parametresini de sistematik olarak dengeleyip optimize etmektedir. Literatürde yapılan çalışmalar göstermektedir ki EfficientNet mimarisinin temel modelin kalitesine bağlı olarak üstün bir performans sergilediğini göstermektedir. Özellikle dikkat çeken bir diğer nokta, bu ölçeklendirme yönteminin diğer mimari yapılara uyarlanabilir olmasıdır [56].



Şekil 2.2 : EfficientNet mimarisi [56].

2.2.3 Xception

Google'ın 2017 yılında literatüre kazandırmış olduğu Xception (Extreme Inception) mimarisi, CNN alanında kritik bir dönüm noktası olarak teşkil etmektedir. Bu mimari yapı sayesinde geleneksel Inception modüllerinden daha farklı bir şekilde modifiye edilmiş derinlemesine olarak ayrışabilir konvolüsyon katmanlarını ana nokta almaktadır. Mimarinin özgün yenilikçi yaklaşımı, öznitelik haritalarının uzamsal boyutları ve derinliksel boyutlarda ayrıştırılması ilkesine dayanır ve artık bağlantılar yoluyla öznitelik haritalarının daha da güçlendirilmesini hedeflemektedir. Dikkat çekici bir nokta olarak klasik ayrılabilir evrişim ağlarındaki işlemdeki sıralamasına karşın, Xception mimarisinde önce noktasal evrişim ve ardından derinlemesine olarak bir evrişim uygulanması tercih edilmektedir. Bu yaklaşım ile birlikte geleneksel metotlara göre daha etkili ve verimli bir öznitelik çıkarımı da sağlamaktadır [57].

2.2.4 MobileNetV2

MobileNetV2 mimarisi, mobil cihazlar ile gömülü sistemler adına özel olarak tasarlanmış sıkı bir CNN mimarisidir. Google'daki araştırma ekibi, ilk MobileNet mimarisini geliştirerek bu yapıyı ortaya koymuştur. Modelin en dikkat çeken özelliklerinden biri ise sınırlı bir kaynağa sahip cihazlarda uygun bir performans gösterebilmek sebebiyle modelin boyutu ile doğruluk oranı arasında kurduğu dengedir.

Bu mimarideki görüntü sınıflandırması alanında kullanımı ise türlü avantajlar sağlamaktadır. İl olarak, hafif yapısı ile sınırlı hesaplama gücündeki mobil sistemler ve gömülü sistemlerde etkin bir biçimde çalışabilmektedir. Bununla birlikte, daha çok karmaşık ve yüksek işlem gücü ihtiyacı gerektiren modellere daha yakın doğruluk oranları da elde edebilmektedir. Modelin boyutunun ufak olması nedeni ile gerçek zamanlı uygulamalardaki hızlı çıkarım özelliğinin yapılmasına imkan da tanımaktadır.

MobileNetV2 mimarisinin yapısı, türlü özelleştirilmiş katmanların bir arada olmasıyla gerçekleşmektedir. Bu yapı içerisinde ise evrişimsel katmanlar, ters artık bağlantılar, derinlemesine ayrılabilir evrişimler, darboğaz tasarımları ve sıkıştırma-uyarma (SE) blokları bulunmaktadır. Tüm bu bileşenler ile birlikte modeldeki karmaşık özellikleri algılamadaki yeteneğini korumuş olurken, ihtiyaç duyduğu parametre sayısını ve hesaplamadaki yükünü minimize etmek için tasarlanmıştır [58].

2.2.5 InceptionResNetV2

InceptionResNetV2 mimarisi, derin öğrenme teknolojisinde kritik bir gelişme olarak ifade edilmektedir. Bu yenilikçi özgün mimari, 2016 yılında Google Research'ün bünyesinde Christian Szegedy ve araştırmadaki ekibin yoğun ve verimli çalışmaları ile ortaya konulmuştur. InceptionResNetV2 mimarisinin en dikkat çeken yönü, Inception mimarisi ve ResNet mimarisi gibi iki güçlü yapının da avantajlarını tek bir noktada başarı ile birleştirmesidir.

InceptionResNetV2 mimarisinin en temel yapı taşları, Inception modüllerindeki zengin özniteliği çıkarma kapasitesi ve ResNet mimarisinin artık öğrenme mekanizmasından kaynaklanmaktadır. Bu hibrit yöntem ile derin sinir ağlarındaki eğitim evresinde sıkça karşılaşılmış olan gradyan kaybı problemi ve aşırı öğrenme gibi önemli problemlere etkili çözümler de sunmaktadır. Mimarinin kendine has tasarımı, geleneksel CNN yapıları ile kıyas edildiğinde daha derin ve daha karmaşık ağların eğitilmesine de imkan tanımaktadır.

Modeldeki bir diğer ayırt edici özellik ise Inception modüllerinin optimize edilen versiyonlarının kullanılmasıdır. Bu modüller ile farklı ölçeklere sahip görsel özellikleri eşzamanlı bir şekilde yakalayabilme özelliğine sahiptir. ResNet mimarisinden gelen artık bağlantılar sayesinde bilgidaki akışın ağ ile kesintisiz olarak sürdürülmesini sağlayarak, derin yapılarda da sıkça görülmüş degradasyon sorununu minimize etmektedir [59].

2.2.6 DenseNet121


DenseNet121 mimarisi, evrişimli sinir ağlarında önemli bir mimari yapı olarak 2017 yılında literatüre kazandırılmış bir mimaridir. Huang ve arkadaşları tarafından geliştirilen bu DenseNet121 mimarisi, yoğun bağlantı ilkesini baz alan özgün bir yenilikçi yaklaşım olarak sunmaktadır. Söz konusu bu yapı, toplam olarak 121 katmandan oluşan karmaşık bir organizasyona sahiptir.

Mimarideki en ayırt edici özellik ise katmanlar arasında bağlantı yapısının gelenekseldeki yaklaşımlardan farklı bir biçimde tasarlanmış olmasıdır. Her bir katman, kendisinden sonra gelen bütün katmanlara direkt bağlantılar ile bağlanmaktadır. Bu yoğun bağlantı yöntemi, özniteliğin tekrar kullanımını maksimize edip, gradyandaki akışın optimizasyonunu da sağlamaktadır. Bu yapı, 7x7

boyutlarında bir konvolüsyon katmanını ile başlar ve dört adet yoğun blok ile devam etmektedir. Aralarında geçiş katmanları da bulunmaktadır.

Yoğun blokların iç yapısı bir hayli sofistike bir organizasyona sahiptir. Her bir blok, BN, ReLU aktivasyonu ve farklı boyutlardaki konvolüsyon katmanlarını barındırmaktadır. Bloklardaki katman sayıları sırasıyla 6, 12, 24 ve 16 olarak düzenlenmektedir. Teknik açıdan dikkat çeken bir diğer nokta ise L katmanlı bir blokta bulunan toplam bağlantı sayısının $L(L+1)/2$ formülü ile hesaplanmasıdır.

DenseNet121 mimarisinin etkin başarısı, üç ana avantaja dayanmaktadır. Birincisi, parametre verimliliği sayesinde daha az kaynak kullanımı ile birlikte etkili bir öğrenme gerçekleştirebilmesidir. İkincisi, güçlü bir öznitelik propagasyonu ile gradyan kaybı sorununu minimize etmesidir. Üçüncüsü ise, optimize edilen eğitim performansı ile düzenli öğrenme eğrileri sunmasıdır. Bu özellikler ile mimarinin görüntü işleme uygulamalarında da tercih edilmesinin başlıca nedenlerindendir [60].



Şekil 2.3 : DenseNet mimarisi [60].

2.2.7 CNN mimarilerinin karşılaştırılmalı analizi

Önceki bölümlerde detaylı olarak incelenen altı farklı CNN mimarisinin (ResNet50, EfficientNet, Xception, MobileNetV2, InceptionResNetV2 ve DenseNet121) karşılaştırmalı bir analizi sunulmaktadır. Bu karşılaştırma, mimarilerin güçlü ve zayıf yönleri ile uygulama alanlarına odaklanarak, Çizelge 2.1’de ayrıntılı olarak ele alınmaktadır.

Çizelge 2.1 : CNN mimarilerinin karşılaştırma tablosu.

