

**ANKARA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**DOKTORA TEZİ**

**SIFIR ATIŞ ÖĞRENME VE ONTOLOJİYİ KULLANARAK HASTALIK  
TANIMADA YENİ BİR YAKLAŞIM**

**Ömürhan A. SOYSAL**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**ANKARA  
2023**

**Her hakkı saklıdır**

## ÖZET

Doktora Tezi

### SIFIR ATIŞ ÖĞRENME VE ONTOLOJİYİ KULLANARAK HASTALIK TANIMADA YENİ BİR YAKLAŞIM

Ömürhan A. SOYSAL

Ankara Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Mehmet Serdar GÜZEL

Açık görüntü veri setlerinin son zamanlarda artmasına rağmen hala sınırlıdır. Bu nedenle, bu veri setleri ve etiketlerle hastalık tespiti/tanınması, tıbbi görüntüleme alanında çok maliyetli ve zor bir iştir. Bu nedenle, bu sorunla ilgili araştırmaların hala geliştirilmesi gerekmektedir. Veri setlerini çeşitlendirmek en büyük zorluktur ve öznellik sorunuyla yüzleşmek zorundadır. Bu sorunun üstesinden gelmek için örneği olmayan sınıflar, bir diğer ifadeyle görünmeyen sınıflar Sıfır-Atış Öğrenme (ZSL) ile eğitilebilir. Bu tezde, sınıf gömmeleri için yardımcı bilgi olarak ontolojiyi kullanarak ZSL'yi güçlendirme amaçlanmıştır. Görüntü gömmeleri ve sınıf gömmelerinin eşlendiği mevcut ZSL yöntemlerinde kullanılan prosedürlere ek olarak, sınıf gömmelerinin semantik verileri de dikkate alınmıştır. Önerilen yaklaşımda ZSL, çok etiketli ChestX-ray14 veri setinin görüntü gömmeleri ve sınıf gömmelerinin yanı sıra DBpedia'dan gelen semantik verilerle desteklenmektedir. Benzerlikleri maksimize etmek için Kosinüs, Hamming ve Öklid mesafeleri dikkate alınmıştır. Veri setini genişletmek için klasik ve evrimsel sinir ağları kullanılmış ve her biri ile testler yapılarak kesinlik değeri yükseltmeye çalışılmıştır. ResNet50 sinir ağı çok etiketli ChestX-ray14 veri seti üzerinde farklı parametrelerle eğitilmiştir. Birebir eşleştirmede en yüksek %29,59 kesinlik değeri ve en az bir eşleştirmede %45,73 kesinlik değeri elde edilmiştir. Sıfır-atış öğrenme literatüründe yer alan çalışmalardaki başarımlarına göre yüksek bir başarımlarına sahip olan bu sonuçlarla beraber bu tez çalışmasının görünmeyen hastalık tespit edilerek/tanınarak tıbbi görüntü alanına önemli bir katkı sağlayacağı düşünülmektedir.

**Haziran 2023, 86 sayfa**

**Anahtar Kelimeler:** Örneksiz Öğrenme, Sıfır-Atış Öğrenmesi, Ontoloji, ChestX-ray14, ResNet50, ResNext50

## ABSTRACT

Ph.D. Thesis

### A NEW APPROACH TO DISEASE RECOGNITION USING ZERO-SHOT LEARNING AND ONTOLOGY

Ömürhan A. SOYSAL

Ankara University  
Graduate School of Natural and Applied Science  
Department of Computer Engineering

Supervisor: Doç.Dr. Mehmet Serdar GÜZEL

Although open image data sets have increased recently, data sets are still limited. So disease detection/recognition with these data sets and labels is very costly and hard challenge in medical domain. Therefore, researches on this problem still need to be improved. It is a greatest challenge to diversify data sets and has to face the problem of subjectivity. Classes without instances, in other words unseen classes, can be trained with Zero-Shot Learning (ZSL) in order to overcome this problem. In this thesis, it is aimed to strengthen ZSL by using ontology as an auxiliary information for class embeddings. In addition to the procedures used in existing ZSL methods where image embeddings and class embeddings are mapped, the semantic data of class embeddings are also considered. In the proposed approach, ZSL is powered by image embeddings and class embeddings of the multi-label ChestX-ray14 data set, as well as semantic data from DBpedia. Cosine, Hamming and Euclidean distances are considered to maximize similarities. Classical and convolutional neural networks were used to augment the data set and the precision value was tried to be increased by making tests with each of them. The ResNet50 neural network is trained on the multi-label ChestX-ray14 data set with different parameters. The highest precision value of 23.25% was obtained in one-to-one matching and 45.73% precision value was obtained in at least one matching. With these results, which have a high success rate compared to the success rates in the studies in the zero-shot learning literature, it is thought that this thesis will make an important contribution to the field of medical imaging by detecting/recognizing invisible disease.

**June 2023, 86 pages**

**Keywords:** Zero-Shot Learning, Ontology, ChestX-ray14, ResNet50, ResNext50

## TEŐEKKÜR

Öncelikle tez alıŐmasının her aŐamasında bana destek olup yol gÖsteren, mesleki bilgilerini ve deneyimlerini Öđrencilerinden esirgemeyip Önerileri ile katkıda bulunan deđerli tez danıŐmanım, Ankara Üniversitesi Bilgisayar Mühendisliđi Anabilim Dalı Öđretim Üyesi Sayın Do. Dr. Mehmet Serdar GÜZEL'e, birikimleriyle bana yol gÖsteren Tez İzleme Komitesi üyelerim; BaŐkent Üniversitesi Bilgisayar Mühendisliđi Ana Bilim Dalı Öđretim Üyesi Sayın Dr. Mehmet DİK MEN ve Ankara Üniversitesi Bilgisayar Mühendisliđi Anabilim Dalı Öđretim Üyesi Sayın Do. Dr. Gazi Erkan BOSTANCI'ya teŐekkürlerimi sunarım.

Beni her konuda destekleyen, doktora sürecimde dünyaya gelen kızım Devrim GüneŐ SOYSAL, yakın zamanda kucađımıza alacađımız Karya Emek SOYSAL ve onların dünyalar güzeli annesi, eŐim Ezgi PekŐen SOYSAL'a soluk almama destek oldukları ve bu alıŐmamı motive ettikleri için; eđitim hayatımda katkıları olan annem ve babama; eŐimin ailesine sonsuz teŐekkürlerimi sunarım.

Ömürhan A. SOYSAL

Ankara, Haziran 2023

## İÇİNDEKİLER

<b>TEZ ONAYI</b>	
<b>ETİK</b> .....	Hata! Yer işareti tanımlanmamış.
<b>ÖZET</b> .....	ii
<b>ABSTRACT</b> .....	iii
<b>TEŞEKKÜR</b> .....	iv
<b>KISALTMALAR DİZİNİ</b> .....	vii
<b>ŞEKİLLER DİZİNİ</b> .....	viii
<b>ÇİZELGELER DİZİNİ</b> .....	x
<b>1. GİRİŞ</b> .....	1
<b>1.1 Çalışmanın Katkısı</b> .....	5
<b>2. LİTERATÜR TARAMASI</b> .....	7
<b>3. YÖNTEM</b> .....	15
<b>3.1 Algılayıcı Öğrenme Algoritması</b> .....	15
<b>3.2 Derin Öğrenme</b> .....	17
<b>3.2.1 Evrişimli sinir ağları</b> .....	20
<b>3.3 Sıfır-Atış öğrenmesi</b> .....	26
<b>3.4 Ontoloji</b> .....	30
<b>3.5 Veri/Görüntü artırımı yöntemleri</b> .....	32
<b>3.5.1 Klasik veri arttırımı</b> .....	33
<b>3.5.2 Deforme veri arttırma teknikleri</b> .....	36
<b>3.5.3 Spline enterpolasyonu</b> .....	36
<b>3.5.4 Deforme olabilen görüntü kaydı</b> .....	36
<b>3.5.5 Diğer deforme olabilen veri arttırma teknikleri</b> .....	37
<b>3.5.6 Derin öğrenme veri arttırma teknikleri</b> .....	37
<b>4. VERİ SETLERİ</b> .....	39
<b>4.1 ChestX-ray14</b> .....	39
<b>4.2 DBpedia</b> .....	44
<b>5. ÖNERİLEN YÖNTEM</b> .....	48
<b>5.1 Problem Formülasyonu ve Gösterimleri</b> .....	48
<b>5.2 Implementasyon</b> .....	51
<b>6. DEĞERLENDİRME</b> .....	56
<b>6.1 ResNet 50 Sinir Ağı ile Yapılan Çalışmalar</b> .....	56
<b>6.2 ResNeXt 50 Sinir Ağı ile Yapılan Çalışmalar</b> .....	60
<b>6.3 Veri/Görüntü Artırımı ile Yapılan Çalışmalar</b> .....	62
<b>6.3.1 Klasik veri arttırımı</b> .....	62
<b>6.3.2 GAN ile veri arttırımı</b> .....	67
<b>6.3.3 Klasik veri arttırımı ve GAN ile veri arttırımı yöntemlerinin birleştirilmesi</b> 73	
<b>6.4 Tekil Etiketle Yapılan Çalışmalar</b> .....	76
<b>6.5 Kısıtlar</b> .....	78
<b>6.6 Geliştirme Ortamı</b> .....	78

<b>7. SONUÇ VE TARTIŞMA</b> .....	<b>79</b>
<b>7.1 Gelecek Çalışmalar</b> .....	<b>80</b>
<b>KAYNAKLAR</b> .....	<b>81</b>
<b>ÖZGEÇMİŞ</b> .....	Hata! Yer işareti tanımlanmamış.



## KISALTMALAR DİZİNİ

ZSL	Sıfır-Atış Öğrenme (Zero-Shot Learning)
GAN	Üretken Çekişmeli Ağlar (Generative Adversarial Networks)
$Y_s$	Görülen sınıflar
$Y_u$	Görülmeyen sınıflar
$Y$	Görülen ve görülmeyen sınıflardan oluşan veri seti
ZSD	ZSD Zero-Shot Detection
ZSC	Zero-Shot Captioning
NBT	Neural Baby Talk
RNN	Recurrent Neural Network
CORL	Combining Ontology and Reinforcement Learning for Zero-Shot Classification
HCR	Hierarchical Classification Rule
MC	Monte Carlo
GPU	Graphical Processing Unit
CNN	Convolutional Neural Network
RNN	Recurrent Neural Network
YSA	Yapay Sinir Ağı

## ŞEKİLLER DİZİNİ

Şekil 1.1	ImageNet yarışmasındaki yöntemlerin sınıflandırma hataları (2011-2016 yılları arası) .....	2
Şekil 1.2	Bilgisayarlı görü yöntemlerinde geniş kapsamlı tanıma parametreleri.....	4
Şekil 3.1	Algılayıcı Algoritması nöron bağlantısının girdiler ve çıktı arasındaki ilişkisi .....	17
Şekil 3.2	ImageNet yarışmasının 2011 ve 2016 yılları arasındaki en yüksek başarımlarına sahip olan yöntemlerinin evrimsel gösterimi .....	19
Şekil 3.3	Tek gizli katmanlı ve çok katmanlı sinir ağı yapısı .....	20
Şekil 3.4	Bir yapay nöronun illüstrasyonu .....	20
Şekil 3.5	$N \times N$ boyutlu bir matrisin üzerinde $F \times F$ boyutlu bir maske ile evrimsel işlemin uygulanmasının illüstrasyonu .....	21
Şekil 3.6	Havuzlama katmanı ile $224 \times 224 \times 64$ boyutlu bir matrisin $112 \times 112 \times 64$ boyutlu bir matrise indirgenmesi .....	23
Şekil 3.7	Tam bağlı katmanın illüstrasyonu (Kaynak: Indiantechwarrior) .....	25
Şekil 3.8	Ili Pika fotoğrafı .....	27
Şekil 3.9	At ve zebra örnekleri .....	27
Şekil 3.10	Sıfır Atış Öğrenmesinde görüntü ve sınıf gömmelerinin kullanımı.....	29
Şekil 3.11	Sıfır Atış Öğrenmesinde görüntü ve etiket verilerinin haritalandırması .....	29
Şekil 3.12	Ontoloji yönetimi .....	32
Şekil 3.13	Klasik veri büyütme yöntemi ile karaciğer lezyonu üzerinde yapılan manipülasyonların sonucu.....	35
Şekil 3.14	Deforme veri arttırma uygulaması sonuçları (Chlap, ve diğerleri, 2021) ....	36
Şekil 3.15	GAN mimarisi .....	37
Şekil 4.1	ChestX-ray 14 veri setindeki 14 patoloji sınıfının birlikte oluşum istatistiği. ....	41
Şekil 4.2	ChestX-ray14 veri setindeki işaretleme örnekleri.....	44
Şekil 4.3	Effusion sınıfının DBpedia'daki kaydının ekran görüntüsü .....	46
Şekil 4.4	Effusion sınıfının DBpedia'daki ilişkili olduğu kavramlar.....	46
Şekil 4.5	Pneumonia sınıfının DBpedia'da ilişkili olduğu kavramlar.....	47
Şekil 5.1	Tez çalışmasında önerilen yöntemin mimarisi.....	48
Şekil 5.2	ChestX-ray14 veri setinden çoklu etikete sahip bir örnek .....	50
Şekil 5.3	ChestX-ray14 veri setindeki 14 yaygın torasik patoloji ve herhangi bir bulgunun tespit edilemedi "No Module" sınıflarına birer örnek .....	50
Şekil 5.4	ResNet öğrenmesi temeli .....	51

Şekil 5.5	Eğitilen sinir ağının özeti .....	53
Şekil 5.6	ResNet ve ResNeXt blokları .....	54
Şekil 5.7	ResNet50 ve ResNeXt50 katmanları.....	54
Şekil 5.8	ResNet ve ResNeXt Top-1 hata oranları.....	55
Şekil 6.1	ResNet50 sinir ağı ile yapılan eğitim sonucunda elde edilen doğruluk oranları .....	59
Şekil 6.2	Emphysema+Nodule+Pleural_Thickening+Pneumothorax sınıfına ait 93309 numaralı örnek üzerinde uygulanan [0.3, 1.5] aralığındaki yeniden boyutlandırma sonuçları .....	63
Şekil 6.3	Veri arttırmında kullanılan GAN mimarisi .....	68
Şekil 6.4	Veri arttırmında kullanılan GAN mimarisi .....	68



## ÇİZELGELER DİZİNİ

Çizelge 4.1	ChestX-Ray 14 veri setindeki sınıfların birlikte oluşum istatistiği.....	42
Çizelge 6.1	ResNet50 sinir ağının eğitiminde kullanılan hiperparametrelerin senaryoları.....	56
Çizelge 6.2	ResNet50 sinir ağının eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%).....	57
Çizelge 6.3	ResNet50 sinir ağının 22, 23 ve 24. senaryolar dahilinde eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%).....	58
Çizelge 6.4	ResNet50 sinir ağı eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları .....	58
Çizelge 6.5	ResNeXt50 sinir ağının eğitiminde kullanılan hiperparametrelerin senaryoları.....	60
Çizelge 6.6	ResNeXt50 sinir ağının eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%).....	60
Çizelge 6.6	ResNeXt50 sinir ağının eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%) (devam).....	61
Çizelge 6.7	ResNeXt50 sinir ağı eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları .....	61
Çizelge 6.8	Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemi uygulanması sonrası sayısı .....	63
Çizelge 6.8	Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemi uygulanması sonrası sayısı .....	64
Çizelge 6.9	ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%).....	66
Çizelge 6.10	ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%).....	66
Çizelge 6.11	ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları .....	66
Çizelge 6.12	Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemi uygulanması sonrası sayısı.....	70
Çizelge 6.13	ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%).....	72

Çizelge 6.14	ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%).....	72
Çizelge 6.15	ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları....	73
Çizelge 6.16	Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemlerinin birleştirilmesi sonrası sayısı.....	73
Çizelge 6.17	ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 5. Epoch ile 55. Epoch arasında elde edilen doğruluk değerleri (%).....	76
Çizelge 6.18	ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%).....	76
Çizelge 6.19	ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları....	76
Çizelge 6.20	Tekil etiketle yapılan çalışmalarda kullanılan veri seti dağılımı .....	77
Çizelge 6.21	ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 5. Epoch ile 55. Epoch arasında elde edilen doğruluk değerleri (%).....	77
Çizelge 6.22	ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%).....	77
Çizelge 6.23	ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları....	78
Çizelge 7.1	Değerlendirme bölümündeki yöntemlerin en az 1 eşleşme sonuçlarını karşılaştırmalı gösteren çizelge.....	80


## 1. GİRİŞ

Günümüz mobil araçları, izleme araçları, güvenlik uygulamaları ve buna benzer araçlar dikkate alındığında görsel bilginin çok hızlı üretildiği ve kontrol edilemeyecek boyutta artışa sahip olduğu bilinmektedir. Arama motoru devi Google'ın Arama Ürünleri Yöneticisi Ben Ling'in açıklamalarına göre Google 2001 yılında 250 milyon fotoğraf indekslemişken 2005 yılında bu sayı 1 milyarı, 2010 yılında 10 milyarı aşmıştır (Siegler, 2010). Sosyal medya kullanımında dünyada birinci sırada yer alan Facebook'un 2018 yılı sonu itibariyle 2,3 milyar kullanıcısı günde 350 milyon fotoğraf yüklemiştir (Simith, 2019). 2016 yılında 1 milyardan fazla aktif kullanıcısı olan Instagram'da her gün 95 milyondan fazla fotoğraf paylaşılmıştır (Staff, 2013). Bu devasa görsel veri ambarında istenilen içeriğe ulaşmak, içeriği yorumlamak, anlamsal ilişkiler çıkarmak güncel araştırmaların konusu haline gelmiştir.