Mimari	Güçlü Yönleri	Zayıf Yönleri	Uygulama Alanları
ResNet50	Gradyan kaybı sorunu çözümü, derin ağlar için etkin eğitim	Yüksek bellek kullanımı	Genel görüntü sınıflandırma
EfficientNet	Parametre verimliliği, ölçeklenebilirlik	Transfer öğrenmede uyarlama zorluğu	Mobil ve sınırlı kaynaklı ortamlar
Xception	Uzamsal ve kanal bilgilerinin etkili ayrıştırılması	Eğitim süresi uzunluğu	Detaylı özellik çıkarımı gerektiren görevler
MobileNetV2	Düşük parametre sayısı, yüksek verimlilik	Karmaşık görüntülerde düşük performans	Mobil cihazlar, gerçek zamanlı uygulamalar
InceptionResNetV2	Çoklu ölçek özellik çıkarma, yüksek doğruluk	Yüksek hesaplama maliyeti, karmaşık yapı	Yüksek doğruluk gerektiren uygulamalar
DenseNet121	Özellik yeniden kullanımı, gradyan akışı	Bellek tüketimi yüksekliği	Transfer öğrenme, daha küçük veri setleri

İncelenen CNN mimarileri, verimlilik ve performans açısından farklılıklar göstermektedir. MobileNetV2 ve EfficientNet, düşük kaynak gereksinimleri ile mobil ve sınırlı ortamlar için ideal seçenekler sunarken; InceptionResNetV2 ve Xception mimarileri yüksek doğruluk gerektiren karmaşık görevlerde üstün performans göstermektedir. ResNet50, gradyan kaybı sorununu çözüm üreterek derin ağların etkili eğitimini sağlarken; DenseNet121 mimarisinin özellik yeniden kullanım stratejisi özellikle transfer öğrenmede avantaj sağlamaktadır.

Her mimarinin belirli uygulama alanlarında öne çıktığı görülmektedir. MobileNetV2 mimarisi gerçek zamanlı uygulamalarda, EfficientNet mimarisi kaynak sınırlı ortamlarda, Xception mimarisi detaylı özellik çıkarımında, ResNet50 mimarisi genel sınıflandırma görevlerinde, InceptionResNetV2 mimarisi yüksek doğruluk gerektiren

uygulamalarda ve DenseNet121 mimarisi ise küçük veri setleriyle çalışırken tercih edilmektedir.

2.3 Değerlendirme Ölçütleri

2.3.1 Model performans metrikleri

2.3.1.1 Genel doğruluk

Genel doğruluk (Accuracy), Zheng ve Yang'ın 2021 yılındaki çalışmalarında açıkladığı üzere, genel doğruluk olarak nitelendirilen accuracy metriği, makine öğrenmesi modelleri ve derin öğrenme modellerinin ne kadar başarılı olduğunu vurgulamak adına kullanılan en temel ölçümlerden biridir. Bu metrik ile bir modelin sınıflandırmadaki görevlerinin performansını değerlendirmede yaygın bir şekilde tercih edilir ve modeldeki genel başarısını temsil eden kritik bir gösterge olarak kabul edilmektedir [61].

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (2.3)$$

Accuracy metriği, modeldeki farklı sınıflar özelinde göstermiş olduğu tahmin edebilme yeteneğini ölçen kapsamlı değerlendirme aracıdır. Bu ölçüm ile birlikte basit bir matematiksel ilkeye dayanmaktadır. Doğru tahminlerin oranının toplam tahminlere oranıdır. Metriğin matematiksel ifadesi Denklem'2.3'te belirtildiği şeklindedir. Formülde yer alan her bir bileşen özel bir anlam taşımaktadır. *TP* doğru pozitifleri, *TN* doğru negatifleri, *FP* yanlış pozitifleri ve *FN* ise yanlış negatifleri temsil etmektedir. Çok sınıflı problemlerde ise formül daha geniş bir bakış açısı kazanmaktadır. Bu noktada, başarılı sınıflandırmaların oranı bütün örnekler oranı esas alınmaktadır. Bu yaklaşım sayesinde karmaşık sınıflandırma problemlerinde çok daha anlamlı sonuçlar sunmaktadır.

2.3.1.2 Makro F1 skoru

Sokolova ve Lapalme'nin 2009 yılındaki araştırmalarında detaylı bir şekilde ele almış olduğu makro f1 skor, çok sınıflı problemlerde işlenen sofistike bir değerlendirme metriği olarak anlatılmaktadır. Bu kritik ölçüm aracıyla sınıflandırma modellerindeki performansı değerlendirilirken her bir sınıfa eşit bir önem kazandırır. İlginç olarak, metrik her bir sınıf adına bireysel f1 skorlarını hesaplamaktadır. Hesaplamadaki

yöntem ise oldukça basit bir yapıda görünse de arkasında çok daha karmaşık bir mantık yatmaktadır. Her bir sınıfın f1 skorları hesaplanır ve bu skorlardaki aritmetik ortalama alınmaktadır. Bu yaklaşım sayesinde modeldeki tüm sınıflar üzerindeki genel performansını anlayabilmek için güvenilir bir çerçeve sunmaktadır [62].

Denklem 2.4'te belirtildiği gibi makro f1 skor, model değerlendirmesinde de kullanılan özel bir metrik sistemidir. Bu ölçüm aracı ile iki temel bileşenin (precision ve recall) harmonik ortalama değerini alarak çalışmaktadır.

$$\text{Makro F1 - score} = (1/n) \Sigma (2 \times \text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall}) \quad (2.4)$$

n değişkeni, bir sınıflandırma modelindeki toplam sınıf sayısını göstermektedir. Bu matematiksel gösterimde modelin kaç değişik kategoride tahmin işlemi yapması gerektiğini ifade etmektedir.

$$\text{Precision} = TP / (TP + FP) \quad (2.5)$$

Makine öğrenmesi modellerindeki performans değerlendirmesinde kullanılan bu üç ana formül, birbirleri ile yakından ilişkilidir. Denklem 2.5 modelin pozitif olarak tahmin ettiği örnekler içerisinde gerçekten pozitif olanların oranını göstermektedir. Bu formülde, doğru pozitif tahminlerin oranının tüm pozitif tahmin oranlarına bölünmesi söz konusudur.

$$\text{Recall} = TP / (TP + FN) \quad (2.6)$$

Denklem 2.6 ise farklı bir bakış açısı sunmaktadır. Bu ölçüm ile gerçekte pozitif olan örneklerden kaç tanesinin bu model tarafından doğru bir şekilde tespit edildiğini göstermektedir. Bu formül doğru pozitif tahminlerin oranının gerçekte pozitif olan tüm örneklere oranını hesaplar.

$$F1 = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall}) \quad (2.7)$$

Denklem 2.7, precision değerini ve recall değerini tek bir metrikte birleştirir. Bu formül basit bir aritmetik ortalama almak yerine harmonik bir ortalama kullanmaktadır. Bu tercih ile uç noktadaki değerlere karşı daha da duyarlı bir ölçüm

sağlamaktadır. F1 skoru, özellikle dengesiz olan veri setlerinde modelin gerçek performansını değerlendirmek üzere kullanışlı bir araç olarak karşımıza çıkmaktadır.

Makro f1 skurun güvenilirlik değerlendirmesinde kritik bir yere sahip olduğu görülmektedir. Bu ölçüm yöntemi, özellikle de dengesiz veri kümelerinde, daha doğru sonuçlar ortaya koymaktadır. Bu sebep ile her bir sınıfa eşdeğer önem kazandırır. İstatistiksel analizlerde kullanılan genel doğruluk metriği bazen yanıltıcı sonuçlar da verebilmektedir. Makro f1 skor, bu sorunu çözerek daha da kapsamlı bir değerlendirme sunmaktadır. Veri setinde yer alan azınlık sınıflarındaki performansı da hesaba katmaktadır. Modelin performans değerlendirmesinde önemli bir role sahip olan bu metrik, özellikle de dengesiz veri setlerinde güvenilir sonuçlar sağlamaktadır. Her bir sınıfın eşit bir önemde değerlendirilmesi ise modelin gerçek başarısının daha doğru bir şekilde ölçülmesine de imkan tanımaktadır. Bu metodolojik yaklaşım, sayesinde azınlık sınıflarındaki performansı da dikkate alarak, modeldeki gerçek dünya uygulamalarındaki başarısını çok daha nesnel bir şekilde yansıtmaktadır.

2.3.1.3 Ağırlıklı ortalama

Ağırlıklı ortalama (WA), derin öğrenme ve makine öğreniminin karmaşık dünyasında kritik bir değerlendirme aracı olarak öne çıkmaktadır. Bu metrik ile çok sınıflı sınıflandırma problemlerinde, her bir sınıfın kendine özgü olan örnek adetini göz önünde bulundurarak hesaplama yapmaktadır. Powers ve Ailab'ın 2020 yılında yayınlamış olduğu araştırmaya göre, özellikle veri setlerindeki dengesizlik durumunun oluşturduğu zorlukları aşmada etkili bir çözüm sunmaktadır. Bu yaklaşım ile birlikte tıpkı bir terazinin farklı ağırlıkları hassasiyet ile ölçmesi gibi, her bir sınıfın katkısını dengeli olarak değerlendirerek daha gerçekçi ve daha güvenilir sonuçlar elde edilebilmesini sağlamaktadır [63].

$$WA = \sum(wi \times mi) / \sum wi \quad (2.8)$$

WA, veri bilimindeki hassas dengeleri gözetken özel bir hesaplama yaklaşımı sunmaktadır. Her bir sınıfın sahip olduğu örnek adeti, değerlendirmede belirleyici bir rol oynar ve böylelikle daha da kapsamlı örneklerle sahip bu sınıflar, sonuçları daha fazla etkilemektedir. Hesaplamadaki süreç, matematiksel bir gösterim gibi ilerlemektedir. Her bir sınıfın performans göstergesi (precision, recall veya F1 skoru gibi), o sınıfın örnek sayısı ile çarpılır ve daha sonra toplam örnek adetine bölünerek

ağırlıklı ortalama elde edilmektedir. Bu süreç, Denklem 2.8'deki formül ile ifade edilmektedir. Burada w_i örnek sayılarını temsil etmekte, m_i ise sınıfların her bir değerin ölçülen değerlerini ifade etmektedir. Özellikle bu dengesiz veri setlerindeki değerlendirmeler, bu yaklaşımın makro ortalamadan çok daha anlamlı sonuçlar üretmesini sağlar. Çünkü veri setinin doğal dağılımı dikkate alınır ve kalabalık sınıfların performansına da daha fazla ağırlık verir. Tıpkı bir parlamentonun nüfus yoğunluğuna göre temsil edilebilme mantığı gibi, her bir sınıf kendi büyüklüğü oranında bu değerlendirmeye katılır. Bu metodoloji ile gerçek dünya verilerinin karmaşık yapısını çok daha iyi yansıtmaktadır.

2.3.1.4 Sınıf bazlı F1 skoru

Sınıf bazlı f1 skor yaklaşımı, derin öğrenme ve makine öğrenmesi alanının en kritik değerlendirme araçlarından biri olarak karşımıza çıkmaktadır. Goutte ve Gaussier'in 2005 yılında ortaya koymuş olduğu bu metrik ile çok sınıflı sınıflandırma problemlerinde de her bir sınıfın performansını derinlemesine bir şekilde analiz etmeye imkan tanımaktadır. Bu metodoloji, precision değerini ve recall değerini harmonik bir ortalama kullanarak birleştirir ve böylece her bir sınıfın başarısını daha kapsamlı olacak şekilde ölçer. Bu durum modelin gerçek performansını çok daha açık bir biçimde ortaya koymaktadır [64].

Sınıf bazlı f1 skor metriği, veri biliminin bu karmaşık dünyasında çok özel bir yere sahiptir. Bu değerlendirme aracı sayesinde özellikle dengesiz veri setlerindeki analiz sürecinde kritik bir önem taşır ve her bir sınıfın kendine has olan performansını ayrı ayrı değerlendirmektedir. Hesaplama yöntemi ise precision metriği ve recall metriğinin harmonik ortalamasına dayanmaktadır ve bu yaklaşım, her bir sınıf adına bağımsız olarak uygulanmaktadır. Bu özelliği sebebiyle çok sınıflı sınıflandırma problemlerinde de çok daha detaylı ve anlamlı sonuçlar elde edilmesini sağlamaktadır. Denklem 2.7'de bulunan formül ile her bir sınıf için ayrı ayrı hesaplanmaktadır.

2.3.2 Eğitim karakteristik metrikleri

2.3.2.1 Eğitim doğruluğu

Eğitim doğruluğu, derin öğrenme ve makine öğreniminin temel yapı taşlarından biri olarak kabul edilmektedir ve bu modellerin öğrenme yeteneğini ölçmede kullanılan önemli bir değerlendirme aracıdır. Bu metrik ise bir modelin eğitim sürecinde

kullanmış olduğu verileri ne kadar iyi özümsemediğini gösteren önemli bir gösterge olarak kabul edilmektedir. Denklem 2.9’da formülü belirtilmiştir.

$$\text{Eğitim Doğruluğu} = (\text{Doğru tahmin edilen örnek sayısı}) / (\text{Toplam eğitim örneği sayısı}) \quad (2.9)$$

Fakat, yüksek eğitim doğruluğu her durumda başarı göstergesi sayılmaz. Örneğin, öğrencinin ders notlarını ezberleyip, farklı sorular ile karşılaştığındaki zorlanması gibi, model de eğitim verilerini ezberlemiş olabilmektedir. Eğitim doğruluğunun çok yüksek olmasına karşın test doğruluğunun düşük kalması durumu, modelin aşırı öğrenme (overfitting) sorunu ile karşı karşıya olduğunu gösterebilmektedir. Bu sebep ile uzmanlar eğitim doğruluğunu tek başına olacak şekilde değerlendirmek yerine, test doğruluğu ile birlikte analiz edebilmektedirler. Bu yaklaşım sayesinde modelin gerçek dünya problemlerinde bulunan performansını çok daha doğru şekilde öngörmemizi sağlamaktadır.

2.3.2.2 Validasyon doğruluğu

Validasyon doğruluk metriği, derin öğrenme ve makine öğrenmesi modellerinin değerlendirilmesinde kritik bir öneme sahip bir ölçüm sistemidir. Bu metrik sayesinde modelin gerçek dünyadaki performansını tahmin etme işleminde kullanılan öncü göstergelerden birisidir. Denklem 2.10 validasyon doğruluğu formülünü ifade etmektedir.

$$\text{Validasyon Doğruluğu} = (\text{Doğru tahmin edilen validasyon örneği sayısı}) / (\text{Toplam validasyon örneği sayısı}) \quad (2.10)$$

Bu metrik, modelin eğitim sürecinde hiç görmediği veriler üzerinde test edilmektedir. Örnek olarak bir öğretmen, öğrencisine ders kitabındaki farklı soruları sorması gibi, model de yeni örneklerle karşılaştırılmaktadır. Bu sayede, modelde bulunan gerçek öğrenme seviyesi değerlendirilmektedir.

Validasyon doğruluğunun en önemli görevlerinden biri, modelin aşırı öğrenme veya yetersiz öğrenme durumlarını belirlemektir. Eğitim doğruluğu ile validasyon doğruluğu arasındaki fark, modelde bulunan genelleme yeteneği hakkında ipuçları

sunmaktadır. Bu bilgi sayesinde model seçimi ile hiper parametre ayarlaması gibi önem arz eden kararlarda yol gösterici bir rol oynamaktadır.

2.3.2.3 Eğitim süresi

Eğitim süresi, derin öğrenme ve makine öğrenmesi dünyasında modellerin pratik uygulanabilirliğini tespit eden temel göstergilerden birisidir. Bu metrik ile bir modelin eğitimini tamamlayabilmesi adına gerekmiş olan zaman dilimini ölçer ve türlü birimler ile (saniye, dakika, saat) ifade edilebilmektedir.

Birçok faktör eğitim süresini etkilemektedir. Modelin karmaşıklığı, veri setindeki büyüklük ve kullanılan donanım kaynakları Merkezi İşlem Birimi (CPU), GPU ve Rastgele Erişimli Bellek (RAM) gibi bu süreyi doğrudan şekillendirmektedir. Bununla birlikte, seçilmiş olan optimizasyon algoritması ile hiper parametreler de (batch size, epoch sayısı) süreyi önemli bir ölçüde değiştirebilmektedir. Durma kriterleri, özellikle erken durdurma (early stopping) gibi yöntemler, eğitim süresini optimize etmekte kullanılmaktadır. Bu optimizasyon sayesinde özellikle büyük ölçekli olan projelerde ve sınırlı kaynak senaryolarında kritik bir önem taşımaktadır. Örneğin, bir maratoncu gibi, model de hedefine en verimli bir şekilde ulaşmalıdır.

Eğitim süresinin bu etkin yönetimi, projenin başarısı için hayati bir öneme sahiptir. Bu sürenin optimize edilmesi durumu, kaynakların verimli kullanımı ve projenin ise zamanında tamamlanması bakımından vazgeçilmez olarak nitelendirilmektedir.

3. METOT VE ANALİZ

Bu bölüm araştırmada yer alan teknik boyutları ve uygulamadaki süreçler detaylı olarak ele alınmaktadır. Bu çalışma kapsamında, 3D nesnelerin birçok farklı açıdan görüntüleri incelenmiştir ve bu görüntüler birbirinden farklı altı türde derin öğrenme mimarisi ile test edilmiştir. Süreçteki aşamalar veri toplanmasından başlayıp sonuçların değerlendirilmesi sürecine kadar ilerleyen bir yol izlemektedir.

Bu metodolojik yöntem sayesinde bilimsel yaklaşımlar göz önüne alınarak planlanarak, her bir adım dikkatli bir şekilde dokümanite edilmiştir. Veri setinin hazırlanma evresinde özel bir yöntem geliştirilmiştir. Modellerdeki eğitim aşamasında standart metotlar kullanılmıştır. Performanstaki değerlendirmeler ise objektif kriterler ile gerçekleştirilmiştir.

Çalışmadaki teknik altyapı, modern CNN mimarilerine dayanmaktadır. Her bir model adına gerekli ayarlamalar yapılmıştır ve bununla birlikte parametre optimizasyonuna dikkat edilmiştir. Veri seti hazırlanırken türlü model tipleri değerlendirilmiştir ve bu aşamada görüntünün kalitesi sürekli olarak kontrol edilmiştir. Bu dikkatli yaklaşım ile birlikte güvenilir ve etkili sonuçlar elde edilmesi sağlanmıştır.