Yapay zekâ alanındaki çalışmalar Alan Turing'in "Bilgisayar Makineleri ve Zekâ" adlı makalesiyle tetiklenmiştir (Turing, 1950). O yıllardan bu yana araştırmacılar, birçok insan davranışını ve düşünme biçimini taklit etmek için makineleri kullanmaya çalışmakta dikkate değer ilerleme kaydetmişlerdir. Günümüzün öne çıkan yapay sinir ağı çalışmalarının temelinde insan beyninin işlevselliğinin yattığı bu alandaki herkes tarafından bilinmektedir. Bu çalışmaların sonucunda, geleneksel makine öğrenmesi yöntemlerine kıyasla gözle görülür ilerleme kaydedilmiştir. Üstelik bu ağlar sadece bilgisayarlı görüde değil, ses analizi, robotik, otonom araçlar, gen analizi, kanser teşhisi ve sanal gerçeklik gibi birçok başka alanda da kullanılmaktadır (İnik & Ülker, 2017). Bu çalışmaların bazılarında elde edilen sonuçlar, bazı ağların belirli bir görev için insanların hata oranından daha düşük hata oranlarıyla önemli başarı oranlarına ulaştığını göstermektedir.

Bu gelişmeler sayesinde yapay zekâ altın çağını yaşamaya başlamıştır. Hem akademik araştırmalar hem de endüstriyel uygulamalar, yapay zekâ yöntemlerinin gelişmesine, derinleşmesine ve yaygınlaşmasına katkı sağlamıştır. Bu alanda yapılan çalışmaların nitelik ve niceliği her geçen gün artmaktadır.

Bilgisayarlı görü alanında yapılan arařtırmalar 2012 yılına kadar donanım ve zaman maliyeti kısıtları yüzünden sınırlı başarımlarına sahip olmuřtur. 2012 yılında büyük ölçekli görsel tanıma (ImageNet) yarışmasında Derin Öğrenme'nin elde ettiđi başarımlar bir anda bu alandaki çalışmalarını alt üst etmiştir (İnik & Ülker, 2017). ImageNet yarışmasında 2011 yılında %74 olan başarımlar oranı 2012 yılında Krizhevsky ve arkadaşlarının yaptığı çalışma ile %83,6'ya ulaşmıştır (Krizhevsky, 2012). Geliştirilen yöntemin bu başarımlar oranına ulaşmasındaki önemli katkılardan birisi de önerilen yöntemlerin büyük veri kaynaklarını kullanması ve bu geniş veri setlerinin işlenebileceđi donanım kaynaklarının geliştirilmesidir. O vakte kadar CPU (Central Processing Unit) üzerinde çalıştırılan yöntemler artık GPU (Graphic Processing Unit) üzerinde çalıştırılabilme olanađına sahip olmuřtur. Zaman maliyetini düşüren bu donanımlar sayesinde *Bilgisayarlı Görü* (Computer Vision) alanında daha büyük veri setlerinden elde edilen özneliklerle oluşturulan modeller daha geniş bir veri temsiline sahip olurken hata oranı da minimize edilebilebilir olmuřtur.



Şekil 1.1 ImageNet yarışmasındaki yöntemlerin sınıflandırma hataları (2011-2016 yılları arası) (Sorin Grigorescu, 2020)

Derin Öğrenme'nin (Deep Learning) yakaladığı başarı, yöntemin adındaki “derin” kavramının ifade ettiği ađın katman sayısının çok olmasından gelmektedir (Say, 2018). 2012 yılından bu yana geliştirilen ađlar ezberleme problemi dâhil birçok engeli aşmıştır.

Özellikle de veri miktarının artışına bağlı olarak modeller verinin birçok detayını öğrenmekte, böylelikle klasik makine öğrenme yöntemlerine göre daha zorlu problemlerin üstesinden gelebilmektedir.

Google Translate'in 2016 yılındaki şaşırtıcı başarısı, "cümle tabanlı istatistiksel çeviri"den yapay sinir ağlarına dayalı bir yöntemle geçmesinde yatmaktadır. Google Çeviri'nin kullandığı sinir ağı, Google'ın eriştiği büyük miktardaki veriden doğru şekilde eşleşen çeviri cümleleri çiftleriyle eğitilmiştir. Çeviri işlemi, kaynak dilin vektör uzayında kelime vektörünün ve hedef dilin vektör uzayında kaynak dil kelime vektörüne en çok benzeyen kelime vektörünün bulunmasından oluşur. Google'ın hayata geçirdiği bu yöntemin bir diğer yenilikçi yönü ise ağı her dil çifti için ayrı ayrı eğitmek yerine "sıfır-atış çeviriler" adı verilen örneksiz öğrenme yöntemini de uygulayabilmiş olmasıdır. Hem İngilizce-Japonca hem de İngilizce-Korece çeviri konusunda eğitilmiş bir sinir ağı, daha önce hiç görmediği bir Japonca-Korece kelime çiftini başarılı bir şekilde çevirebilmiştir (Say, 2018). Başka bir deyişle, Google Translate'in başarısının önemli bir yönü, çeviriler arasında anlambilimi aktarmasıdır.

Donanım alanındaki gelişmeler de derin öğrenme yöntemlerinin gelişmesine katkıda bulunmuştur. Derin öğrenme yöntemleri büyük veri gerektiren, bu nedenle de uzun çalışma süreleri gerektiren yöntemlerdir. Grafik İşlem Birimleri<sup>1</sup> günlerce süren eğitim aşamalarının sadece saatler süreceği şekilde kısaltılabilmesi hem derin öğrenme yöntemlerinin geliştirilmesine hem de bu yöntemlerin günlük hayatta kullanılabilmesine yol açmıştır.

Her ne kadar Derin Öğrenme klasik makine öğrenme yöntemlerine göre dikkate değer bir başarı sağlamış olsa da kendinden önceki yöntemlerde de var olan bir problemle hâlâ uğraşmaktadır: Veri seti!

Geleneksel makine öğrenmesi yöntemlerinde olduğu gibi derin öğrenme için de eğitim verileri çok önemlidir. Sinir ağlarının eğitiminde kullanılan verilerin çeşitliliği ve etiketi

---

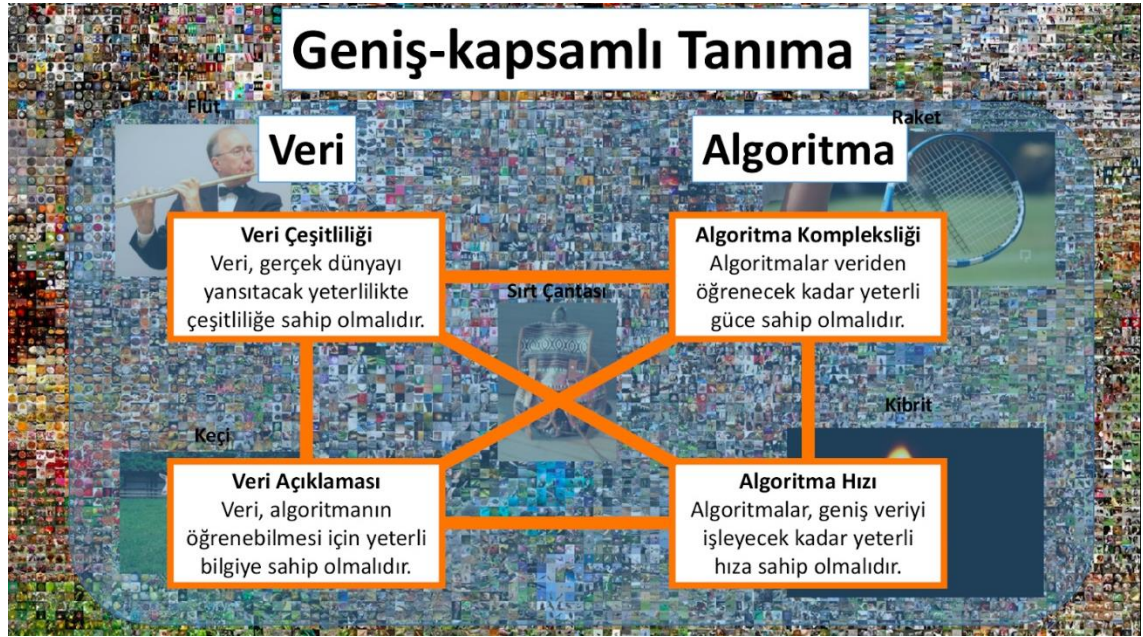
<sup>1</sup> GPU

ve/veya tanımı, o sinir ağının performansını etkilemektedir. Bu nedenle, derin öğrenme sürecinde veri setinin hazırlanması kritik bir adımdır.

Geniş kapsamlı tanıma yapılabilmesi için veri setinin iki önemli özelliğe sahip olması gerekmektedir:

- **Veri Çeşitliliği:** Verinin gerçek dünyayı temsil edecek yeterlilikte çeşitliliğe sahip olması beklenir.
- **Veri Açıklaması:** Modelin iyi eğitilebilmesi için verinin yeterli bilgiye sahip olması beklenir.

Bu 2 kriterin özenli bir şekilde hazırlanması derin modellerin eğitiminde önem arz etmektedir. Bunu sağlamak için de çoğu zaman geniş veri setlerine (tanınması/erişilmesi istenen içeriğin örnek sayısının nicelik olarak çok olması) ve bu veri setlerini tanımlayacak uzmanlara (veri setinin nitelikli olmasına) ihtiyaç duyulmaktadır. İşte bu sebeplerden ötürü son zamanlarda görsel verinin sınıf ve sınıf özellikleri verisinin semantik transferi kullanılarak yapılan çalışmalar ağırlık kazanmıştır.



Şekil 1.2 Bilgisayarlı görü yöntemlerinde geniş kapsamlı tanıma parametreleri

Son yıllarda birçok sorunun çözümü için farklı veri setleri hazırlanmış ve araştırmacıların kullanımına açılmış olsa da hem içerik hem de tanımlama açısından bu veri setleri hâlâ yeterli değildir. Bunun nedenlerini incelemek gerekirse;

- Verilerin elle etiketlenmesi öznellik sorunu gibi tehlikeli bir olasılığı barındırır. Ayrıca bu işlem aynı zamanda oldukça maliyetli de bir işlemdir.
- Öznellik sorunu olmadığını iddia eden veri setlerinde bu sefer de çeşitlilik sorunu kendini göstermektedir. Pek çok veri seti için gerçek dünyayı temsil edecek yeterlilikte bir çeşitlilik düzeyinden bahsetmek mümkün değildir. Bu veri setleri bazı problemlerle ilgili içerikleri kapsıyor olsa da tam anlamıyla belirli bir probleme özgü içeriğin tamamını içeremezler.
- Veri setlerindeki sınıfların dengesizliği de sıklıkla veri setlerinde karşılaşılan önemli bir problemdir: Bazı sınıflar fazla sayıda veri içerirken, bazı sınıflar ise yeterli miktarda veriye sahip değildir. Bu da ağız eğitimi sırasında ezberleme, yeterince öğrenememe gibi problemlere neden olur. Bu durum ağız bazı sınıfları iyi öğrenirken bazılarını iyi öğrenmemesine neden olur ve yanlış pozitif sonuçların tespit edilmesi sonucunu doğurur.

## 1.1 Çalışmanın Katkısı

Bu zorlukların üstesinden gelmek için, gömülü görüntü bilgilerine yardımcı bilgileri kullanarak görünmeyen sınıfların tanınmasına yönelik yöntemlerin geliştirilmesinde önemli ilerlemeler kaydedilmiştir. Bu yöntemlerden biri de literatürde “Örneksiz Öğrenme” olarak da ifade edilen “Sıfır-Atış Öğrenme” (Zero-Shot Learning) yöntemidir. Halen araştırmacılar için aşılması gereken birçok zorluğu barındıran Sıfır-Atış Öğrenmesi anlamsal aktarım ile görünmeyen sınıfların tespiti/tanınması için geliştirilmiş önemli bir yöntemdir. Bu tezde Sıfır-Atış Öğrenme kullanımına ek olarak, anlamsal ilişkileri güçlendirmek için ontoloji de önerilen yöntemle entegre edilmiştir. Böylelikle derin öğrenme yöntemlerini kullanarak görünmeyen sınıfları tespit etme yeteneğine sahip olan Sıfır-Atış Öğrenme'nin (ZSL) sınıf gömmelerinde ontolojinin anlambilimsel gücünü ekleyerek algılama gücü yüksek bir yöntem geliştirdik.

Buna göre sıfır-atış öğrenmesi kullanılarak daha önceden modele verilmeyen örneklerin tanınması amaçlanmıştır. Veri setindeki sınıf ve sınıf özellikleri verisi ile semantik transfer yapılmış ve görünmeyen (unseen) sınıflara dair tahmin yürütülmektedir. Sağlık alanında çalışılacağı için bu elde edilen verinin özelliklerinin belirlenmesi için DBpedia'daki sağlık verilerinden yararlanılmıştır.

Bu tezde ChestX-ray14 veri seti kullanılmıştır. On dört yaygın torasik patoloji arasında;

- Atelektazi
- Konsolidasyon
- İnfiltrasyon
- Pnömotoraks
- Ödem
- Amfizem
- Fibrozis
- Efüzyon
- Pnömoni
- Plevral Kalınlaşma
- Kardiyomegali
- Nodül
- Kitle
- Fıtık

yer alır.

Başlıca katkılarımız:

- 1) Sıfır-Atış Öğrenme yöntemi kullanarak görünmeyen sınıfları tespit etme/tanıma
- 2) Veri setindeki etiketlerle beraber bu etiketlerin anlamsal karşılıklarının kullanılması
- 3) Ontolojinin yeteneklerini sınıf yerleştirmelerinde kullanmak
- 4) Veri seti dengesiz olsa bile ezberleme sorununun üstesinden gelinmesi
- 5) Sıfır-Atış Öğrenme ve ontoloji yöntemleri daha önce birlikte ChestX-ray 14 veri setinde (birlikte veya ayrı ayrı) şimdiye kadar kullanılmamış

## 2. LİTERATÜR TARAMASI

Bu bölümde, ZSL ve/veya ontoloji kullanan veya performansını artırmak için yöntemler sağlayan araştırmalar ve ilişkili çalışmalar ile ilgili literatür çalışmaları sunulmuştur.

Tez kapsamındaki çalışmalarımızı üç ayrı yayın ile araştırmacıların dikkatine sunduk:

- 1) “Lung Disease Detection on ChestX-Ray 14 Dataset Using Zero-Shot Learning With Ontology” (Soysal & Güzel, An Introduction to Zero-Shot Learning: An Essential Review, 2020)
- 2) “Lung Disease Detection on ChestX-Ray 14 Dataset Using Zero-Shot Learning With Ontology” (Soysal, Guzel, Dikmen, & Bostanci, 2022)
- 3) “Common Thorax Diseases Recognition Using Zero-Shot Learning With Ontology in the Multi-Labeled ChestX-ray14 Data Set” (Soysal, Güzel, Dikmen, & Bostanci, 2023)

ZSL yöntemini öneren/geliştiren çalışmalar literatürde her yıl sıklıkla karşımıza çıkmaktadır. Bu çalışmalarda önerilen yöntemler kendilerinden önceki yöntemleri iyileştirdiğini iddia etmiş olsalar da bu ilerlemenin/gelişmenin yerleşik bir değerlendirme protokolü olmadan ölçülmesi o yöntemi nesnel değerlendirme imkanı vermez (Xian, 2017). Bu tespite dayanarak Xian ve arkadaşları hem değerlendirme protokollerini hem de veri bölmelerini birleştirerek yeni bir kıyaslama yöntemi belirlemişlerdir. Beş veri setinde 10 ZSL yöntemini hem ZSL hem de genelleştirilmiş ZSL ayarları için değerlendirmişlerdir. İstatistiksel anlamlılık ve sağlamlık testleri sağlamışlar ve bu kıyaslamadan elde edilen diğer değerli içgörülerini sunmuşlardır. Bu çalışmada Doğrudan Öznitelik Tahmini (DAP) adını verdikleri yöntemle ilk 1 doğrulukta başarı oranı yaklaşık %22 olmuştur.

Keshari ve arkadaşları (Keshari, 2020) daha önceki çalışmalara göre daha kapsamlı bir değerlendirme yapmışlardır. Mevcut denetimli derin sinir ağı (DNN) algoritmalarının çoğunun performansının eğitim setindeki görünmeyen sınıflar için düştüğü bulgusuna

dayanarak, ZSL ayarlarında iyi performans gösteren ayırt edici bir sınıflandırıcıyı öğrenmek için hem görülen hem de görünmeyen sınıfların *koşullu varyasyon otomatik-kodlayıcı* (Conditional Variation Autoencoder) ile *aşırı tam dağılımının* (Over-complete Distribution) kullanılmasını önerdiler ve yöntemlerini hem ZSL hem de geliştirilmiş ZSL protokolleri kullanarak SUN, CUB ve AWA2 veri setlerinde değerlendirdiler. Ancak veri setlerini görülen ve görünmeyen sınıflarda ayrı ayrı değerlendirmemişlerdir.

Yu ve arkadaşları (Yu, 2020), ZSL için epizod tabanlı etkili bir eğitim çerçevesi sunmuşlardır. Model, her biri ZSL sınıflandırma görevini simüle etmek için tasarlanmış bir dizi bölümde eğitilmiş böylelikle tüm bölümler üzerinde eğitimden geçerek gerçek görünen sınıflar üzerinde iyi bir şekilde genelleşecek olan mimetik görünmeyen sınıfları tahmin etmede topluluk deneyimini aşamalı olarak kazanmıştır. Dört veri seti (AWA1, AWA2, CUB, FLO) üzerinde yapılan kapsamlı deneyler, önerilen modelin geniş marjlarla son teknoloji yaklaşımlardan daha iyi performans gösterdiğini kanıtlamışlardır. Ancak önerdikleri yöntemi tıbbi veri seti üzerinde değerlendirmemişlerdir.

Wang ve arkadaşları (Wang S. a.-H.-P., 2020), ZSL aracılığıyla yeni nesnelere insan etkileşimlerini tanımayı amaçlamıştır. Önceki araştırmacılardan farklı olarak, anlamsal kelime yerleştirmeyi kullanarak görünmeyen nesne kategorilerine izin vermişlerdir. Özellikle insan-nesne etkileşimini algılamak için bir insan-nesne bölgesi öneri ağı tasarlamışlardır. İnsanlarla etkileşime giren nesnelere yerleştirmek için insan görsel ipuçlarından yararlanmak ana konsept olarak değerlendirilmiştir. Yöntemlerini V-COCO ve HICO-DET veri setleri üzerinde değerlendirmişlerdir.

Han ve arkadaşları (Han, 2020), ince taneli nesnelere gereksiz bilgileri azaltmak için geliştirilmiş ZSL için artıklık içermeyen özniteliklerin öğrenilmesini önermişlerdir. Görüntü yerleştirmelerini yeni bir özellik alanına yansıtılmışlar ve ardından istatistiksel bağımlılığı sınırlandırmışlardır. Dört farklı veri seti (AWA1, CUB, FLO, SUN) üzerinde değerlendirdikleri bu yöntemde görsel özniteliklerden ayırt edici verileri kaybetmeden, artık veri içermeyen öznitelik alanındaki ilişkileri koruyarak ve hatta

güçlendirerek bu öznelikleri kaldırmışlardır. Önerilen yöntemi dört farklı veri seti üzerinde değerlendirmişlerdir.

Huynh ve arkadaşları (Huynh, Fine-Grained Generalized Zero-Shot Learning via Dense Attribute-Based Attention, 2020) dikkatini her bir öznelikle en çok ilişkili olan ve öznelik tabanlı özellikler elde eden görüntü bölgelerine odaklayan yoğun öznelik tabanlı bir ilgi yaklaşımı önermişlerdir. Bir görüntünün global özellik vektörünü ilişkili sınıfın anlamsal vektörüyle hizalamak yerine, bir özellik gömme tekniği üzerinde çalışmışlardır. Gerçek sınıfa benzerliği maksimize eden bir görüntüdeki her bir özellik varlığı için bir özellik puanları vektörü hesaplamışlardır. Ayrıca, farklı özellikleri daha iyi yakalamak için özelliklere odaklanma mekanizması kullanarak her bir özellik puanını ayarlamışlardır. Büyük ölçekli DeepFashion, CUB, SUN ve AWA2 veri setleri üzerinde değerlendirilen bu yöntemde eğitim yanlılığını hesaba katmak için görünmeyen sınıfların olasılığını ayarlayan yeni bir kendi kendine kalibrasyon kaybı önermişlerdir. Bu sayede test sırasında görülen sınıflara yönelik önyargı sorununun üstesinden gelmeyi amaçlamışlardır.

Huynh ve arkadaşları (Huynh, A Shared Multi-Attention Framework for Multi-Label Zero-Shot Learning, 2020), çok etiketli ZSL için paylaşılan bir odaklı model geliştirmişlerdir. Bir görüntüdeki birden çok görülen ve görülmeyen etiketi tanımak için bir dikkat mekanizması tasarlamının önemsiz bir görev olmadığını, çünkü görünmeyen etiketlerin yerini belirlemek için bir eğitim sinyali olmadığını ve bir görüntünün olası birçok etiketten yalnızca birkaçını içerdiğini savunmuşlardır. Görünmeyen etiketlerin etiketten bağımsız olarak eğitilmiş bir dizi ortak dikkat arasından seçim yapmasına izin veren yöntemi NUS-WIDE ve büyük ölçekli Open Images veri setleri üzerinde değerlendirmişlerdir. Böylece, herhangi bir eğitim örneğinin olmaması nedeniyle ilgisiz bölgelere dikkat çekebilecek bilinmeyen davranışlara sahip görünmeyen etiketlere dikkat çekilmemiştir.

Sıfır-atış tanıma için hiperbolik bir görsel gömme ağı öneren Liu ve arkadaşları (Liu, 2020) bu ağı anlamsal sınıfların hiyerarşik yapısını düşük boyutlarda koruyabilen hiperbolik uzayda görüntü yerleştirmeleri ile eğitmişlerdir. Sıfır noktalı diğer öğrenme

yöntemlerine nazaran, hiperbolik uzaya yerleştirmenin sınıf hiyerarşisini daha iyi temsil ettiği için ağın daha sağlam olduğunu iddia etmişlerdir. Bu sayede ilgisiz kardeş düğümlerin yanlış anlamalarından kaçındığını savunmuşlardır.

Prasanna ve arkadaşları (N. Lakshmi Prasanna, 2021) bir *Evrişimsel Sinir Ağı* (CNN) kullanarak çok etiketli sınıflandırma problemi üzerinde çalışmış ve yöntemi topladıkları görüntülerden oluşan bir veri setine uygulamışlardır.

Gencer Sümbül ve arkadaşları (G. Sumbul, 2018) yaptıkları çalışmada uzamsal ve spektral çözünürlüğün artışı ile yeni sınıfların ve yeni ayrıntıların ortaya çıktığı tespitinden yola çıkarak hedef sınıfların çeşitliliğinde ve benzerliğinde artış olmasından kaynaklanan tanıma/tespit problemlerini incelenmiştir. Diğer sınıflandırma ve tanıma problemleri ile karşılaştırıldığında bu problemin küçük örneklem büyüklüğü ve sınıf dengesizliği açılarından ayrıştığı değerlendirilmiştir. Geleneksel tanıma ve sınıflandırma çalışmalarına göre daha az sayıda örneğin olması, sınıflar arasındaki veri miktarının dengeli olmaması, sınıflar arası düşük, sınıf içi yüksek değişim, çok çeşitli ve farklılıkları güç algılanan sınıflar, bunların alan uzmanları için dahi zor bir problem olması nedeniyle örneksiz öğrenme üzerinde çalışılmıştır. Yeni yardımcı bilgi kaynakları eğitimde görülmeyen ve görülen sınıflar arasındaki ilişkiyi oluşturmak için kullanılmıştır. Test zamanında ise eğitim örneği bulunmayan yardımcı bilgi kaynaklarından gelen ek bilgiye sahip sınıflar tercih edilmiştir. Sınıflar için yardımcı bilgi kaynağı olarak elle etiketlemiş nitelikler kullanılmıştır. Bu etiketler sınıf isimlerinin hiyerarşik ve metin gösterimlerinden oluşmaktadır. Görüntü gösteriminde ise CNN tercih edilmiş, bu derin evrişimsel sinir ağının farklı boyutlardaki filtre sonuçları değerlendirilmiştir. Sınıfların yardımcı bilgileri ile evrişimsel sinir ağından çıkarılan görüntü öznitelikleri arasında bir uyumluluk fonksiyonu öğrenilmiştir. Nitelik, hiyerarşi ve Word2Vec sonuçlarının ayrı ayrı, ikili ve üçünün beraber incelendiği çalışmada en iyi başarımın bu 3 yardımcı bilgi kaynağının bir arada kullanılması sonucunda elde edildiği görüşmüştür:

- Sadece niteliğin kullanılması sonucu %13,3
- Sadece hiyerarşinin kullanılması sonucu %13,0

- Sadece Word2Vec'in kullanılması sonucu %13,3
- Nitelik ve hiyerarşinin kullanılması sonucu %13,5
- Nitelik ve Word2Vec'in kullanılması sonucu %13,4
- Hiyerarşi ve Word2Vec'in kullanılması sonucu %13,5
- Nitelik, hiyerarşi ve Word2Vec'in kullanılması sonucu %15,2

Berkan Demirel ve arkadaşları (Demirel, Image Captioning with Unseen Objects, 2019) ise ZSL kullanılarak örneği olmayan görüntüler için altyazılama çalışması yapmışlardır. Eğitim sırasında görülmeyen nesnelere içeren test görüntülerinin altyazılarını oluşturabilmeyi hedefleyen, tamamen sıfır atışlı bir öğrenme ortamında görüntü altyazı sorununu hedefleyen yeni ve zorlu bir senaryo oluşturulmuştur. Bilgisayarlı görme ve doğal dil işlemenin kesiştiği alanda yer alan belirli bir görüntünün kısa bir metin özetini oluşturma sorunu olan görüntü altyazılama, hala aktif olarak incelenen sorunlarından biridir. ( $Y = Y_s \cup Y_u$ ) ifadesinde  $Y$  ile gösterilen bütün sınıfların örneklerinin sınırlayıcı kutularını tanıyabilmektir. Yerelleştirmek için görülen sınıfları ifade eden  $Y_s$  tarafından belirtilen, verilen örnekler üzerinde bir algılama modeli öğrenmek sıfır atışlı nesne algılamasında temel amaçtır. Aynı ifadedeki  $Y_u$  görünmeyen sınıfları temsil eder. Bu amaçla, YOLO mimarisi backend olarak kullanılmış ve ZSD problemine uyarlanmıştır. Tahmin fonksiyonunu hücre gömmeleri<sup>1</sup> ve sınıf gömmeleri<sup>2</sup> arasında bir uyumluluk fonksiyonu olarak yeniden tanımlayarak YOLO mimarisi ZSD problemine uyarlanmıştır. Böylece test zamanında yeni test sınıfları sadece sınıf gömmelerine dayanarak tahmin edilebilir. Daha kompakt ve açıklayıcı sınıf gömmeleri elde etmek için kelime uzayındaki sınıfların birbirlerine olan benzerlik vektörü tercih edildiği çalışmada MS-COCO veri seti kullanılmış, ZSD modeli ve ZSD çıktıları üzerinde tanımlanan şablon tabanlı bir altyazı oluşturucudan oluşan bir ZSC yaklaşımı tercih edilmiştir. NBT yöntemi, RNN kullanarak boş kelime yuvalarından oluşan cümle şablonları oluşturulmuş ve tespit edilen sınıf isimleri ile boşluklar doldurulmuştur.

---

<sup>1</sup> Cell Embeddings

<sup>2</sup> Class Embeddings

Literatür incelemesinde şu açık bir şekilde görülmüştür ki, sıfır atış veya örneksiz öğrenme kullanan çalışmalarda farklı yardımcı bilgi kaynakları ve görsel veriler ile bu verilerin arasındaki uyumluluk fonksiyonları incelenmiştir. Rahman ve arkadaşları (Rahman S. a., 2019) benzer sınıfları kümelemek için anlamsal kümeleme kaybını (loss) kullanmış, bir diğer çalışmalarında da (Rahman S. a., 2020) görsel özellikleri ilgili anlambilimle iyi hizalanacak şekilde gömmeleri yeniden şekillendirmişlerdir.

Demirel ve arkadaşları (Demirel, Zero-Shot Object Detection by Hybrid Region Embedding, 2018) görsel ve anlamsal olarak anlamlı kelime vektörlerini birlikte ele alarak hibrid bir yöntem önerir.

Bansal ve arkadaşlarının (Bansal, 2018) önerdiği yaklaşım arka plana duyarlı geliştirilmiş sıfır atış nesne dedektörünü elde etmeye yöneliktir.

Zayıf denetimli öğrenmeye benzer şekilde sıfır atış nesne tespitine alternatif olarak öğrenilen görüntü sınıflandırıcılarından dedektörlere bilgi transferini Hoffman ve arkadaşları (Hoffman, 2014), Redmon ve arkadaşları (Redmon, 2016) önerir. Bu tür yaklaşımlar, tüm ilgi sınıfları için etiketlenmiş eğitim görüntüleri gerektirir ve bu da sıfır çekim altyazısına uygunluğunu önemli ölçüde azaltır.

Rohrbach ve arkadaşları (Rohrbach, 2011) ise yaptıkları çalışmada örneksiz öğrenme paradigmasına daha yakın bir yaklaşımla hiyerarşide yer almayan sınıfların üst sınıflarını eğiten bir yöntem önermişlerdir. Bu sayede nesnelere bu sınıflandırıcıya göre sınıflandırılmıştır. Çalışmada hiyerarşik bilgi kullanılmayan diğer yöntemlerden daha iyi bir başarı oranına ulaşılmıştır.

Her özniteliğin sıfır-atış sınıflandırmada (Zero-Shot Classification) rol almasının beklenmemesi gerektiğini Bin Lui ve arkadaşları (Wu, 2018) savunmuştur. Başka bir ön bilgi türü olan hiyerarşi de sıfır atış sınıflandırmaya yarar sağlar. Görünmeyen sınıflarla ilişkili niteliklerin aranması ve bu ilişkilerin farklılaştırılmasının, nitelik temelli sıfır atış sınıflandırıcılarının performansını artırdığı bu çalışmada gösterilmektedir. Ontolojideki

özelliik açıklamaları sinir ağıının eğitimi sırasında öğrenilir. Bu açıklamalar HSK(HCR) adı verilen Hiyerarşik Sınıflandırma Kurallarıdır. Her özelliğın öngörücüsünün eğitiminin yapılıp yapılmayacağı HSK'da yer alıp almadığına göre kararlaştırılır: Eğer yer almıyorsa, eğitim yapılmaz. Böylelikle görüntülerdeki düşük seviyeli nitelikler sayesinde nesne niteliklerinin tahmin edilmesine olanak sağlayan bir akış sağlanır. Test aşamasına geçildiğinde de nesnenin nitelikleri tahmin edilir. Nesne niteliklerinden aynı zamanda HSK'ların seçiminde ön koşul olarak da faydalanılır. Pekiştirme öğreniminde<sup>1</sup> HSK'leri seçmek için  $\epsilon$ -açgözlü<sup>2</sup> yöntem kullanılır. HSK'ler aynı zamanda nesnelere hiyerarşik sınıflandırmada ön şart olarak da sağlanır. Uyarlanabilir bir şekilde sınıflandırmalardan gelen geri bildirimler kullanılarak MC takviye öğrenme yöntemi ile değer fonksiyonu Q belirlenir. Q'nun güncellenmesiyle birlikte HCR seçimi için  $\epsilon$ -açgözlü yöntem uyarlanabilir şekilde ayarlanır ve optimize edilir. Ek bilgi olarak hiyerarşiden sınıf gömmeleri<sup>3</sup> türetebilir. Hiyerarşik bilgiye sahip olmayan aşağıdaki diğer yöntemlerden daha yüksek sıfır atış sınıflandırma doğruluğu elde ederler.