Araştırma sürecindeki her bir evre, diğer araştırmacıların tekrar edebilmesi adına ayrıntılı olarak kaydedilmiştir. Kullanılan teknik ayrıntılar ve değerlendirmedeki kriterler net olarak kayıt altına alınmıştır.

3.1 Veri Seti Ve Karakteristikleri

Bu araştırmada kullanılan metodolojik yaklaşımlar detaylı olarak incelenerek, karmaşık olan teknik süreçler basit bir dil ile ele alınmaktadır. Çalışmadaki ana odak, üç boyutlu STL dosyalarından elde edilmiş iki boyutlu görüntülerin birçok farklı açıdan sınıflandırılmak üzere kullanılan altı farklı türde derin öğrenme mimarisi bulunmaktadır. Araştırmadaki süreç, veri setinin hazırlık aşamasından başlayıp modellerin eğitilmesi sürecine kadar devam eden bir yol izlemektedir.

Bilimsel araştırma ilkeleri ile şekillenen bu metodolojik yapıda sistematik bir yaklaşım benimsenmiştir. Her bir model için kullanılan eğitim kuralları standart yöntemler ile gerçekleştirilmiştir. Değerlendirmedeki süreçte, objektif kriterler göz önüne alınmıştır.

Güncel olan derin öğrenme yöntemleri kullanılarak oluşturulmuş olan bu teknik altyapı ayrıntılı parametre optimizasyonlarını barındırmaktadır. Veri setinin hazırlanmasındaki süreçte, türlü model çeşitlerinin birbiri ile uyumluluğu ve görsel kalitedeki standartlar dikkate alınmış olup, bu unsurlar sayesinde ilgili yaklaşımda güvenilir sonuçların da elde edilmesi sağlanmaktadır.

Bu metodolojik çerçevede araştırmadaki tekrar edilebilirliği sağlamak adına kapsamlı bir dokümantasyon sunulmaktadır. Kullanılmış teknik ayrıntılar ve değerlendirme ölçütleri net olarak belgelendirilmiş olup bu sayede araştırmadaki şeffaflık sağlanmaktadır.

3.1.1 Veri toplama süreci

Thingiverse platformu, farklı kullanıcılar tarafından oluşturulmuş dijital tasarım dosyalarının paylaşımı için yapılmış içerisinde özellikle üç boyutlu dosyalar barındıran bir web sitesidir. Açık kaynaklı yapıya sahip donanım tasarımlarının da paylaşıldığı ve lisanslamış olduğu yenilikçi bir dijital platform olarak sunulmaktadır. Paylaşımında bulunan kullanıcılar, üç boyutlu yazıcılar ve lazer kesiciler gibi modern üretim teknolojileri sayesinde bu üç boyutlu tasarım dosyaları fiziksel ürünlere de dönüştürebilmektedir. Bir milyondan fazla olan bu tasarımlara ev sahipliği yapmış olan platform, onarım amaçlı, dekorasyon amaçlı ve organizasyon amaçlı ürünlere odaklanıp, alternatifler sunmaktadır.

Thingiverse (<https://www.thingiverse.com/>) platformu içerisinden elde edilmiş STL uzantıdaki 3D modeller, bu araştırmadaki temel veri kaynağını oluşturmaktadır. Platformdaki açık kaynaklı 3B nesne örnekleri, çalışmanın ihtiyaç duymuş olduğu zengin içeriği sunmaktadır.

Modellerin seçim sürecinde, tutarlı bir geometrik yapının olması kritik bir nokta olarak belirlenmektedir. Yüzeylerdeki pürüzsüzlük seviyesi ölçütü ve topolojik bir açıdan doğruluk ölçütü, modellerdeki değerlendirilme aşamasında kullanılan en önemli metrikler içerisinde yer almaktadır. Her bir modelde tespit edilen standartlara uyumluluğu bakımından ayrıntılı olarak incelenmiştir.

Seilen bu modeller, aısal olarak nceden tanımlanmış olan kategorilere dikkat edilerek sistematik olacak şekilde bir dzenlemeye tabi tutulmaktadır. Veri kmesi oluřturma organizasyondaki yapı ile birlikte veri setinin daha sonralardaki evrelerinde kolay kullanılabilmesini saėlamak adına oluřturulmuřtur. Kategorize etme iřlemi sırasında bu modellerin en temel zellikleri dikkate alınmış ve dzenli bir kayıt sistemi de kurulmuřtur.


3.1.2 Grnt oluřturma metodolojisi

Veri toplama srecindeki otomasyon iin, VS Code masast uygulamasında ve Python diliyle geliřtirilmiş bir yazılım kodu ile STL dosyalarından alınacak grntler iin bir altyapı oluřturulmuřtur. Bu kod paracıėı sayesinde STL uzantılı 3D modeli dosyaların farklı aılardan konumlandırılarak (45 derecelik fark olacak şekilde) alınacak grntlerini otomatik bir şekilde oluřturulmak iin programlanmıştır. Her bir 3D modelin x dzlemi, y dzlemi ve z dzleminden olmak zere toplam  ve bu dzlemlerden her birinin yedi farklı aıdan konumlandırılmak řartıyla (0° , 45° , 90° , 135° , 180° , 225° , 270°) toplam yedi aının grselleřtirilmeye tabi tutularak iki boyutlu png formatındaki resimleri alınmıştır.

Bu grntlerin oluřturma iřlemi ařamasında, tutarlı sonular elde edilmesi iin belirli tipteki parametreler de standardize edilmiştir. Aydınlatmadaki kořullar ve arka plan gibi zellikler sabit tutulmuřtur. Bu yaklařım sayesinde grntlerin birbiri arasında karřılařtırılabilirlik iřlemi saėlamıştır. Render etme srecinde kullanılmış olan teknik zellikler ise dikkatle seilmiştir.


Oluřturulan bu grseller, yksek bir znrlėe sahip png formatında kaydedilme iřlemine bařlamıştır. Oluřan resimlerde 960x960 pikseldeki boyutlar tercih edilmiştir ve bu sayede grntlerde bulunan ayrıntıların korunması da hedeflenmiştir. Bu format seimi ile grseldeki kalitenin maksimum bir dzeyde tutulabilmesini de saėlamıştır.

Bu alıřmada, 3 boyutlu STL dosyaları iki boyutlu grsellere dnřtrlerek tamamen zgn bir veri seti hazırlanmıştır.




Şekil 3.1 : Bir STL dosyasının x düzleminde, (a) 0, (b) 45, (c) 90, (d) 135, (e) 180, (f) 225, (g) 270 dereceden açıları.

Şekil 3.1’de örnek bir STL dosyasının x düzlemine karşı yedi farklı açıdan png formatındaki resimleri yer almaktadır.



Şekil 3.2 : Bir STL dosyasının y düzleminde, (a) 0, (b) 45, (c) 90, (d) 135, (e) 180, (f) 225, (g) 270 dereceden açıları.

Şekil 3.2’de örnek bir STL dosyasının y düzlemine karşı yedi farklı açıdan görüntüsü alınarak oluşturulan png formatındaki resimleri yer almaktadır.



Şekil 3.3 : Bir STL dosyasının z düzleminde, (a) 0, (b) 45, (c) 90, (d) 135, (e) 180, (f) 225, (g) 270 dereceden açıları.

Şekil 3.3'te örnek bir STL dosyasının z düzlemine karşı yedi farklı açıdan görüntüsü alınarak oluşturulan png formatındaki resimleri yer almaktadır.

3.1.3 Veri seti bölümlendirmesi

Araştırmadaki kapsamda oluşturulmuş olan kapsamlı veri seti ile titiz bir çalışma gerçekleştirilerek sonuç olarak toplamda 5859 tane yüksek kalitedeki görseller oluşturulmuştur. Bu açısal dağılımlar, sistematik bir yaklaşım ile x, y ve z düzlemlerinden konumlandırılmış yedi farklı perspektiften oluşturulmuş olup, her açı

için özenli bir şekilde seçilmiş görsel sayıları ise şu şekilde düzenlenmiştir. 0° açısında toplam 185 adet, 45° açısında toplam 172 adet, 90° açısında toplam 154 adet, 135° açısında toplam 174 adet, 180° açısında toplam 170 adet, 225° açısında toplam 153 adet ve son olarak 270° açısında toplam 164 adet görsel bulunmaktadır (Şekil 3.1).

Veri setinin eğitim grubu ve test grubuna ayrılması sürecinde, bilimsel metodoloji ilkeleri gözetilmiştir. Toplamda görüntü sayısının %80 orandaki dilimi olan 4687 adet görsel veri, modeldeki eğitim sürecinde kullanılmak için ayrılmıştır. Diğer geriye kalan %20 oranındaki kısım, yani toplamda 1172 adet görsel veri ise test aşamasında kullanılmak üzere rezerve edilmiştir. Bu orandaki dağılım ile literatürde kabul gören standartlar sayesinde tespit edilmiş olup, modeldeki öğrenme kapasitesi ve genelleme kapasitesini de optimize edilmeye yönelik planlanmıştır.