- AHLE<sup>4</sup> (Zeynep Akata, 2013)
- HAT<sup>5</sup> (Al-Halah, 2015)
- SJE<sup>6</sup> (Akata, 2015)

Li Zhang ve arkadaşlarının (Zhang L. a., 2017) yaptığı çalışmada sıfır atışlı öğrenme (ZSL) için yeni bir derin gömme modeli önerilir. CNN çıkış özelliği alanını gömme alanı olarak kullanır. Böylelikle model, mevcut ZSL modelinden farklılaşır. Önerilen model, birden fazla anlamsal alan kullanma esnekliği sunar ve anlamsal alan bir sinir ağı kullanılarak hesaplandığında, uçtan uca öğrenme yeteneğine sahip olur.

Yanwei Fu ve arkadaşlarının yaptığı çalışmada (Fu, 2017) sıfır atış tanıma alanındaki son gelişmeler incelenmiştir. Çalışmada ilk olarak farklı anlamsal temsil türleri

---

<sup>1</sup> Reinforcement Learning

<sup>2</sup>  $\epsilon$ -greedy

<sup>3</sup> Class Embeddings

<sup>4</sup> Attribute and Hierarchical Label Embedding

<sup>5</sup> Hierarchical Attribute Transfer

<sup>6</sup> Structured Joint Embedding

incelenmiş ve karşılaştırılmıştır. İlerleyen bölümlerde ise sıfır atış öğreniminde kullanılan modeller de incelenmiştir. Daha sonra, sıfır atış tanımının ötesinde, tek atış (one-shot) ve açık set (test örnekleri kaynak veya hedef kategorilerine ait olabilir) tanıma çok önemli iki konu olarak tanımlanmış ve böylece gözden geçirilmiştir. Tartışılan sıfır atış tanıma yöntemlerinin mevcut değerlendirmelerinde bir dizi konu ile sıfır atış tanıma işleminde ortak kullanılan veri setleri gözden geçirilmiştir.

Thomas Deselaers ve arkadaşlarının yaptığı çalışmada (Deselaers, 2011) görsel ve anlamsal kategoriler arasındaki ilişkiler deneysel olarak incelenmiş ve birçok bilgisayarlı görü yaklaşımında kabul edilen bazı varsayımların geçerli olup olmadığı araştırılmıştır. Özellikle, (i) bir kategorideki görsel değişkenliğin anlamsal alanıyla büyüdüğü; (ii) görsel benzerliğin, anlamsal benzerlikle büyüdüğü; (iii) görsel sınıfların anlamsal olarak belirlenmiş sınırlar arasında ayrılabilirdiği gözlenmiştir. Aynı çalışmada ikinci bir katkı olarak, aynı temel seviye kategorisinin örneklerini gösterip göstermediklerini değerlendiren görüntü çiftleri arasında yeni bir mesafe sunulmuştur. ImageNet'teki veriler doğrudan görsel benzerliğin ötesinde ek anlamsal bağlantılar oluşturmak için arka plan verileri olarak kullanılmıştır. Deneysel olarak, görsel mesafeleri geride bıraktığını gösterilmiştir.

Maxime Bucher ve arkadaşlarının yaptığı çalışmada (Bucher, 2016) çok amaçlı metrik öğrenme tekniklerini kullanarak sıfır atış sınıflandırması için yeni bir yaklaşım sunulmuştur. Önerilen formülasyonun, görüntü ve anlamsal yöntemler arasında tutarlılık puanı öğrenmek için kategori düzeyinde herhangi bir temel gerçeğe ihtiyaç duymama, ancak yalnızca zayıf tutarlılık bilgisi gerektirme avantajına sahip olduğu ispatlanmaya çalışılmıştır. Elde edilen puanın, çeşitli görüntü yorumlama görevlerinde çok yönlülük ile kullanılabilir ve dört standart kıyaslamada son teknoloji performansın üstünde performans gösterdiği hipotezi doğrulanmaya çalışılmıştır.

### 3. YÖNTEM

Bu bölümde tez çalışmasında kullanılan yöntemler toplam dört alt bölümde detayları ile yer almaktadır. İlk bölümde yapay zekâ çalışmalarının 20.yy içerisindeki başlangıcı sayılabilecek olan Derin Öğrenme'nin evrimsel olarak beslendiği Algılayıcı Öğrenme Algoritması'nın açıklamasına yer verilmiştir. Sonraki bölümde Derin Öğrenme ve Evrimsel Sinir Ağı'ndan bahsedilmiş ve bu ağın katmanları detaylı bir şekilde aktarılmıştır. Üçüncü bölümde bu tez çalışmasında kullanılan Sıfır Atış Öğrenmesi (bir diğer ifadeyle Örneksiz Öğrenme) yöntemi anlatılmıştır. Son alt bölüm olan dördüncü bölümde ise Ontoloji ve Semantik Web kavramları ile bunların uygulaması olan Ontoloji Mühendisliği'ne yer verilmiştir.

#### 3.1 Algılayıcı Öğrenme Algoritması

Düşünen makineler yapmak insanlığın uzun yıllardır en büyük hayalidir. Üstelik bu hayal sadece son birkaç yüzyılın değil, antik Yunan'dan bu yana tüm düşünürlerin, bilim insanlarının önemli bir gündemi olmuştur (Courville, 2016). Programlama dillerinin ilk ortaya çıkmasının da böyle bir ihtiyacı karşılama amacına sahip olduğunu söylemek zor olmasa gerek. Bugün ise gündelik yaşamımıza baktığımızda bu hayale her geçen gün yaklaştığını söylemek zor olmasa gerek.

19.yy'da programlama dillerinin gelişmesiyle beraber 20.yy'ın ikinci yarısının başında Alan Turing'in çığır açan çalışmaları 1960'lara kadar büyük ses getirmiştir. Genelde Yapay Zeka'nın<sup>1</sup>, özelde ise Derin Öğrenme'nin<sup>2</sup> öncülü diye nitelendirilen Algılayıcı<sup>3</sup> Öğrenme Algoritmasının 1957 yılında Frank Rosenblatt tarafından Cornell Havacılık Laboratuvarı'nda önerilmesiyle bu çalışmaların temelleri hazırlanmaya başlanmıştır.

Tek katmanlı bir yapay sinir ağı olarak geliştirilen bu algoritma ile insan beyni modellenmeye başlanmıştır. Algoritma, ağıdaki ağırlık katsayılarının uygun bir şekilde

---

<sup>1</sup> Artificial Intelligence

<sup>2</sup> Deep Learning

<sup>3</sup> Perceptron

kullanılmasına yardımcı olur. Ağırlık katsayıları optimize edildikten sonra girdi öznitelikleri ile ağırlıklar çarpılır. Bu algoritma doğrusal bir sınıflandırma yapar.

$$x \in R^d, y \in \{-1, 1\} \quad (3.1)$$

Yukarıdaki formülde girdi değerlerini temsil eden  $x$  sınıflandırma için yapılan tahmine destek olmaktadır.  $d$  girdi boyutunu temsil ederken  $y$  bu işlem sonucunda elde edilen etiket verisini temsil etmektedir.

$$S_n = \{(x^{(i)}, y^{(i)}), i = 1, 2, 3, \dots, n\} \quad (3.2)$$

$S$  ile eğitim seti,  $n$  ile de eğitimde kullanılacak örnek sayısı temsil edilmektedir.

$$h: R^d \rightarrow \{-1, 1\}, h(x) = 1 \text{ veya } -1 \quad (3.3)$$

Sınıflandırıcı girdi olarak verilen öznitelikleri yukarıdaki formülde görüleceği üzere haritalandırır. Bu algorithmada kullanılan doğrusal sınıflandırma kullanılır. Bir başka ifadeyle;


$$x^+ = \{x \in R^d : h(x) = 1\} \quad (3.4)$$

$$x^- = \{x \in R^d : h(x) = -1\} \quad (3.5)$$

Sınıflandırıcının tahmin ettiği değer etiket değerine eşit değilse bir hata değeri üretilir. Eğitim sırasındaki eğitim hatası şu şekilde hesaplanır:

$$\varepsilon_n(h) = \frac{1}{n} \sum_{i=1}^n \llbracket h(x^{(i)}) \neq y^{(i)} \rrbracket \quad (3.6)$$

$$h(x^{(i)}) \neq y^{(i)} \rightarrow \begin{cases} 0, & \text{eşit ise} \\ 1, & \text{eşit değilse} \end{cases} \quad (3.7)$$



Şekil 3.1 Algılayıcı Algoritması nöron bağlantısının girdiler ve çıktı arasındaki ilişkisi (Kaynak: Wikipedia)

İşte bu temel adımlar sadece bir katman için yapılırken Derin Öğrenme’de yüzlerce katman için doğrusal olan veya olmayan fonksiyonlarla özneliklerden modelin en iyi öğrenbilmesine olanak sağlayan sınıflandırıcılar elde edilmektedir.

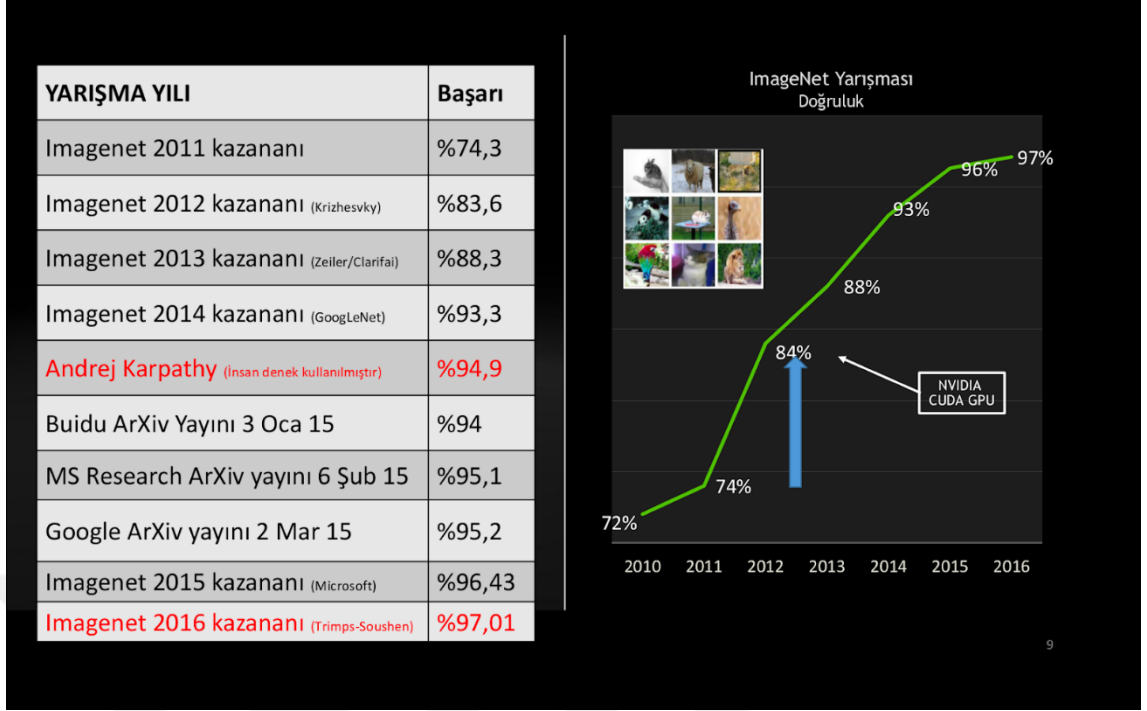
### 3.2 Derin Öğrenme

1980’li yıllara kadar *Yapay Zekâ*’nın durağan dönemi olarak adlandırılabilen düşük yoğunluklu çalışmalar yapıldığını söylemek çok da gerçekten uzak bir tanımlama olmaz. 1980’li yıllardan itibaren *Makine Öğrenmesi*’nin atağa geçmesiyle beraber birçok yöntem literatüre girmiştir.

1970’lerin sonlarında ve 1980’lerin başında, yapay zekâ araştırmaları, algoritmalarından ziyade mantıksal, bilgiye dayalı yaklaşımları kullanmaya odaklanmıştır. Araştırmalar yapay zekâ araştırmacıları ve bilgisayar bilimi tarafından terk edildi. Bu durum yapay zekâ ve makine öğrenimi arasında bir bölünmeye neden oldu. O zamana kadar makine öğrenimi, yapay zekâ için bir eğitim programı olarak kullanılıyordu.

Makine öğrenimi endüstrisi alanında çalışan çok sayıda araştırmacı ve teknisyen sayesinde bu alan ilerleyen yıllarda ayrı bir alan olarak yeniden düzenlendi. Yaklaşık 10 yıllık bir mücadele sonrasında yapay zekâ araştırmalarından miras kalan yaklaşımlardan istatistik ve olasılık teorisinde kullanılan yöntemlere odaklandı. Bu süre zarfında Makine Öğrenmesi endüstrisi sinir ağları üzerine çalışmaktan vazgeçmedi ve bunun sonucu olarak da 1990'larda sinir ağları önemli bir mesafe aldı. Bu başarının çoğu, dijital verilerin sürekli artan kullanılabilirliğinden ve hizmetlerini internet yoluyla paylaşma yeteneğinden yararlanan internet büyümesinin bir sonucuydu.

2010'larda hem Derin Öğrenme üzerine yapılan çalışmaların gözle görülür bir başarıya ulaşması, hem de donanım alanındaki yenilikçi yaklaşımlar bütün dikkatleri bu alana kaydırıldı. 2012 yılında Krizhevsky ve arkadaşlarının yaptığı çalışma ile (Krizhevsky, 2012) başarı oranları dikkate değer bir biçimde yükseldi. Yine yakın dönemde Nvidia firmasının geliştirdiği GPU'lu bilgisayarların üretilmesiyle derin öğrenme yöntemleri işlemci yerine grafik kartları üzerinde çalışmaya başladı. Böylelikle yöntemler işlemcideki çalışma sürelerine göre daha kısa zamanda çalışıp dikkate değer sonuçlar üretmeye başladı. Donanım desteğiyle beraber derin öğrenme yöntemleri yapay zeka alanında dikkatle takip edilir ve üzerine yoğun çalışmalar yapılır bir alan haline geldi. Böylece derin öğrenme yöntemleri geleneksel makine öğrenme yöntemleri yerine daha "modern" yöntemler haline geldi. Şekil 3.2 'de görüleceği üzere 2011 yılında geleneksel makine öğrenmesi yöntemlerine nazaran 2012 yılındaki sıçrama ile derin öğrenme yöntemleri ilerleyen yıllarda önemli başarı oranları elde etmiştir. Daha sonraki yıllarda elde edilen başarı oranlarının insanlar tarafından dahi yakalanamadığı konuşulmaktadır. Bu başarı oranlarının elde edilmesinde donanım alanındaki gelişmelerin de göz ardı edilemeyeceği unutulmamalıdır.




Şekil 3.2 ImageNet yarışmasının 2011 ve 2016 yılları arasındaki en yüksek başarı oranlarına sahip olan yöntemlerinin evrimsel gösterimi


YSA<sup>1</sup>'lardaki nöronlar birbirlerine bir ağırlık vektörü ile bağlıdır. Derin Öğrenme'deki temel yaklaşım bu ağırlık vektörlerinin optimum değerlerini bulmak üzerinedir. Bu yüzden de eğitim setinde olabildiğince farklı örneğin yer alması, nöronların ve bunlar arasındaki ağırlık vektörünün olabildiğince çeşitlenmesi eğitilecek modelin daha fazla örneği temsil etmesine neden olacaktır.

YSA'nın girdi verileri ilk katmanda yer alır. Bu katmanı gizli katmanlar izler. En sonda yer alan katmana ise çıktı katmanı adı verilir. Tek gizli katmanlı ve çok katmanlı sinir ağı yapısı Şekil 3.3'te yer almaktadır. Şekil 3.4'te ise bir yapay nöronun illüstrasyonu yer almaktadır.

<sup>1</sup> Yapay Sinir Ağı



Şekil 3.3 Tek gizli katmanlı ve çok katmanlı sinir ağı yapısı (Kızırcak, 2018)



Şekil 3.4 Bir yapay nöronun illüstrasyonu (SESTILI, 2018)

### 3.2.1 Evrişimli sinir ağları


Bu bölümde Derin Öğrenme ağlarından birisi olan ESA<sup>1</sup>'larda uygulanan işlemler anlatılacaktır.

#### Evrişimsel katman

Girdi değerleri üzerinde özelleştirilebilir maskelerin uygulanması işlemidir. Bu maske filtrelerin boyutları ve içeriği ağına tasarımına göre değişmektedir. Maskenin girdi verisi üzerinde dolaştırılırken attığı adım sayısına göre sonraki katmana aktarılan verinin boyutu değişmektedir.

<sup>1</sup> Evrişimsel Sinir Ağı

Örneğin Şekil 3.5'te görüldüğü üzere  $N \times N$  boyutlu bir matrisin üzerinde  $F \times F$  boyutlu bir maske dolaştırdığımızı varsayalım. Bu evrişimsel işlemin sonucunda elde edeceğimiz ve aktivasyon haritasına aktarılacak matrisin boyutu (3.8)'deki formülde gösterildiği şekilde hesaplanır. Katmandaki işlemlerin özeti Algoritma 1'de verilmiştir.



Şekil 3.5  $N \times N$  boyutlu bir matrisin üzerinde  $F \times F$  boyutlu bir maske ile evrişimsel işlemin uygulanmasının illüstrasyonu

$$\frac{N - F}{\text{adım sayısı}} + 1 \quad (3.8)$$

---

**Algoritma 1** Evrişimsel Katman

---

**Gerekenler:**

- Girdi verisinin genişliği:  $W_1$
- Girdi verisinin genişliği:  $H_1$
- Girdi verisinin genişliği:  $D_1$
- Evrişimsel İşlem Maskesi Boyutu:  $F$
- Adım sayısı:  $S$

- Filtre sayısı:  $K$
- Katman sonunda  $W_2 \times H_2 \times D_2$  boyutunda bir çıktı elde edilir:
 
$$W_2 = (W_1 - F + 2P)/S + 1$$

$$H_2 = (H_1 - F + 2P)/S + 1$$

$$D_2 = K$$
- Parametre paylaşımı ile her bir ağırlık için  $F \cdot F \cdot D_1$  hesaplanır ve toplamda  $(F \cdot F \cdot D_1) \cdot K$
- Çıkış boyutunda,  $(W_2 \times H_2)$  boyutlarının  $d$ . derinlik dilimi,  $d$ . filtresinin giriş boyutu üzerinde  $S$  adımlı bir adımla geçerli bir evrişim gerçekleştirmesinin ve ardından  $d$ . sapması ile dengelenmesinin sonucudur.

### Aktivasyon fonksiyonları

Önceki bölümde, nöronların bir sinir ağının önceki katmanından girdi sinyalleri aldığı detaylarıyla aktarıldı. Bu sinyallerin ağırlıklı toplamı ile nöronun aktivasyon fonksiyonu beslenir, ardından aktivasyon fonksiyonunun çıktısı ağırlık bir sonraki katmanına iletilir.

YSA'da sıklıkla kullanılan ve aşağıda listelenen dört çeşit aktivasyon fonksiyonu vardır:

- **Eşik Değeri Fonksiyonu**<sup>1</sup>: Giriş değerinin belirli bir eşik değerinin üstünde veya altında kalmasına bağlı olarak farklı bir çıkış sinyali hesaplar.
- **Sigmoid Fonksiyonu**: Bu fonksiyon çıktı değeri olarak 0 ile 1 arasında bir değeri aşağıdaki formül (3.9) dâhilinde hesaplar.

$$Sigmoid(x) = 1/(1 + e^{-x}) \quad (3.9)$$


---

<sup>1</sup> Threshold Function

- **Doğrultucu Fonksiyonlar<sup>1</sup>** veya **ReLU**: Derin öğrenme alanında oldukça popülerdir. Giriş değerinin davranışına göre çıktı üretir ve şu şekilde formülize edilebilir:
  - Giriş değeri 0'dan küçükse, fonksiyon 0 verir.
  - Diğer durumlarda, fonksiyonun girdi değerini verir.
- **Hiperbolik Tanjant Fonksiyonları<sup>2</sup>**: Trigonometrik özdeşliğe dayalı tek etkinleştirme işlevidir.

### Havuzlama katmanı

Derin Öğrenme yöntemlerinde kullanılan veri büyük veri sınıfına dahil edilebilir. Bu yüzden de yüksek kaynaklı hesaplama cihazları (GPU<sup>3</sup>) kullanılmaktadır. Havuzlama katmanı sayesinde temsiller daha küçük boyuta çekilebilir ve daha yönetilebilir hale gelir. Bir önceki katmandan iletilen her aktivasyon haritalaması üzerinde bağımsız bir şekilde çalıştırılır. Örneğin Şekil 3.6'te  $224 \times 224 \times 64$  boyutlu bir aktivasyon haritalamasının  $112 \times 112 \times 64$  boyuta indirgenmesi yer almaktadır.



Şekil 3.6 Havuzlama katmanı ile  $224 \times 224 \times 64$  boyutlu bir matrisin  $112 \times 112 \times 64$  boyutlu bir matrise indirgenmesi (Kaynak: Computer Science Wiki)

Bu katmanda indirgeme yapılırken 3 yöntem kullanılabilir:

<sup>1</sup> Rectifier Functions

<sup>2</sup> Hyperbolic Tangent Functions

<sup>3</sup> Graphics Processing Unit

- **Ortalama Havuzlama:** Ortalama değer aktivasyon haritalamasındaki her bir parça için hesaplanır.
- **En Yüksek Havuzlama:** Aktivasyon haritalamasındaki her bir parça için en yüksek değer hesaplanır.
- **Global Havuzlama:** Aktivasyon haritalamasındaki her bir parça için tek değer hesaplanır.

Havuzlama katmanı kullanarak ve indirgenmiş veya havuzlanmış özellik haritaları oluşturarak girdide algılanan özelliklerin özetlenmiş bir versiyonu hazırlanmış olur. Evrişimsel katman tarafından algılanan girdideki özelliğin konumundaki küçük değişiklikler, özelliğin aynı konumda olduğu bir havuzlanmış özellik haritasına neden olacağından kullanışlıdır. Katmandaki işlemlerin özeti Algoritma 2’de verilmiştir.

---

### Algoritma 2 Havuzlama

---

#### Gerekenler:

- Girdi verisinin genişliği:  $W_1$
- Girdi verisinin genişliği:  $H_1$
- Girdi verisinin genişliği:  $D_1$
- Evrişimsel İşlem Maskesi Boyutu:  $F$
- Adım sayısı:  $S$
- Katman sonunda  $W_2 \times H_2 \times D_2$  boyutunda bir çıktı elde edilir:

$$W_2 = (W_1 - F)/S + 1$$

$$H_2 = (H_1 - F)/S + 1$$

$$D_2 = D_1$$

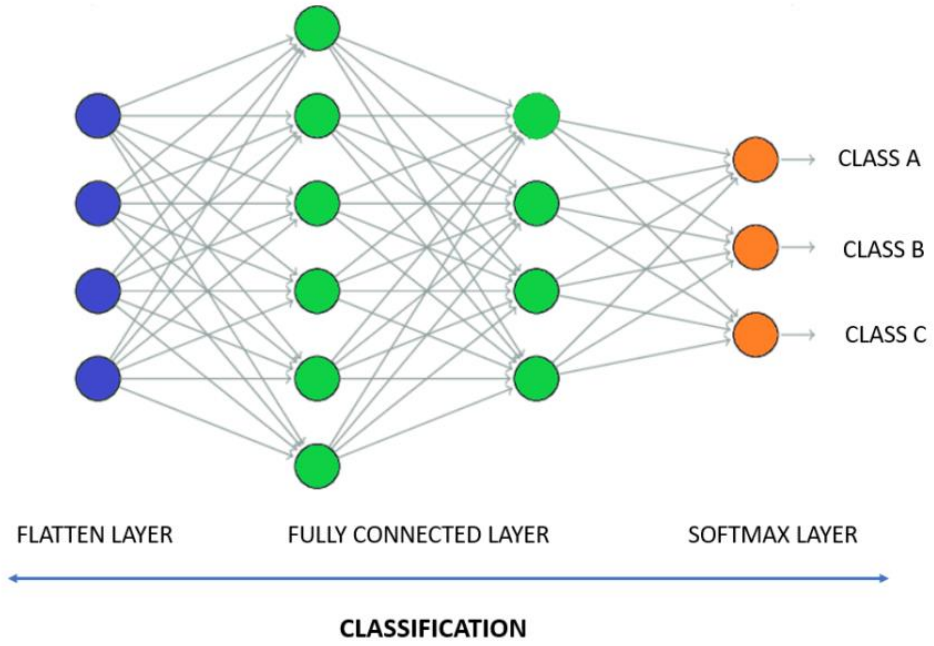
#### Tam bağlantılı katman

YSA’daki giriş katmanında yer alan özellik verisinin tümünün bağlı olduğu, nihai sınıflandırma kararını yönlendiren son katmandır. Gizli katman olarak YSA’da yer alan bu katman *Afin Fonksiyonu* ve *Doğrusal Olmayan Fonksiyonun* kombinasyonudur. Afin Fonksiyonu (3.10)’daki denklemde verilmiştir. Doğrusal olmayan fonksiyonlardan ise Sigmoid, TanH ve ReLu fonksiyonları kullanılır.

$$y = Wx + b \quad (3.10)$$

Tamamen Bağlı Katman, tek boyutlu bir katman olan (1D Katmanı) **Flatten Katmanı**'ndan girdi alır. **Flatten Katmanı**'ndan gelen veriler önce **Afin Fonksiyonu**'na, daha sonra **Doğrusal Olmayan Fonksiyon**'a iletilir. 1 **Afin Fonksiyonu** ve 1 **Doğrusal Olmayan Fonksiyon**'un kombinasyonuna 1 FC<sup>1</sup> veya 1 Gizli Katman<sup>2</sup> denir.

Sınıflandırma modelimize, almak istediğimiz derinliğe göre bu tür birden çok katman ekleyebiliriz. Bunun tamamen eğitim veri setine bağlı olduğu unutulmamalıdır. Son gizli katmandan gelen çıktı, toplam sınıf sayısının son kümesi üzerindeki olasılık dağılımı için Softmax veya Sigmoid işlevine gönderilir.



Şekil 3.7 Tam bağlı katmanın illüstrasyonu (Kaynak: Indiantechwarrior)

<sup>1</sup> Fully Connected

<sup>2</sup> Hidden Layer

### 3.3 Sıfır-Atış öğrenmesi

İster geleneksel makine öğrenmesi ister derin öğrenme yöntemleri kullanılsın, nesne tespit/tanıma/erişim (retrieval) problemlerinde çok sayıda örnek bulmak, bu örneklerle ilişkili sınıf tanımlarını temin etmek zor ve güvenilirliği tartışmalı olmaktadır. Veri setinin oluşturulmasında ve öznelitik vektörlerinin çıkarılmasında uzman kişilere ihtiyaç bulunmaktadır. Çünkü etiketleme işlemi bu işlemi yapan kişinin sosyal, kültürel, entelektüel özellikleriyle doğrudan ilişkili olması nedeniyle öznellik sorunu ile karşı karşıyadır. Bu yüzden problemin çözümünde yanıltıcı olabilmektedir. Her ne kadar fotoğraf etiketleme sonucunda son zamanlarda çok geniş veri setleri oluşmaya başlamış olsa da çoğu problemdeki örnekleri bulmak ciddi bir problem olmaktadır. Diğer yandan bulunacak örneklerin problemin bağlamını zenginleştirmesi de bu çalışma alanının uğraştığı bir diğer zorluktur.

Bu zorlukların üstesinden gelmek üzere veri setindeki örneklerin semantik ilişkilerini kullanarak, daha önceden örneği olmayan sınıfların tanınmasına yönelik çalışmalarda son zamanlarda artış gözlenmektedir. Bu çalışmaların başında da son zamanlarda literatürde “Örneksiz Öğrenme” olarak da adlandırılmaya başlanan “Sıfır-Atış Öğrenmesi” gelmektedir.

Şekil 3.8’de 2017 yılı yaz aylarında Çin’deki Tianshan dağlarında görülen Ili Pika adındaki canlı görülmektedir. Daha önce görmediğimiz ve adını bilmediğimiz bu canlı hakkında fotoğrafa bakarak fikir sahibi olabiliriz. Veya Şekil 3.9’un sol tarafında bilgi sahibi olduğumuz at örneğinden yola çıkarak zebranın ne olabileceği hakkında önermede bulunabiliriz. Bu canlı türünü tespit etmek üzerine inşa edilen bir bilgisayarlı görü problemi ile uğraşılıyor olduğumuzu varsayarsak bu canlının farklı görsellerini toparlamak ve bunları etiketlemek gibi bir görev tanımlayarak işe başlayabiliriz. Fakat nesli tükenmek üzere olan bu canlı türünün farklı örneklerini toplamak oldukça zor ve imkansıza yakın bir iştir. Bunun için çok çaba sarfedilmesi gerektiği unutulmamalıdır. Oysaki insan algısı daha önce görmediği bir örnek ile karşılaştığında, daha önce gördüğü benzer örneklerle karşılaştırarak bir fikir sahibi olmayı tercih eder. İşte Sıfır Atış Öğrenmesi de tıpkı insan öğrenmesine benzer şekilde, eğitim aşamasında daha

önce görülmeyen örneklerle ilgili yardımcı bilgileri dikkate alır ve daha önce karşılaşmadığı bir örnek hakkında fikir sahibi olabilir.



Şekil 3.8 Ili Pika fotoğrafı (Kaynak: National Geographic)



Şekil 3.9 At ve zebra örnekleri (Kaynak: analyticsindiamag.com)

Bu yöntemde klasik makine öğrenme yöntemlerinde kullanılan veri setlerine ilave olarak yardımcı bilgiler kullanılır. Literatürde yer alan ve sınıflar için yardımcı bilgi olarak kullanılan öznitelikler şunlardır:


- **Sınıf isimlerinin metin gösterimleri:** Her bir sınıfın metinsel tanımının vektör uzayında ifade edilmiş halidir. Google tarafından geliştirilen Word2Vec modeli sayesinde kelimeler arasındaki mesafeler hesaplanarak semantik ilişki çıkarımı yapılabilir. Çünkü Word2Vec gösteriminde kelimelerin beraber geçme sıklığı dikkate alınarak vektörel bir gösterim hazırlanmıştır.
- **Elle etiketlenmiş nitelikler:** Her bir sınıfın metinsel tanımı yanında o sınıfı oluşturan kavramların özelliklerinin tanımlanmasıdır. Semantik ilişki çıkarımını güçlendiren bu veriler sayesinde örneği olmayan sınıfların tespiti yapılabilmektedir.
- **Hiyerarşik gösterim (Taksonomik hiyerarşi):** “Takson” kelimesi antik Yunan’da düzenleme anlamında kullanılmaktadır. Kelimelerin dikey hiyerarşi içerisinde sınıflandırma bilimi dahilinde gösterilmesidir. Bu sayede semantik ilişki çıkarımı elde edilebilmektedir.

Kullanılan bu 3 yardımcı bilgi ile sınıf gösterimleri birbirlerini destekleyici niteliğe sahip olmaktadır. Sinir ağının öğrenme süreci insan beyninin öğrenme sürecine oldukça benzerdir: Önceden öğrenilen sınıf özellikleriyle semantik ilişkisi olduğu tespit edilen fakat daha önce benzeri görülmemiş örnekler, semantik çıkarım yapılarak tespit edilebilir.