Veri setindeki dengeli dağılım, derin öğrenme mimarilerinin birçok farklı açıdan nesneyi tanıma yeteneklerini de geliştirmede önemli bir rol oynamaktadır. Her bir açı kategorisinden seçilmiş olan görsel verilerin sayısal olarak dengesi, modelin türlü perspektiflerde de dengeli bir performans göstermesini sağlamak adına özenli bir şekilde ayarlanmıştır. Test verilerindeki seçim, eğitim sürecinde bulunan kullanılmamış görsel verilerinden yararlanılması ve modelin gerçek dünya şartlarındaki performansını da değerlendirmede kritik bir nokta olmuştur.

Bu sistematik verideki organizasyon, araştırmada güvenilirlik ve tekrarlanabilirlik özelliklerini artırmak ile kalmayıp, aynı zamanda modelde bulunan genelleme yeteneğinin de objektif olarak değerlendirilmesine imkan tanımaktadır. Veri setinin bu biçimdeki yapılandırılması, derin öğrenme mimarilerinin eğitim sürecinde uygun öğrenme şartlarının sağlanmasına da katkıda bulunmuştur.

Çizelge 3.1 : Her bir açı sınıfındaki görsel dağılımı.

Açı (Sınıf)	Toplam Görsel Sayısı	Eğitim Verisi (%80)	Test Verisi (%20)
0	837	652	185
45	837	665	172
90	837	683	154
135	837	663	174
180	837	667	170
225	837	684	153
270	837	673	164
Toplam	5859	4687	1172

3.2 Kullanılan Platform Ve Donanım

Model eğitimi sürecinde hem Google Colab platformu hem de yerel bir bilgisayar kullanılmıştır. Google Colab, Google tarafından sağlanan bulut tabanlı bir derin öğrenme geliştirme ortamıdır ve bu süreçte, platformun "Pro" sürümü tercih edilmiştir. Colab Pro'nun sunduğu 25 GB'a kadar yükseltilebilen RAM kapasitesi, büyük veri kümelerinin işlenmesi ve yüksek boyutlu modellerin eğitimi sırasında önemli bir avantaj sağlamıştır. Bunun yanı sıra, Colab'in sağladığı NVIDIA Tesla T4 veya P100 GPU donanımları, modelin paralel işlem kapasitesini artırarak eğitim sürecini büyük ölçüde hızlandırmıştır. Bu özellikler, özellikle büyük ölçekli verilerle çalışırken daha verimli ve hızlı bir model geliştirme süreci sunmuştur.

Yerel olarak model eğitimi ve denemeleri için kullanılan bilgisayarın özellikleri ise şu şekildedir:

- İşlemci: Intel(R) Core(TM) i7-8750H CPU @ 2.20 GHz
- Ekran Kartı: NVIDIA GeForce GTX 1070 (8 GB)
- Çekirdek Frekansı: 2.21 GHz
- Bellek (RAM): 16 GB
- Depolama Aygıtı: 1.14 TB SSD

Bu iki farklı platformun bir arada kullanılması, hem bulut tabanlı hem de donanım tabanlı farklı ihtiyaçların karşılanmasına olanak tanımış ve model geliştirme sürecini hızlandırmıştır.

3.3 CNN Mimarileri İle Elde Edilen Bulgular

3.3.1 Eğitim parametreleri

Bu çalışmada kullanılan CNN mimarileri (ResNet50, EfficientNet, Xception, MobileNetV2, InceptionResNetV2 ve DenseNet121), belirli temel eğitim parametrelerinde ortak bir yapı çerçevesinde değerlendirilmiştir. Eğitim sürecinde, tüm modeller için batch size değeri 32, learning rate değeri 0.0001, optimizer olarak ise Adam algoritması kullanılmış ve her bir model 50 epoch boyunca eğitilmiştir (Çizelge 3.2). Eğitim parametrelerinin bu şekilde standardize edilmesi, farklı

mimarilerin eşit koşullar altında eğitilmesine olanak sağlamış ve elde edilen performans verilerinin karşılaştırılabilirliğini artırmıştır. Böylece modellerin doğruluk, başarı ve kaynak kullanımı açısından gösterdiği farklılıkların yalnızca mimariden kaynaklandığı varsayımı yapılabilmektedir.

Adam optimizasyon algoritmasının tercih edilme nedeni, özellikle derin öğrenme modellerinde momentum ve adaptif öğrenme oranı özelliklerini bir arada sunarak daha kararlı ve hızlı bir yakınsama sağlamasıdır. Adaptif öğrenme oranları kullanması, başlangıç öğrenme oranının seçimi eğitim sürecinin stabilitesi açısından kritiktir. Özellikle, değeri 0.0001 gibi düşük bir başlangıç öğrenme oranı, transfer öğrenme ve ince ayar (fine-tuning) süreçlerinde daha istikrarlı bir eğitim sağlar [65].

Eğitim süresi olarak belirlenen 50 epoch, modellerin yeterli düzeyde öğrenme gerçekleştirmesi, doğruluk değerlerinin dengelenmesi ve erken yakınsama eğilimlerinin gözlemlenebilmesi açısından uygun bir süre olarak değerlendirilmiştir. Daha yüksek epoch sayılarında overfitting riski artabileceğinden, 50 epoch optimum bir denge sağlamaktadır. Eğitim sırasında doğrulama kaybı izlenmiş ve bu sayede modellerin aşırı öğrenme davranışı göstermemesi amaçlanmıştır.

Çizelge 3.2’de mimari yapıların giriş boyutlarına bakıldığında ise iki temel gruptandırma yapılmıştır. Xception ve InceptionResNetV2 modelleri, orijinal tasarımlarına uygun olarak 299x299x3 boyutlarında giriş kullanırken, diğer modeller ise 224x224x3 boyutlarında girişleri tercih etmiştir. Bu tercih, hem bellekteki kullanım miktarını hem de eğitim sırasında işlenen veri hacmini doğrudan etkilemektedir. 299x299’luk giriş boyutu daha yüksek bilgi çözünürlüğü sağlarken, 224x224 boyutu özellikle kaynak verimliliği açısından avantaj sunmaktadır.

Fine-tuning stratejileri açısından ise her bir mimaride farklı seviyelerde yeniden eğitim uygulanmıştır. InceptionResNetV2 mimarisi, transfer öğrenme sürecinde veri kümesine daha kapsamlı şekilde uyum sağlamak amacıyla son 100 katmanı yeniden eğitmiş ve bu yönüyle en kapsamlı fine-tuning yaklaşımını benimsemiştir. Diğer yandan, Xception ve MobileNetV2 mimarileri yalnızca son 20 katman üzerinde fine-tuning işlemi gerçekleştirerek daha kısa sürede eğitimi tamamlamayı ve hesaplama kaynaklarını daha verimli kullanmayı hedeflemiştir. Bu farklı yaklaşımlar, eğitim süresi, GPU kullanımı ve elde edilen doğruluk değerleri üzerinde belirleyici rol oynamaktadır.

Sonuç olarak, bu çalışmada belirlenen eğitim parametreleri hem literatürle uyumlu olacak şekilde hem de modeller arası karşılaştırılabilirliği sağlayacak biçimde yapılandırılmıştır. Tüm mimariler, aynı eğitim koşulları altında değerlendirilmiş ve mimariden kaynaklanan performans farklarının daha doğru yorumlanabilmesi sağlanmıştır.

Çizelge 3.2 : CNN mimarilerinin eğitim parametreleri karşılaştırması.

Model Adı	Batch Size	Learning Rate	Optimizer	Fine-tuning	Giriş Boyutu	Epoch Sayısı
ResNet50	32	0.0001	Adam	Son 30 katman	224x224x3	50
EfficientNet	32	0.0001	Adam	Son 30 katman	224x224x3	50
Xception	32	0.0001	Adam	Son 20 katman	299x299x3	50
MobileNetV2	32	0.0001	Adam	Son 20 katman	224x224x3	50
InceptionResNetV2	32	0.0001	Adam	Son 100 katman	299x299x3	50
DenseNet121	32	0.0001	Adam	Son 50 katman	224x224x3	50

Çizelge 3.2'de, kullanılan CNN mimarilerinin eğitim parametreleri detaylı bir şekilde karşılaştırmalı olarak sunulmuştur.

3.3.2 Mimarilerin performans sonuçları

Çizelge 3.3'te sunulmuş olan CNN mimarilerinin karakteristik özellikleri ve performanstaki metrikleri incelenmiştir. Öncelikle doğruluk (accuracy) başlığı altında temsil edilen yüzdesel doğruluk değerleri farklı açılardaki (0°, 45°, 90°, 135°, 180°, 225°, 270°) sınıfların doğruluk ortalamalarını göstermektedir.

ResNet50 mimarisi, atlama bağlantıları ve residual blok yapısını etkin şekilde kullanarak toplam 24.7M parametre ve 24.6M eğitilebilir parametre ile 94.15 MB'lık bir model boyutunda %73,22 doğruluk oranına ulaşmıştır. Residual bloklar ile batch normalization katmanlarının etkisi olduğu değerlendirilmektedir.