Şekil 3.10’da Sıfır Atış Öğrenmesi aşamalarında hangi verinin dikkate alındığının özeti görülmektedir. Eğitim aşamasında görüntü gömmeleri olarak adlandırılan özniteliklerin yer almadığı ama sınıf gömmeleri olarak ifade edilen yardımcı bilgilerin yer aldığı dikkatlerden kaçmamalıdır. Bu sayede eğitimde daha önce örneği olmayan verilerin semantik verilerinin yardımıyla tespit edilebilmesine olanak sağlaması bu yöntemin birçok alanda araştırmacılara ve kullanıcılara sağlayacağı olanak göz ardı edilmemelidir. Yöntemin sağladığı bu avantajdan faydalanabilmek için Şekil 3.11’de sunulduğu gibi görüntü ve sınıf (etiket) verilerinin haritalandırmalarının yapılması gerekmektedir.

CLASSES		Image Embedding	Class Embedding
TRAINING	A	✓	✓
	B	✓	✓
	C	✓	✓
	D	✓	✓
	E	✓	✓
ZERO SHOT	F	✗	✓
	G	✗	✓
	H	✗	✓

Şekil 3.10 Sıfır Atış Öğrenmesinde görüntü ve sınıf gömmelerinin kullanımı



Şekil 3.11 Sıfır Atış Öğrenmesinde görüntü ve etiket verilerinin haritalandırması (Zeynep Akata, 2013)

### 3.4 Ontoloji

Ontoloji kavramı asıl olarak felsefede kullanılan bir kavram olarak ortaya çıkmıştır (Neches, 1991). Varoluşun özünü ve hedeflerin kompozisyonunu incelemek için ortaya atılan bir felsefe kavramı iken daha sonra yapay zekâ alanındaki araştırmacılar alan bilgisinin modellenmesi için bu kavramı ödünç aldılar. Ontoloji var olan varlığa sistematik bir açıklama sağlar (Gruber, 1993). Studer ve arkadaşları yaptıkları çalışmada (Fensel, 1998) ontolojinin açık, biçimlendirilmiş ölçüt ve yaygın olarak kavramsallaştırılan açıklama olduğunu önerirler. Buradaki temel amaç alandaki bilgiyi yakalamak, alan bilgisinin ortak bir şekilde anlaşılmasını sağlamak, sözlüğün ortak tanınmasını belirlemek ve bu terimler için farklı düzeylerden ve farklı kalıplardan net bir tanım vermektir (Zhang, Zhu, & Huang, 2009).

Veri ve bilgi yönetimi alanında ontoloji, bazı alanlarda ortak bilgiyi tanımlamak ve ifade etmek için kullanılan kavramsal bir modeldir. Ontolojiler basit kelimeler yerine anlamsal varlıklar (kavramlar, kavramların ilişkileri ve örnekler) içerirler, bu sayede anlamsal düzeyde bilgiyi temsil ederler. Varlıklar arasında özel semantik ilişkilerin belirlenmesine ve ayrıca bir bilgi alanı hakkında (zamansal bilgiler dahil) iyi bilenen gerçekleri ve aksiyomları depolamaya izin verirler.

Ontoloji kullanımının getirdiği önemli avantajlardan birisi de geliştiriciler dahil tüm taraflar için kullanılabilir ortak ve tekrar kullanılabilen bir ilişkiler ve kavramlar kümesi sunmasıdır. Nesnelere, nesnelere ait olduğu sınıflar, sınıf özellikleri ve sınıflar arasındaki ilişkilerden oluşan ontolojiler belli bir alandaki bilgiyi formel bir altyapı kullanan bilgi modelleridir. Bu sayede çıkarılabilir motorlarının<sup>1</sup> kullanımıyla yeni özellikler ve ilişkiler elde edilebilmektedir.

Ontolojinin sağladığı bir diğer avantaj da ayrık ontolojilerin bir arada kullanılabilmesidir. Bu sayede daha önceden formalize edilmiş bir başka veri seti kolaylıkla mevcut çalışma alanına dahil edilebilir, bu sayede yeni bir sözlük

---

<sup>1</sup> Inference Engine

oluşturmakla uğraşılmayıp ve/veya o alana dair uzman denetimi gerektirmeyen bir çalışma ortaya koyulabilmektedir. Üstelik asimetrik ilişkilerin de dahil edilmesiyle bir nesneye ait ilişkilerin dışında o nesnenin dışsal olarak tarif edebileceğimiz dolaylı ilişkilerinin de sorgulanabilmesine olanak sağlamaktadır. Bu özelliğiyle ontolojiler bilginin evrenselleşmesine büyük bir katkı sağlamaktadır. Bilginin çıkarımına hizmet etmesiyle de geleneksel ilişkisel veri tabanlarının yeteneklerinin ötesine geçmektedir.

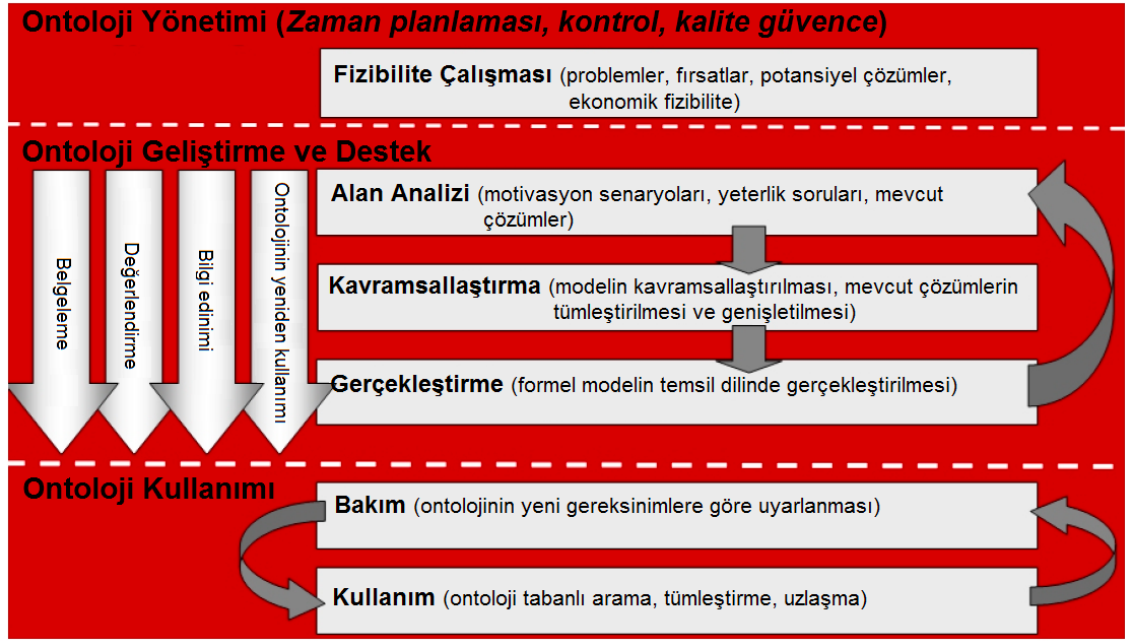
Anlamsal web, ontoloji tanımlama dilleriyle web’de dağıtık olarak sunulan içeriğin, insanların yanı sıra uygulamaların da anlamlandırılabilir olmasını amaçlamaktadır. Özellikle web’de yayınlanan içerikler arasındaki ilişkilerin de ontolojilerle tanımlanabilmesine olanak sağlayan bağlı veri yaklaşımı web’in sorgulanabilir büyük bir veri tabanına dönüşmesini sağlamaktadır.

Ontolojilerin geliştirilmesinden, bakımından sorumlu olan Ontoloji Mühendisliği disiplini ise gereken yöntem, etkinlikler, teknoloji ve araç setini en etkin biçimde bir araya getirmeyi hedefleyen bir mühendislik alanıdır.

Ontoloji geliştirme yöntemleri için kavramsal bir çerçeve Gomez-Perez ve arkadaşlarının çalışması (Corcho, 2004) temelinde Simperl ve arkadaşları (Simperl, 2006) tarafından Şekil 3.12’de gösterildiği biçimde ortaya konulmuştur. Bu çerçeve üç temel faza ayrılmıştır:

- Ontoloji Yönetimi
- Ontoloji Geliştirme
- Destek ve Ontoloji Kullanımı

Her faz ayrıca etkinliklere ayrılmıştır. Çerçevede tanımlanan etkinliklerin bir ontoloji yönteminde bir şekilde karşılanması gerekmektedir.



Şekil 3.12 Ontoloji yönetimi

Bu çalışma sağlık alanındaki problemlere odaklanacağı için evrensel bir sağlık ontolojisi kullanılarak gerçekleştirilmiştir.

### 3.5 Veri/Görüntü artırımı yöntemleri

Derin öğrenmenin üstesinden gelmeye çalıştığı problemlere benzer şekilde tıbbi görüntüleme alanında da en önemli zorluklardan birisi küçük ve sınırlı açıklaması olan veri setleridir. Bu veri setleri ile eğitim yapmak ve başarı oranlarını yükseltmek üzerine hâlâ birçok çalışma yapılmaktadır. Kamuya açık tıbbi veri setleri çevrimiçi olarak araştırmacıların kullanımına sunulmuş olmasına rağmen çoğu veri setinin boyutu hala sınırlıdır ve yalnızca belirli tıbbi sorunların üstesinden gelebilmektedir. Tıbbi verilerin toplanması aşamasında araştırmacıların, hekimlerin ve radyologların iş birliğini yapması gerekmektedir. Bu yüzden de karmaşık ve pahalı bir prosedürdür. Bu yüzden son yıllarda GAN üzerine yapılan çalışmaların artışında gözle görülür bir artış gerçekleşmiştir (Chlap, ve diğerleri, 2021).

Sınıf dengesizliği bir modeli eğitirken sık karşılaşılan diğer bir problemdir. Sınıf dengesizliği, bir veya daha fazla sınıfın veri setinde diğer sınıflara göre daha az veri ile

temsil edilmesi anlamına gelir ve bu da modelin diğer temsil edilen sınıf(lar)a doğru bir önyargıya sahip olmasına yol açabilir. Bu sorunun üstesinden gelebilmek için yetersiz temsil edilen verinin çeşitli yöntemlerle artırılması<sup>1</sup> yaygın olarak kullanılan bir yöntemdir.

Bu sorunu çözmek ve modelin genelleme hatasını azaltmak için bir düzenleme tekniği olarak kabul edilebilecek derin öğrenmede eğitim setinin boyutunu ve çeşitliliğini artırmak için genellikle veri artırma uygulanır.

Eğitim setindeki görüntüleri kullanan veri artırma yöntemi hastaların edinimi ve anatomik çeşitliliğindeki değişikliklerini bu vakalar üzerinde modifikasyon uygulayarak simüle eder. Bu sayede eğitilecek olan model bu ek verilerle öğrenme özelliklerini güçlendirir ve modelin daha geliştirilebilir bir temsiliyete sahip olmasına yol açar. Veri artırımının test aşamasında modelin başarımlı performansını artırması sonucuna yol açması beklenir.

Literatürde sıklıkla kullanılan veri artırma yöntemleri şunlardır:

### **3.5.1 Klasik veri artırım**

Gri tonlamalı görüntüler üzerindeki klasik büyütme teknikleri, öteleme, döndürme, ölçekleme, çevirme ve yamultma gibi çoğunlukla afin dönüşümleri içerir. Veri setlerinin yetersizliği, dengesizliği başta olmak üzere birtakım problemler nedeniyle son dönemde yapılan çalışmalarda sinir ağlarının eğitim sürecini ve performansını iyileştirmek için bu yöntemleri kullanmak, sıklıkla başvurulan bir prosedür haline gelmiştir.

---

<sup>1</sup> Augmentation

## Geometrik dönüşümler

Bu dönüşümler en yaygın olarak ölçekleme, öteleme, döndürme, yansıtma ve yamultma gibi afin veya bazen eğriliği içeren perspektif dönüşümleridir.

## Kırpma

Mevcut görüntü üzerindeki yamaların rastgele seçildiği bir tekniktir.

## Kapatma

Benzer bir kavramdır, tek farkı, bir görüntünün yamalarının artırılmış bir görüntü oluşturmak için görüntüden çıkarılmasıdır.

## Yoğunluk işlemleri

Bu işlem genellikle, görüntünün parlaklığını veya kontrastını değiştirerek mevcut piksellerin/voksellerin değerlerini değiştirmek suretiyle gerçekleştirilir. Gama düzeltme, doğrusal kontrast ve histogram eşitleme, bir görüntünün kontrastını ayarlamak için yaygın olarak kullanılan yöntemlerdir.

## Gürültü enjeksiyonu


Mevcut görüntüye Gauss gürültüsünün uygulanması ile gerçekleştirilir. Tekdüze bir dağılım rastgele örneklenerek değerleri değiştiren tekdüze gürültü uygulanır. Tuz ve biber gürültüsü olarak da bilinen, piksellerin rastgele siyah veya beyaza ayarlandığı gürültü, kullanılabilir.

## Filtreleme

Konvolüsyonel filtreler kullanılır.

## Kombinasyon

2 veya daha fazla orijinal görüntüyü birleştirerek yeni bir görüntü oluşturan bir veri artırma yöntemidir.




Şekil 3.13 Klasik veri büyütme yöntemi ile karaciğer lezyonu üzerinde yapılan manipülasyonların sonucu (Chlap, ve diğerleri, 2021)

### 3.5.2 Deforme veri arttırma teknikleri

Deforme edilebilir veri arttırma teknikleri, temel büyütme teknikleri sonraki modeli genelleştirilebilir kılmak için yeterli deęişkenlik sağlamadığında kullanılabilir.

### 3.5.3 Spline enterpolasyonu

Yeni deęerleri, mevcut veri noktaları arasında tahmin etmek için parçalı bir polinom fonksiyonu kullanır. Örneęin lineer enterpolasyondan daha üstün sonuçlar veren matematiksel bir işlemdir. Deforme olabilen görüntü büyütmeye uygulandığında, bu, yeni görüntü verileri oluşturmak için düzgün deforme olmuş bir görüntüyü hesaplamak için bir yol sağlar.



Şekil 3.14 Deforme veri arttırma uygulaması sonuçları (Chlap, ve dięerleri, 2021)

### 3.5.4 Deforme olabilen görüntü kaydı

Deformasyon tekniklerinin yaygın kullanımı, bir görüntünün (hareketli görüntü olarak anılır) bir başkasıyla (sabit görüntü olarak anılır) daha yakından eşleşmesi için deęiştirildięi görüntü kaydı sürecidir. Literatürde bu yöntemin bir hastanın CT ve MRI gibi farklı görüntüleme yöntemlerini karşılaştırmak için kullanıldığı görülür. Ancak literatürde bir veri arttırma teknięi olarak da kullanıldığı bilinmektedir. Krivov ve

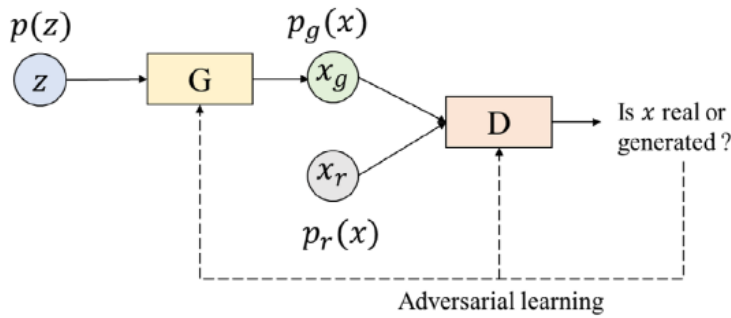
arkadaşları (Krivov, Pisov, & Belyaev, 2018) yaptıkları çalışma ile hasta ve sağlıklı hasta arasında deforme olabilen görüntü kaydı gerçekleştirerek beyin lezyonlarının sağlıklı hasta taramalarına haritalanabileceği bir yöntemi geliştirmişlerdir.

### 3.5.5 Diğer deforme olabilen veri artırma teknikleri

Temel ve elastik deformasyonların yanında, mevcut görüntülerin orijinaline uygulanmasından ziyade eğitim verileri üzerinde uygulanır ve bu görüntülerin konturları artırılır. Bu işlem, belirli bir aralıkta rastgele kontur büyütme üretir ve bir yumuşatma işlevi uygulanır. Arttırımın olmadığı, yalnızca veri arttırmanın olduğu, yalnızca kontur arttırımı veya veri ve kontur arttırımının bir arada olduğu test edilen modeller arasında en güçlü performansı kontur ve veri arttırma kombinasyonun gösterdiği gözlemlenmiştir.