EfficientNet, yalnızca 4.8M parametre ile 18.46 MB'lık oldukça kompakt bir model boyutunda %72,83 doğruluk oranı elde etmiştir. MBConv blokları ile sıkıştırma ve uyarım mekanizmaları sonuca etki etmiştir.

Xception, toplam 22M parametre ve 84.89 MB boyutla %69,73 doğruluk oranı sağlamıştır. Bu mimarinin giriş, orta ve çıkış akışı olmak üzere üç temel yapısal

bölüme ayrılması, özelliklerin ayrıştırılması ve yoğunlaştırılması sonucun belirlenmesine etki etmiştir.

MobileNetV2 ise en kompakt yapıda olan mimaridir. Toplam 3M parametre ve 11.62 MB model boyutu ile minimal bir mimari olmasına rağmen, depthwise konvolüsyon katmanları ile %68,84 doğruluk oranı elde edilmiştir.


InceptionResNetV2, değerlendirilen mimariler içerisinde en karmaşık yapıya sahiptir. Toplam 56.4M parametre ve 215.30 MB model boyutu ile oldukça kapsamlı bir mimari olmasına rağmen, %69,63 doğruluk oranında kalmıştır.

DenseNet121 ise yoğun bağlantıları ile alternatif bir yaklaşım sunmakta olup toplam 7.7M parametre ve 29.36 MB model boyutuyla, dense bloklar aracılığıyla bilgi akışı sağlayarak %71,38 doğruluk oranına ulaşmıştır. Doğruluk, mimarinin parametrik verimliliği ve öğrenme kapasitesi arasında denge kurduğunu göstermektedir.

Sonuçlar, model karmaşıklığıyla performans arasındaki ilişkinin her zaman doğrusal olmadığını göstermektedir. Özellikle kaynak kısıtlı ortamlarda kompakt mimarilerin sağladığı doğruluk-verimlilik dengesi önemli bir avantaj oluşturmaktadır. Büyük boyutlu modellerin her zaman en yüksek performansı garanti etmediği, optimize edilmiş daha küçük mimarilerin de kritik sonuçlar sunabildiği görülmektedir.

Çizelge 3.3 : Derin öğrenme modellerinin mimari özellikleri ve parametre detayları.

Model Adı	Temel Mimari Özellik	Toplam Parametre	Model Boyutu (MB)	Eğitilebilir Parametre	Özel Mimari Bileşenler	Doğruluk (Accuracy)
ResNet50	Atlama bağlantıları	24.7M	94.15	24.6M	Residual bloklar, batch normalizasyon	%73,22
EfficientNet	Bileşik ölçekleme	4.8M	18.46	4.8M	MBConv blokları, Sıkıştırma ve uyarım blokları	%72,83
Xception	Derinliksel ayrılabilir evrişim.	22M	84.89	8.5M	Giriş akışı, orta akış, çıkış akışı	%69,73
MobileNetV2	Derinliksel ayrılabilir evrişim	3M	11.62	2M	Depthwise konvolüsyon katmanları	%68,84
InceptionResNetV2	Inception + ResNet	56.4M	215.30	17.6M	Karma inception blokları	%69,63
DenseNet121	Yoğun bağlantılar	7.7M	29.36	1.7M	Dense bloklar	%71,38



Şekil 3.4 : Modellere göre doğruluk grafiği.

Şekil 3.4 modellere göre doğruluk grafiği verilmiştir. Veri setinde her bir açının doğruluk oranı alınarak ortalaması grafiğe yansıtılmıştır.

Çizelge 3.4’te sınıf bazlı F1 skorları değerlendirildiğinde, modellerin belirli açılardan farklı performans sergilediği gözlemlenmiştir. Angle_0 sınıfında ResNet50 (0.8912), Xception (0.8870), InceptionResNetV2 (0.8845) ve DenseNet121 (0.8767) modelleri öne çıkmıştır. Buna karşın Angle_135 sınıfı tüm modeller için en zorlayıcı açıyı temsil etmiş; ResNet50 (0.6857) ve EfficientNet (0.6625) bu sınıfta en yüksek değerleri elde ederken, Xception ve MobileNetV2 bu sınıfta 0.5957 F1 skoruna ulaşabilmiştir. Angle_180 sınıfında ise yine ResNet50 mimarisi (0.7417) en başarılı sonuçları verirken, EfficientNet mimarisi (0.7316) onu takip etmiştir.

Çizelge 3.4 : Sınıf bazlı F1 skor karşılaştırması.

Açı Sınıfı	ResNet 50	Efficient Net	Xception	Mobile NetV2	Inception ResNetV2	DenseNet 121
angle_0	0.8912	0.8352	0.8870	0.8253	0.8845	0.8767
angle_45	0.7636	0.7470	0.7247	0.7247	0.7616	0.7871
angle_90	0.6857	0.6899	0.6506	0.6506	0.6326	0.6597
angle_135	0.6857	0.6625	0.5957	0.5957	0.6216	0.6676
angle_180	0.7417	0.7316	0.6749	0.6749	0.7000	0.7000
angle_225	0.6500	0.6461	0.6395	0.6395	0.6006	0.6061
angle_270	0.7077	0.7860	0.7086	0.7086	0.6738	0.6994


Çizelge 3.5’te modellerin eğitim, validasyon doğruluğu ve eğitim süresi karşılaştırılmıştır. Xception, eğitim sırasında %85’e ulaşmasına rağmen, validasyonda %69 seviyesinde kalmış ve bu durum modelin aşırı öğrenme eğiliminde olduğunu göstermiştir. InceptionResNetV2 de benzer biçimde eğitimde %84, validasyonda %69

oranlarına ulaşarak bu eğilimi göstermiştir. ResNet50 ise %82 eğitim doğruluğuna karşılık %73 validasyon doğruluğu ile görece daha dengeli bir genel performans sergilemiştir. EfficientNet ve MobileNetV2, düşük eğitim süresi ve dengeli doğruluk değerleriyle istikrarlı öğrenme süreçleri geçirmiştir. EfficientNet'in %74 eğitim ve %72 validasyon doğruluğu sonuçları elde edilmiştir.

Çizelge 3.5 : Modellerin eğitim karakteristikleri.

Model Adı	Eğitim Doğruluğu	Validasyon Doğruluğu	Eğitim Süresi
ResNet50	%82	%73	Orta
EfficientNet	%74	%72	Düşük
Xception	%85	%69	Orta
MobileNetV2	%77	%68	Düşük
InceptionResNetV2	%84	%69	Yüksek
DenseNet121	%74	%71	Yüksek


Model boyutu ve eğitim süresi açısından yapılan değerlendirmelerde, InceptionResNetV2 gibi büyük mimarilerin yüksek hesaplama gücü ve uzun eğitim sürelerine ihtiyaç duyduğu, buna karşılık EfficientNet ve MobileNetV2 gibi kompakt mimarilerin çok daha kısa sürede ve düşük kaynak tüketimiyle eğitilebildiği gözlemlenmiştir. ResNet50 ve Xception orta, DenseNet121 ise yüksek kaynak gereksinimleri gerektirdiği sonuçlarına ulaşılmıştır.



Şekil 3.5 : Model performans karşılaştırması.

Eğitim ve validasyon doğruluğu grafiği Şekil 3.5' te modellere göre yüzdesel olarak belirtilerek grafiğe yansıtılmıştır.

Çalışmanın bu aşamasında, modellerin genelleme yeteneklerini ve performanslarını daha da iyileştirmek amacıyla varolan veri seti üzerinde incelemeler yapılmış ve eğitim verisine veri artırma tekniği uygulanmıştır. Bu bağlamda, ImageDataGenerator kullanılarak döndürme (rotation_range=15), yatay ve dikey kaydırma (width_shift_range=0.2, height_shift_range=0.2), yakınlaştırma (zoom_range=0.15), yatay ve dikey çevirme (horizontal_flip=True, vertical_flip=True), parlaklık değişimi (brightness_range=[0.8, 1.2]), kayma (shear_range=0.15) gibi çeşitli geometrik ve fotometrik dönüşümler uygulanarak eğitim verisinin çeşitliliği artırılmıştır (Şekil 3.6).



Şekil 3.6 : Eğitim verisine uygulanan örnek data artırma.

Colab üzerinde uygulanan veri artırma stratejisine rağmen, ilk eğitim sonuçlarına kıyasla validasyon metriklerinde (eğitim doğruluğu, validasyon doğruluğu, kesinlik, duyarlılık ve F1 skorları vb.) belirgin ve istatistiksel olarak anlamlı bir iyileşme gözlemlenmemiştir (Çizelge 3.6).

Çizelge 3.6 : Modellerin veri artırma eğitim sonuçları.

Model Adı	Eğitim Doğruluğu	Validasyon Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skor
ResNet50	%64	%55	0.5000	0.1297	0.2060
EfficientNet	%56	%54	0.5714	0.0235	0.0452
Xception	%67	%50	0.2336	0.4156	0.2991
MobileNetV2	%59	%51	0.2434	0.4770	0.3223
InceptionResNetV2	%66	%52	0.3009	0.2073	0.2455
DenseNet121	%56	%49	0.1951	0.1395	0.1627

Çizelge 3.6’da veri artırma sonucu kesinlik, duyarlılık ve bu ikisinin harmonik ortalaması olan F1 skor değeri farklı derecelerden elde edilen sonuçların ortalamasına bakılarak hesaplanmıştır.

4. SONUÇLAR VE ÖNERİLER

4.1 Sonuçlar

Bu çalışma, derin öğrenme temelli evrimsel sinir ağı mimarilerinin üç boyutlu nesne tanıma işlevindeki performanslarını kapsamlı bir şekilde analiz etmiştir. Farklı mimarilerin yapısal özellikleri, parametre sayıları, model boyutları ve doğruluk oranları karşılaştırılmıştır. Ayrıca sınıf bazlı başarımları ve eğitim karakteristikleri ayrıntılı olarak incelenmiştir.

Çalışmanın temel sonuçlarından biri, model karmaşıklığı ile doğruluk arasında doğrudan bir ilişkinin her zaman geçerli olmadığıdır. Örneğin, en yüksek parametre sayısına sahip olan InceptionResNetV2 mimarisi, genel doğruluk açısından en iyi performansı sergilememiştir. Bu durum, modelin sadece derinliğinin veya parametre sayısının artırılmasının, veri setine uygunluk ve genelleme yeteneği gibi faktörler göz ardı edildiğinde performans artışı sağlamayabileceğini göstermektedir. Aksine, genel başarımlar ve parametrik verimlilik dengesi gözetildiğinde, ResNet50 mimarisi bu çalışmada optimum model olarak öne çıkmaktadır. Yüksek doğruluk oranı ve makul parametre sayısı ile iyi bir denge sunmaktadır. Üç boyutlu nesne tanıma işlemi gibi karmaşık işlerde, geleneksel yöntemler genellikle insan gözüyle yapılan görsel incelemeye dayanmaktadır. Ancak bu yaklaşımlar zaman alıcı, yorucu ve subjektif olabilmektedir. Derin öğrenme modelleri, bu sınırlamaları aşarak daha hızlı, tutarlı ve objektif sonuçlar sunma potansiyeline sahiptir.

3D STL nesnelerinin iki boyutlu düzleme aktarım işleminde ve birçok farklı açıdan sınıflandırılmasında ise nesnelerdeki değişken başarımların profilleri gösterdiği tespit edilmiştir. Özellikle 0 derecelik açıda bütün mimariler üstün bir performans gösterirken, bazı (135 derecedeki gibi) açılarda performans düşüşleri gözlenmiştir. Bu durum açıkça açıdaki çeşitliliğin model başarısını doğrudan etkilediğini göstermektedir.

Sınıf bazlı F1 skorları incelendiğinde, mimarilerin farklı açılardaki nesneleri tanıma konusunda değişken sonuçlar sergilediği görülmüştür. Angle_135 sınıfının tüm

modeller için en zorlayıcı sınıf olması, belirli bakış açılarından elde edilen görsel bilgilerin temsil edilmesinde mimarilere özgü zorluklar olabileceğini göstermektedir. Öte yandan, EfficientNet mimarisinin Angle_270 sınıfındaki üstün başarımı, bazı mimarilerin belirli özelliklere ve açılara karşı daha duyarlı olabileceğini göstermektedir.

Eğitim karakteristikleri açısından, bazı modellerde (Xception mimarisi ve InceptionResNetV2 mimarisi) eğitim doğruluğu ve validasyon doğrulukları arasında belirgin farklar gözlemlenmiştir. Bu durum, bu mimarilerin aşırı öğrenme eğilimine sahip olabileceğini ve genelleme yeteneklerinin sınırlı olabileceğini düşündürmektedir. Buna karşın, sınırlı donanım kaynaklarına sahip uygulamalar için EfficientNet ve MobileNetV2 mimarileri, düşük parametre sayıları ve model boyutları ile öne çıkmaktadır. Bu mimariler, dengeli bir öğrenme süreci sergileyerek aşırı öğrenmeye karşı daha dirençli olduklarını göstermişlerdir ve kaynak kısıtlı ortamlarda veya hızlı prototipleme gerektiren uygulamalarda önemli avantajlar sunmaktadır.

Çalışmanın ilerleyen aşamalarında, modellerin genelleme yeteneklerini ve performanslarını daha da iyileştirmek amacıyla veri artırma teknikleri uygulanmıştır. Döndürme, kaydırma, yakınlaştırma, çevirme ve parlaklık değişimi gibi çeşitli geometrik ve fotometrik dönüşümler ile eğitim verisinin çeşitliliği artırılmıştır. Ancak, elde edilen sonuçlar (Çizelge 3.6), veri artırma işleminin bu modelin validasyon doğruluğu ve sınıf bazlı F1 skorlarında belirgin bir iyileşme sağlamadığını açıkça göstermiştir. Bu durum, mevcut veri setinin ve modelin bu tür artırma tekniklerine karşı doygunluğa ulaşmış olabileceğini göstermektedir.

Özetle, bu çalışma, farklı CNN mimarilerinin üç boyutlu nesnelerden elde edilmiş iki boyutlu resimleri tanıma işlemindeki başarımını etkileyen çeşitli faktörleri incelemiştir. Elde edilen bulgular, model karmaşıklığının her zaman çok daha yüksek doğruluk anlamına gelmediğini, kaynak kısıtlarının önemli olduğu durumlarda kompakt modellerin de rekabetçi sonuçlar sunabileceğini ve mimari seçiminin spesifik uygulama gereksinimleri ile veri setinin özelliklerine göre dikkatlice yapılması gerektiğini vurgulamaktadır.

4.2 Öneriler

Çalışmada elde edilen bulgular ışığında, hem uygulama alanları hem de gelecekteki araştırmalar için ilk olarak, kompakt yapıya sahip EfficientNet ve MobileNetV2 gibi modeller, kaynak kısıtlı ortamlarda veya mobil uygulamalarda kullanılabilecek etkili modeller olarak gösterilebilir. Bu modeller, düşük parametre sayıları ve hızlı eğitim süreleri ile hem doğruluk hem de verimlilik açısından başarılı sonuçlar vermiştir. Öte yandan, yüksek doğruluk gerektiren uygulamalarda ResNet50 mimarisi, parametrik verimlilik ve genel başarı dengesi ile diğer mimarilere kıyasla en iyi model olarak gösterilmektedir.

Gelecekteki çalışmalar için daha büyük ve çeşitli veri setlerinin kullanılması önerilmektedir. Örneğin, bu çalışmada üç boyutlu bir STL nesnesinin 45 derecelik farklarla resimleri alındı ve veri seti bu şekilde oluşturuldu. İleriki çalışmalarda derece farkını daha da azaltarak (örneğin 5,10,20,30) açısal çeşitlilik ile veri seti büyütülebilir ve bu sayede modellerin performansı optimize edilebilir. Optimizasyon teknikleri açısından ise Adam optimizier dışında, SGD, RMSprop veya AdaGrad gibi alternatif yöntemlerin farklı mimariler üzerindeki etkileri incelenebilir.

Endüstriyel uygulamalar açısından, CNN tabanlı görsel benzerlik analizine dayalı sistemler, tasarım süreçlerini hızlandırarak projelerin başlangıç aşamasında zamandan tasarruf ve süreçleri optimize etmek için kullanılabilir. Özellikle prototip geliştirme veya benzer ürünlerin hızlı bir şekilde tespit edilmesi gibi görevlerde bu sistemlerin uygulanabilirliği yüksektir. Derin öğrenme modelleri ve geleneksel bilgisayarlı görü tekniklerinin hibrit bir şekilde kullanılması, hem performansı artırabilir hem de hesaplama maliyetlerini düşürebilir. Bu önerilerin, hem akademik araştırmalar hem de endüstriyel uygulamalar için yol gösterici olması hedeflenmiştir.

KAYNAKLAR

- [1] Gonçalves, M., Cardoso, C., Badke-Schaub, P. (2014). What inspires designers? Preferences on inspirational approaches during idea generation. *Design studies*, 35(1), 29-53.
- [2] Cross, N. (2023). *Design thinking: Understanding how designers think and work*. Bloomsbury Publishing.
- [3] Dell’Era, C., Magistretti, S., Candi, M., Bianchi, M., Calabretta, G., Stigliani, I., Verganti, R. (2025). *Design thinking in action: A quantitative study of design thinking practices in innovation projects*. Journal of Knowledge Management. <https://doi.org/10.1108/JKM-04-2024-0424>
- [4] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [5] Tan, M., Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- [6] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).
- [7] Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- [8] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- [9] Ruediger-Flore, P., Glatt, M., Hussong, M., Aurich, J. C. (2023). CAD-based data augmentation and transfer learning empowers part classification in manufacturing. *The International Journal of Advanced Manufacturing Technology*, 125(11), 5605-5618
- [10] Farahmand, M. (2022). Bal peteğindeki hücrelerin tespit edilmesi için derin öğrenme yaklaşımlarının kullanılması.
- [11] Bozkurt, F. (2021). Derin öğrenme tekniklerini kullanarak akciğer X-ray görüntülerinden Covid-19 tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (24), 149-156.