### 3.5.6 Derin öğrenme veri arttırma teknikleri

Görüntülerin temsillerini otomatik olarak öğrenebilir ve modelin genelleştirilebilirliğini arttırmak ve eğitim sırasında fazla uyumlanmayı azaltmak için DL tabanlı veri arttırımı yaklaşımlar gerçekçi görüntüler oluşturabilir. Bu sentetik görüntü oluşturma işlemine genellikle görüntü sentezi denir. Veri arttırma için en yaygın bilinen Derin Öğrenme Ağları GAN ve varyantlarıdır. Bir üretici G'nin ve bir ayırmacı D'nin çekişmeli öğrenmesi yoluyla GAN makul görüntüler üretebilen bir üretici modeller sınıfıdır.



Şekil 3.15 GAN mimarisi

Son zamanlarda literatürde sıklıkla bahsedilen yeni ve karmaşık veri artırma türü yüksek kaliteli örneklerin sentetik veri artırmasıdır. Sistem eğitim sürecini daha da iyileştirmek için daha fazla değişkenlik sağlayan üretken bir model kullanılarak öğrenilen sentetik veri örnekleri veri setini zenginleştirir. Generative Adversarial Networks (GAN'lar) olarak bilinen bu yöntem görüntüleri sentezleyen bir modeli eğitmek için oyun teorisinden ilham alan bu tür umut verici bir yaklaşımdır. (Goodfellow, ve diğerleri, 2014) Model, bir ağın sahte görüntüler ürettiği ve diğer ağın tekrar tekrar gerçek ve sahte görüntüler arasında ayırım yaptığı, çekişmeli bir süreçte eğitilmiş iki ağdan oluşur. (Frid-Adar, ve diğerleri, 2018) Son dönemde birçok medikal görüntüleme uygulamaları GAN'ları uygulamaktadır. (Costa, ve diğerleri, 2017) (Ben-Cohen, Klang, Raskin, Amitai, & Greenspan, 2017)

Mayaan Frid-Adar ve arkadaşları (Frid-Adar, ve diğerleri, 2018) karaciğer lezyonu sınıflandırması problemi için derin öğrenme metodolojisini kullanmışlardır. Son yıllarda birçok tıbbi görüntüleme çalışması, CNN'leri uygulamış ve çok çeşitli tıbbi görevler için oldukça iyi sonuçlar almışlardır. Karaciğer lezyonu sınıflandırması için önerdikleri yöntem, CNN ile GAN kullanarak sentetik karaciğer lezyonu üretimini birleştirmeye dayanmaktadır. Bu tez çalışmasında da Mayaan Frid-Adar ve arkadaşlarının önerdiği karaciğer lezyonu için GAN tabanlı sentetik medikal görüntü artırımı yöntemi kullanılmıştır.

Doğruluk oranlarını yükseltmek için literatürde sıklıkla kullanılan Veri Artırımı<sup>1</sup> yöntemi de test edilmiştir.

---

<sup>1</sup> Data Augmentation

## 4. VERİ SETLERİ

Bu bölümde çalışmada kullanılan veri setlerinin detaylı açıklaması yer almaktadır. Çalışmada görsel veri seti ve bu verinin sınıf tanımları için ChestX-ray14, bu veri setinin sınıf tanımlarının özellikleri için de DBpedia'daki karşılıkları kullanılmıştır. Wikipedia'daki verilerin yapılandırılmış içeriğini sunan DBpedia verilerinin tasarımında ontoloji yöntemleri kullanılmıştır. Buradaki veriler basit bir tarayıcı<sup>1</sup> ile çekilmiştir.

### 4.1 ChestX-ray14

ChestX-ray14 veri seti 30,805 tekil hastadan alınan 112,120 akciğer ön yüzey görüntüsünden oluşmaktadır. 2017 yılında Xiaosong Wang ve arkadaşlarının yaptığı bir çalışma (Wang, ve diğerleri, 2017) ile 8 farklı akciğer hastalığını barındıran ChestX-ray8 veri seti yayınlanmıştır. İlerleyen yıllarda bu çalışma genişletilmiş ve hastalık sayısı 14 (herhangi bir bulgu olmayan örneklerle beraber 15) olmuştur.

Veri setinde yer alan toraks hastalık kategorileri şunlardır:

- Atelektazi
- Konsolidasyon
- İnfiltrasyon
- Pnömotoraks
- Ödem
- Amfizem
- Fibrozis
- Efüzyon
- Pnömoni
- Plevral Kalınlaşma

---

<sup>1</sup> Crawler

- Kardiyomegali
- Nodül
- Kitle
- Fıtık

Bu 14 sınıfın yanında herhangi bir bulguya rastlanmadığı durumların da yer aldığı “No Module” adında 15. Sınıf da yer almaktadır.

Ulusal Sağlık Enstitüsü Klinik Sağlık Merkezi’ndeki<sup>1</sup> PACS<sup>2</sup> veri setinden derlenerek hazırlanan ChestX-ray14 veri seti çoklu etiketle işaretlenen akciğer görüntülerinden oluşmaktadır. Sağlık merkezindeki tüm ön göğüs röntgen verisinin yaklaşık %60’ını oluşturan bu veri seti gerçek hasta popülasyonu dağılımını ve aşılması zor problemlerle gerçek dünya verilerini temsil etme iddiasındadır.


Yukarıda listelenen etiket verileri klinik tanı raporlarından NLP yöntemleri kullanılarak çıkarılmıştır. Etiketlerin birlikte oluşum<sup>3</sup> istatistiği Şekil 4.1 ve Çizelge 4.1’de yer almaktadır.

---

<sup>1</sup> National Institute of Health Clinical Health Center

<sup>2</sup> Picture Archiving and Communication Systems

<sup>3</sup> Co-occurrence



Şekil 4.1 ChestX-ray 14 veri setindeki 14 patoloji sınıfının birlikte oluşum istatistiği. Atelektazi kırmızı, Kardiyomegali turuncu, Efüzyon açık yeşil, İnfiltrasyon turkuaz, Kitle mavi, Nodül koyu mavi, Pnömoni menekşe, Pnömotoraks mor, Konsolidasyon altın, Ödem parlak yeşil, Amfizem yeşil, Fibrozis bahar yeşili, Plevral Kalınlaşma mavi-mor, Fıtık akuamarin.

Çizelge 4.1 ChestX-Ray 14 veri setindeki sınıfların birlikte oluşum istatistiği

	Atelectasis	Cardiomegaly	Effusion	Infiltration	Mass	Nodule	Pneumonia	Pneumothorax	Consolidation	Edema	Emphysema	Fibrosis	Pleural_Thickening	Hernia
Atelectasis	4212	369	3269	3259	727	585	243	772	1222	221	423	220	495	40
Cardiomegal	369	1094	1060	583	99	108	36	48	169	127	44	51	111	7
Effusion	3269	1060	3959	3990	1244	909	253	995	1287	592	359	188	848	21
Infiltration	3259	583	3990	9552	1151	1544	571	943	1220	979	447	345	749	33
Mass	727	99	1244	1151	2138	894	62	424	602	128	212	115	448	25
Nodule	585	108	909	1544	894	2706	63	340	428	131	115	166	410	10
Pneumonia	243	36	253	571	62	63	307	34	114	330	21	11	45	2


Çizelge 4.1 ChestX-Ray 14 veri setindeki sınıfların birlikte oluşum istatistiği (devam)

Pneumothorax	772	48	995	943	424	340	34	2199	222	33	746	80	289	9
Consolidation	1222	169	1287	1220	602	428	114	222	1314	162	103	79	251	4
Edema	221	127	592	979	128	131	330	33	162	634	30	9	64	3
Emphysema	423	44	359	447	212	115	21	746	103	30	895	36	151	4
Fibrosis	220	51	188	345	115	166	11	80	79	9	36	727	176	8
Pleural_Thickening	495	111	848	749	448	410	45	289	251	64	151	176	1127	8
Hernia	40	7	21	33	25	10	2	9	4	3	4	8	8	110

Bu veri setinin bir diğer özelliği çoklu-etikete sahip olmasıdır. Bir görüntü bazı durumlarda sadece bir sınıfa ait olabilirken bazı durumlarda ise sekiz sınıfa birden ait olabilmektedir. Bu yüzden de sınıflar X-Ray görüntülerine göre belirlenmiştir.

Veri setinin temin edildiği kaynakta eğitim ve test verileri için öneri sunulmuştur. Bu öneri yerine toplam veri setinden rastgele veriler seçilmiştir. Toplam veri setinin %80'i eğitim, %20'si test için ayrılmıştır. Görülmeyen sınıflar test veri setinde yer almış, doğrulama için de test veri setindeki eşleşme bilgisi dikkate alınmıştır.

Veri setinin bu çalışma kapsamındaki bir diğer dezavantajı özellik verisinin olmamasıdır. Her ne kadar hastanın yaşı ve cinsiyeti bilgileri verilmiş olsa da bu verilerin ayrıştırıcı bir özelliğinin zayıf olması sebebiyle çalışma kapsamında değerlendirilmemiştir. Tez kapsamında bir hekim desteği olmadığı için de eksik olan özellik verisi DBpedia'dan tamamlanmıştır.



Şekil 4.2 ChestX-ray14 veri setindeki işaretleme örnekleri

## 4.2 DBpedia

DBpedia Derneği, DBpedia ve DBpedia topluluğunu desteklemek için 2014 yılında kurulmuştur. DBpedia, Wikipedia'dan yapılandırılmış bilgiler toplamayı ve oluşturmayı ve bu bilgileri web'de kullanılabilir hale getirmeyi amaçlayan bir topluluktur (Auer, 2007). Bu çalışmalarla kurulduğu tarihten bu yana tüm kullanıcılar için profesyonelleşme yolunda önemli mesafeler katetmiştir.

Topluluk, DBpedia'nın bir yandan yerelleşmesi için katkı sağlarken, diğer yandan ise uluslararası niteliğini güçlendirmek Wikipedia'nın İngilizce olmayan sürümlerinin yayınlanmasını desteklemektedir. Belirli diller, bölgeler ve spesifik alanlarda veri toplulukları oluşturmak için topluluğun sağladığı katkılar dikkate değerdir. Mevcut durumda DBpedia, yaklaşık 20 dil bölümüne sahiptir ve bu veriler Wikipedia'daki dile özgü sürümlerden çıkarılmıştır.

DBpedia veri setinin İngilizce sürümünde:

- 1.5 milyon kişi
- 735 bin mekân
- 123 bin müzik albümü
- 87 bin film
- 19 bin video oyunu
- 241 bin kuruluş
- 251 bin tür
- 6 bin hastalık tanımlanmıştır.

DBpedia'da çıkarılan bilgilerin temsil edilmesi için RDF kullanılır. 2020 yılı itibariyle bu bilgiler 9,5 milyar RDF üçlüsü ile temsil edilir. Bunların 1,3 milyarı Wikipedia'nın İngilizce sürümünden, 5 milyarı ise diğer dil sürümlerinden alınmıştır.

Bu tez kapsamında ChestX-ray14 veri setindeki 14 sınıf etiketinin öznitelikleri DBpedia'dan alınmıştır. Bazı etiketlerin eş anlamlıları tercih edilmiştir. 1258 benzersiz nitelik 836 sınıf için tanımlanmıştır. Bu işlemin ardından ise etiket-özellik matrisi hazırlanmıştır.

ChestX-ray14 veri setindeki 14 sınıftan birisi olan *Effusion* hastalığının DBpedia'daki kaydı Şekil 4.3'te görüntülenmektedir. Bu şekilde görüldüğü üzere kavramın tanımı ve değeri gibi veriler yer almaktadır. Söz konusu kavramın ilişkili olduğu kavramların listesi ise Şekil 4.4'te yer almaktadır. Şekil 4.5'te ise ChestX-ray14 veri setindeki 14

sınıftan bir diğeri olan *Pnömoni* sınıfının DBpedia’da tanımlanan kavramlardan ilişkili olduğu kavramların bir kısmı gösterilmektedir.

The screenshot shows the DBpedia page for 'Effusion'. At the top, there is a navigation bar with the DBpedia logo, 'Browse using', 'Formats', 'Faceted Browser', and 'Sparql Endpoint'. Below this is the title 'About: Effusion' and a subtitle 'An Entity of Type : Thing, from Named Graph : http://dbpedia.org, within Data Space : dbpedia.org'. The main text describes the process of effusion in physics and chemistry. Below the text is a table with two columns: 'Property' and 'Value'. The table contains one row with the property 'dbo:abstract' and a detailed description of effusion.

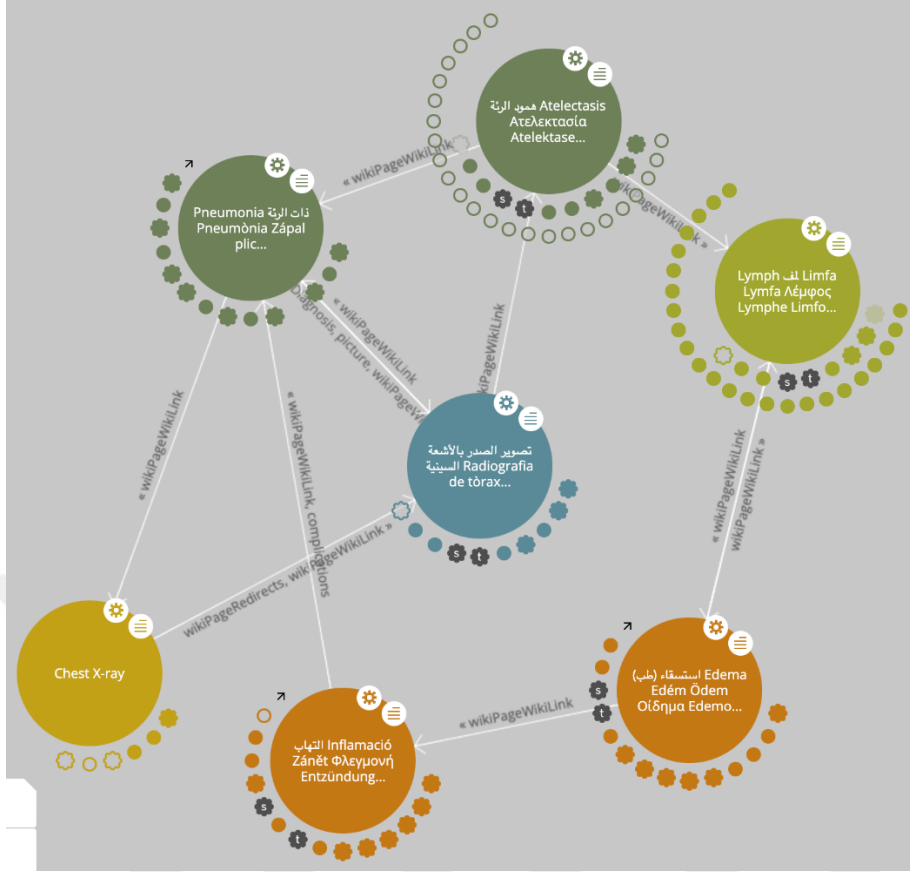
Property	Value
dbo:abstract	<ul style="list-style-type: none"><li>In physics and chemistry, effusion is the process in which a gas escapes from a container through a hole of diameter considerably smaller than the mean free path of the molecules. Such a hole is often described as a pinhole and the escape of the gas is due to the pressure difference between the container and the exterior. Under these conditions, essentially all molecules which arrive at the hole continue and pass through the hole, since collisions between molecules in the region of the hole are negligible. Conversely, when the diameter is larger than the mean free path of the gas, flow obeys the Sampson flow law. In medical terminology, an effusion refers to accumulation of fluid in an anatomic space, usually without loculation. Specific examples include subdural, mastoid, pericardial and pleural effusions. <sup>(en)</sup></li></ul>

Şekil 4.3 Effusion sınıfının DBpedia’deki kaydının ekran görüntüsü (Kaynak: DBpedia)

The screenshot shows the DBpedia page for 'Effusion' with a list of related concepts. The page title is 'dbo:wikiPageWikiLink'. The list includes the following concepts:

- dbo:Locule
- dbo:Sampson\_flow
- dbo:Boltzmann\_constant
- dbo:Graham's\_law
- dbo:Kinetic\_theory\_of\_gases
- dbo:Helium
- dbc:Gases
- dbo:Vapor\_pressure
- dbo:Anatomic\_space
- dbo:Gas\_constant
- dbo:Kinetic\_energy
- dbo:Avogadro\_constant
- dbo:Otitis\_media
- dbo:Oxygen
- dbc:Physical\_chemistry
- dbo:Clausius-Clapeyron\_relation
- dbo:Enthalpy\_of\_sublimation
- dbo:Pleural\_effusion
- dbo:Sublimation\_(phase\_transition)
- dbo:Molar\_mass
- dbo:Pericardial\_effusion
- dbo:Knudsen\_cell
- dbo:Maxwell-Boltzmann\_distribution
- dbo:Mean\_free\_path