- [12] **Ezzat, A. S. D.** (2020). Evrişimsel Sinir Ağları ile Toraks BT Görüntülerinden Akciğer Kanseri Tespiti. *Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.*
- [13] **Öner, M. R.** (2023). Derin Öğrenme Algoritmaları Kullanılarak Dış ve Orta Kulak Hastalıklarının Tespiti. *Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü.*
- [14] **Elitok, E., Kasım, Ö., Saraoğlu, H. M.** (2024). Stokastik Komşuluk Gömülme ile Özellik Çıkarımı ve Derin Transfer Öğrenmesi kullanılarak göğüs röntgeni görüntülerinden etkili pnömoni tespiti. *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences*, 11(36), 17-40.
- [15] **Özçelik, S. T. A., Üzen, H., Şengür, A., Çelebi, A.** (2024). Derin öğrenme ile panoramik radyografi görüntülerinden diş segmentasyonu: UNet, FPN ve PSPNet karşılaştırması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(4), 1347-1354.
- [16] **Demir, F. B.** (2022). Akciğer bilgisayarlı tomografilerinden görüntü işleme ve derin öğrenme ile COVID-19 tespiti. *Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi.*
- [17] **Jha, N., Pant, D. R.** (2021). Stochastic gradient descent and discriminative fine tuning on ResNet, DenseNet, Inception-ResNet and MobileNet for the multi class pathogenic microbes classification. In *10th IOE graduate conference (IOEGC)* (pp. 604-613).
- [18] **Pattanaik, R. K., Mishra, S., Siddique, M., Gopikrishna, T., Satapathy, S.** (2022). Breast cancer classification from mammogram images using extreme learning machine-based DenseNet121 model. *Journal of Sensors*, 2022(1), 2731364.
- [19] **Breve, F. A.** (2022). COVID-19 detection on Chest X-ray images: A comparison of CNN architectures and ensembles. *Expert systems with applications*, 204, 117549.
- [20] **Su, H., Maji, S., Kalogerakis, E., Learned-Miller, E.** (2015). Multi-view convolutional neural networks for 3d shape recognition. In *Proceedings of the IEEE international conference on computer vision* (pp. 945-953).
- [21] **Rajpal, S., Lakhyani, N., Singh, A. K., Kohli, R., Kumar, N.** (2021). Using handpicked features in conjunction with ResNet-50 for improved detection of COVID-19 from chest X-ray images. *Chaos, Solitons & Fractals*, 145, 110749.
- [22] **Salim, F., Saeed, F., Basurra, S., Qasem, S. N., Al-Hadhrani, T.** (2023). DenseNet-201 and Xception pre-trained deep learning models for fruit recognition. *Electronics*, 12(14), 3132.
- [23] **Özdemir, M. T.** (2023). Effcientnet ve Resnet-50 Modelleri Kullanılarak Limon Görüntülerinin Sınıflandırılması. *YÖK Tez Merkezi*, 123, 803810 (2023).
- [24] **Koyuncu, H., Barstuğan, M.** (2023). A New Breakpoint to Classify 3D Voxels in MRI: A Space Transform Strategy with 3t2FTS-v2 and Its Application for ResNet50-Based Categorization of Brain Tumors. *Bioengineering*, 10(6), 629.

- [25] Shin, H. C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Summers, R. M. (2016). Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE transactions on medical imaging*, 35(5), 1285-1298.
- [26] Goodfellow, I., Bengio, Y., Courville, A. (2016). Deep learning. MIT press.
- [27] LeCun, Y., Bengio, Y., Hinton, G. (2015). "Deep learning." *Nature*, 521(7553), 436-444.
- [28] Bengio, Y., Courville, A., Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.
- [29] He, K., Fan, H., Wu, Y., Xie, S., Girshick, R. (2020). Momentum contrast for unsupervised visual representation learning. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 9729-9738).
- [30] Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- [31] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- [32] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [33] Analytics Yogi. <<https://vitalflux.com/different-types-of-cnn-architectures-explained-examples/>>, erişim tarihi 29.12.2024.
- [34] Nwankpa, C., Ijomah, W., Gachagan, A., Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
- [35] Dubey, S. R., Singh, S. K., Chaudhuri, B. B. (2021). A comprehensive survey and performance analysis of activation functions in deep learning. *arXiv preprint arXiv:2109.14545*, 99.
- [36] Agarap, A. F. (2018). Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*.
- [37] Nair, V., Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).
- [38] Ioffe, S. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*.
- [39] Santurkar, S., Tsipras, D., Ilyas, A., Madry, A. (2018). How does batch normalization help optimization?. *Advances in neural information processing systems*, 31.
- [40] Wu, Y., He, K. (2018). Group normalization. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 3-19).

- [41] Lin, M. (2013). Network in network. *arXiv preprint arXiv:1312.4400*.
- [42] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2921-2929).
- [43] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [44] Zhang, C., Bengio, S., Hardt, M., Recht, B., Vinyals, O. (2021). Understanding deep learning (still) requires rethinking generalization. *Communications of the ACM*, 64(3), 107-115.
- [45] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [46] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- [47] Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv 2012. arXiv preprint arXiv:1207.0580*.
- [48] Ba, J., Frey, B. (2013). Adaptive dropout for training deep neural networks. *Advances in neural information processing systems*, 26.
- [49] Gal, Y., Ghahramani, Z. (2016). Dropout as a bayesian approximation: Representing model uncertainty in deep learning. In *international conference on machine learning* (pp. 1050-1059). PMLR.
- [50] Bridle, J. S. (1990). Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition. In *Neurocomputing: Algorithms, architectures and applications* (pp. 227-236). Berlin, Heidelberg: Springer Berlin Heidelberg.
- [51] Bishop, C. M., Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4, No. 4, p. 738). New York: springer.
- [52] Liu, W., Wen, Y., Yu, Z., Yang, M. (2016). Large-margin softmax loss for convolutional neural networks. *arXiv preprint arXiv:1612.02295*.
- [53] Deng, J., Berg, A. C., Li, K., Fei-Fei, L. (2010). What does classifying more than 10,000 image categories tell us?. In *Computer Vision—ECCV 2010: 11th European Conference on Computer Vision, Heraklion, Crete, Greece, September 5-11, 2010, Proceedings, Part V 11* (pp. 71-84). Springer Berlin Heidelberg.
- [54] Aly, M. (2005). Survey on multiclass classification methods. *Neural Netw*, 19(1-9), 2.
- [55] Zhou, Z. H., Zhang, M. L., Huang, S. J., Li, Y. F. (2012). Multi-instance multi-label learning. *Artificial Intelligence*, 176(1), 2291-2320.

- [56] **Scaler Topics.** <<https://www.scaler.com/topics/deep-learning/efficientNet/>>, erişim tarihi 28.12.2024.
- [57] **Uzun, M. Z., Başaran, E., Çelik, Y.** (2023). Xception Derin Öğrenme Modeli ve Gabor Filtreleri ile ÇDÖÖE-DVM Algoritması Kullanılarak Mikro İfadelerin Tanınması. *Journal of the Institute of Science and Technology*, 13(4), 2339-2352.
- [58] **Analytics Vhidya.** <<https://www.analyticsvidhya.com/blog/2023/12/what-is-mobilenetv2/>>, erişim tarihi 28.12.2024.
- [59] **Szegedy, C., Ioffe, S., Vanhoucke, V., Alemi, A. A.** (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. *AAAI Conference on Artificial Intelligence*, 31(1).
- [60] **Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q.** (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- [61] **Li, W., Zheng, T., Yang, Z., Li, M., Sun, C., Yang, X.** (2021). Classification and detection of insects from field images using deep learning for smart pest management: A systematic review. *Ecological Informatics*, 66, 101460.
- [62] **Sokolova, M., Lapalme, G.** (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.
- [63] **Powers, D. M.** (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *arXiv preprint arXiv:2010.16061*.
- [64] **Goutte, C., Gaussier, E.** (2005). A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In *European conference on information retrieval* (pp. 345-359). Berlin, Heidelberg: Springer Berlin Heidelberg.
- [65] **Kingma, D. P., Ba, J.** (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.

ÖZGEÇMİŞ

TARANMIŞ
VESİKALIK
FOTOĞRAF

Ad-Soyad : Rukiye TİPİ

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2019, Sakarya Üniversitesi, Haşim Gürdamar Bilgisayar ve Bilişim Bilimleri Fakültesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- Devam Ediyor, Mubitek Tasarım ve Bilişim, Yazılım Mühendisi

YAYINLAR:

- **Tipi, R., Şahin, H., Doğru, Ş., Zengin Bintaş, G. Ç.** (2023). A Comparative Evaluation on the Prediction Performance of Regression Algorithms in Machine Learning for Die Design Cost Estimation. *Electronic Letters on Science and Engineering*, 19(2), 48-62.