Şekil 4.4 Effusion sınıfının DBpedia’deki ilişkili olduğu kavramlar (Kaynak: DBpedia)



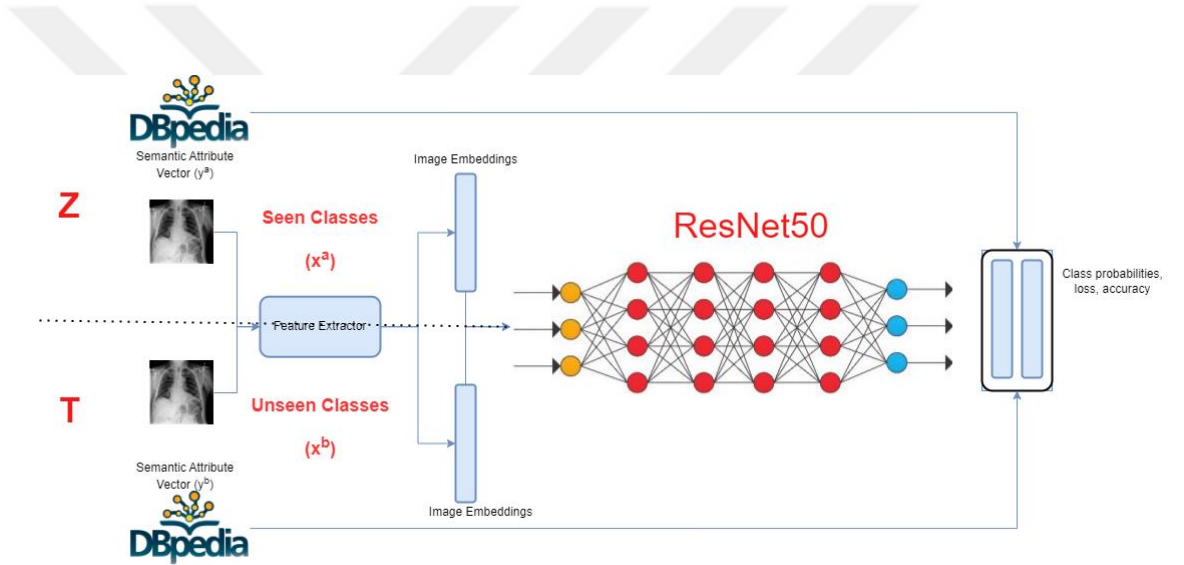
Şekil 4.5 Pneumonia sınıfının DBpedia’da ilişkili olduğu kavramlar

## 5. ÖNERİLEN YÖNTEM

Bu bölümde ilk olarak problem formülasyonu ve notasyonu tanımlanmıştır. Bu alt bölümde veri setindeki sınıflarla ilgili bazı detaylara da yer verilmiştir. Sonraki alt bölümde ise önerilen yöntem detaylı bir şekilde aktarılmıştır.

### 5.1 Problem Formülasyonu ve Gösterimleri

Önerilen yöntemin mimarisi Şekil 5.1’de yer almaktadır. Bu şekilde yer alan görülen ve görülmeyen sınıfların formülasyonunu şu şekilde ifade edebiliriz:



Şekil 5.1 Tez çalışmasında önerilen yöntemin mimarisi

Önerilen yöntemde veri seti iki parçadan oluşmaktadır:

$$Z \cup T \quad (5.1)$$

$Z$  görülen sınıfları temsil ederken  $T$  ise görülmeyen sınıfları temsil etmektedir. Görülen sınıfları şu şekilde detaylandırabiliriz:

$$Z = (x_i^a, y_i^a)_{i=1}^{M_a} \quad (5.2)$$

Burada  $M_a$  sinir ağının eğitiminde kullanılacak görülen sınıftaki toplam görüntü sayısını,  $x_i^a$  ise görülen sınıflardaki i. görseli,  $y_i^a$  bu görsele karşılık gelen etiketi ifade etmektedir.

$$T = (x_j^b, y_j^b)_{j=1}^{P_b} \quad (5.3)$$

Burada  $P_b$ , sinir ağının görünmeyen sınıfındaki tüm görüntüleri,  $x_j^b$  ise görülmeyen sınıflardaki j. görseli,  $y_j^b$  bu görsele karşılık gelen etiketi ifade etmektedir. Görülen ve görülmeyen sınıflarındaki görüntüler kümesi birbirinden farklıdır. Diğer bir deyişle,

$$x^a \cap x^b = \emptyset \quad (5.4)$$

Her  $y \in Y$  etiketine karşılık gelen öznitelik vektörleri de tanımlanmıştır. Bu vektörler bölüm 3.4'te detayları aktarıldığı üzere DBpedia'dan alınmıştır. Etiketlere karşılık gelen DBpedia verileriyle haritalandırma adı verilen eşleştirme işlemi yapılmıştır.

ChestX-ray14 veri setinde çoklu etiketli bir veri setidir. Bu yüzden de bu veri setinin tez kapsamındaki probleme uyarlanması gerekmektedir. Örneğin, Şekil 5.2'deki görüntü toplam sekiz etikete sahiptir :

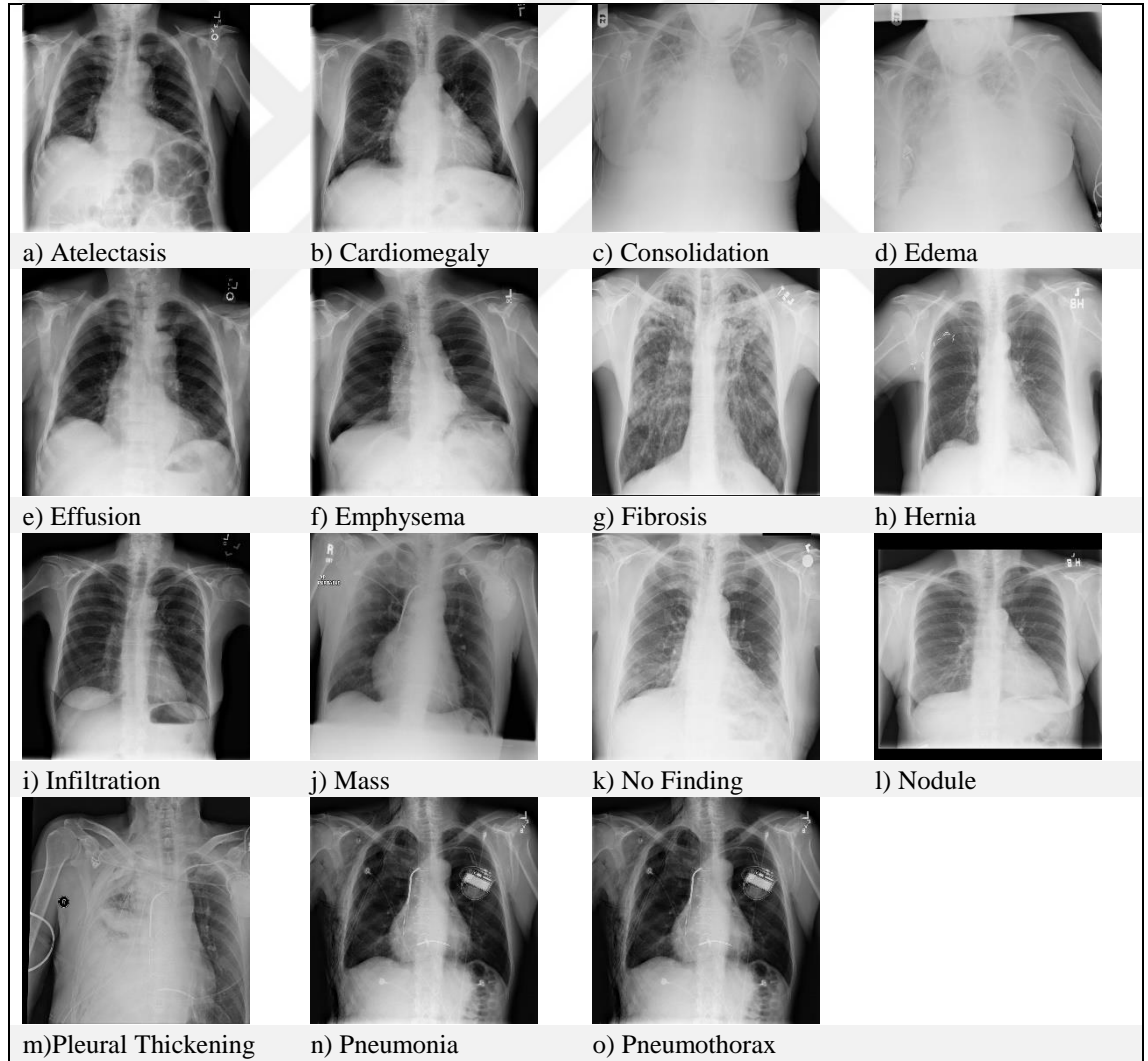
1. Kardiyomegali
2. Nodül
3. Konsolidasyon
4. Kitle
5. Atelektazi
6. Ödem
7. Efüzyon
8. İnfiltrasyon

Bu sebeple aşağıda örneği sunulan görüntü toplam 8 etiketle işaretlenmiştir.



Şekil 5.2 ChestX-ray14 veri setinden çoklu etikete sahip bir örnek

Eğitim veri setinde toplam 669 sınıf, test veri setinde ise 167 sınıf oluşturulmuştur. DBpedia'dan alınan öznitelik vektörünün boyutu 1,258 ve ikili eşleme vektörünün boyutu 836 x 1,258 olmuştur.




Şekil 5.3 ChestX-ray14 veri setindeki 14 yaygın torasik patoloji ve herhangi bir bulgunun tespit edilemedi No Module” sınıflarına birer örnek

## 5.2 Implementasyon

Eđitim ve test veri setleri hazırlandıktan sonra sinir ađlarının eđitimine bařlanmıřtır. Bu tez kapsamında eđitim ařamasında 2 sinir ađı kullanılmıřtır: ResNet50 ve ResNeXt50.

ResNet50 (He, Zhang, Sun, & Sun, 2015), 50 katman derinliđine sahip bir evriřimsel sinir ađıdır<sup>1</sup>. Katmanlar ađık bir řekilde yeniden formüle edilmiřtir. Bu yontemle, artık fonksiyonlar, bařvuru yapmayan fonksiyonları ođrenmek yerine katman girdilerine referans vererek ođrenen artık fonksiyonlar haline gelirler Kısayol bađlantıları, yalnızca kimlik eřlemesi geręekleřtirir ve ıktıları yıđılmıř katmanların ıktılarına eklenir (řekil 5.4). ResNet50'nin tam bađlantılı katmanının varsayılan ıktısı, 2,048 boyutlu tam bađlantılı bir vektordur. Bu alıřmada, her bir oznitelik (1,258) iin ıkıř deđerine tam bađlı bir katman eklenir. 1,258 boyutundaki ıktı, her bir nitelik iin olasılıkları elde etmek iin bir sigmoid aktivasyon fonksiyonundan geirilmiřtir. ok etiketli sınıflandırma yaptığımız bu tez kapsamında, ađı eđitmek iin ikili apraz entropi<sup>2</sup> kaybı kullanılmıřtır.



řekil 5.4 ResNet ođrenmesi temeli (He, Zhang, Sun, & Sun, 2015)

Derin ođrenme üzerine yapılan alıřmalar incelendiđinde ađın eđitiminde hiperparametrelerin olduka kritik bir iřleve sahip olduđunu grlecektir. Bu alıřma kapsamında sinir ađı farklı parametrelerle eđitilmiř ve bu eđitimin sonuları deđerlendirme blmnde sunulmuřtur. Kullanılan parametreler:

<sup>1</sup> Convolutional Neural Network

<sup>2</sup> Binary Cross Entropy

- Batch size = 4 ve 24
- Dropout = 0.25 ve 0.5
- Epoch size = 5'ten 100'e
- Drop-out = 0.0001 ve 0.000001
- Optimizer = Adam
- Döndürme = 5 ve 15.

Ön işleme parametreleri:

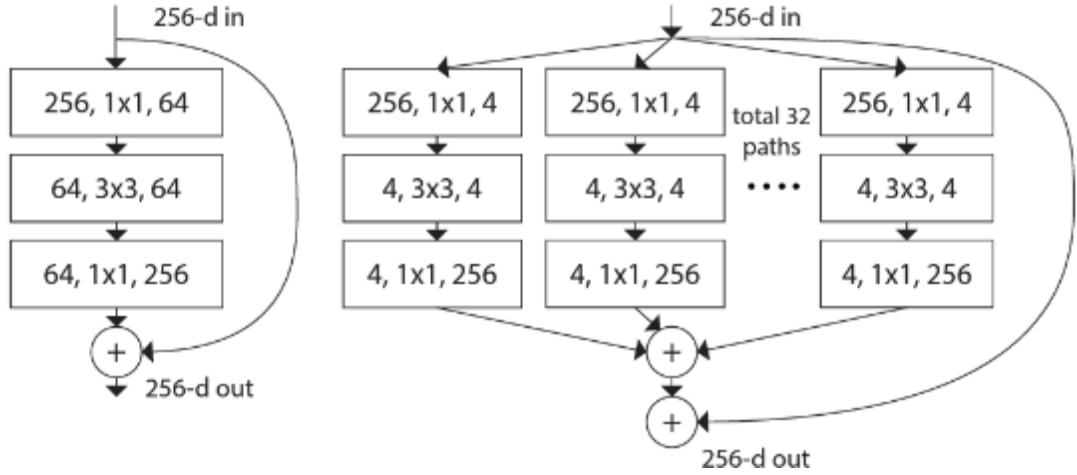
- Yeniden boyutlandırma = 224 ve 448
- Parlaklık = 0.3 ve 0.5
- Kontrast = 0.3 ve 0.5

Histogram eşitleme de yine bir ön işleme adımı olarak bazı parametrelerle beraber uygulanmıştır. Uygulanmadığı sonuçlar da yine değerlendirme bölümünde paylaşılmıştır. Eğitilen ağın özeti Şekil 5.5'te yer almaktadır.

Layer (type)	Output Shape	Param #	Tr. Param #
Conv2d-1	[1, 64, 112, 122]	9,408	9,408
BatchNorm2d-2	[1, 64, 112, 122]	128	128
ReLU-3	[1, 64, 112, 122]	0	0
MaxPool2d-4	[1, 64, 56, 61]	0	0
Bottleneck-5	[1, 256, 56, 61]	75,008	75,008
Bottleneck-6	[1, 256, 56, 61]	70,400	70,400
Bottleneck-7	[1, 256, 56, 61]	70,400	70,400
Bottleneck-8	[1, 512, 28, 31]	379,392	379,392
Bottleneck-9	[1, 512, 28, 31]	280,064	280,064
Bottleneck-10	[1, 512, 28, 31]	280,064	280,064
Bottleneck-11	[1, 512, 28, 31]	280,064	280,064
Bottleneck-12	[1, 1024, 14, 16]	1,512,448	1,512,448
Bottleneck-13	[1, 1024, 14, 16]	1,117,184	1,117,184
Bottleneck-14	[1, 1024, 14, 16]	1,117,184	1,117,184
Bottleneck-15	[1, 1024, 14, 16]	1,117,184	1,117,184
Bottleneck-16	[1, 1024, 14, 16]	1,117,184	1,117,184
Bottleneck-17	[1, 1024, 14, 16]	1,117,184	1,117,184
Bottleneck-18	[1, 2048, 7, 8]	6,039,552	6,039,552
Bottleneck-19	[1, 2048, 7, 8]	4,462,592	4,462,592
Bottleneck-20	[1, 2048, 7, 8]	4,462,592	4,462,592
AdaptiveAvgPool2d-21	[1, 2048, 1, 1]	0	0
BatchNorm1d-22	[1, 2048]	4,096	4,096
ReLU-23	[1, 2048]	0	0
Dropout-24	[1, 2048]	0	0
Linear-25	[1, 1258]	2,577,642	2,577,642

Şekil 5.5 Eğitilen sinir ağının özeti

Önerilen yöntemin doğrulanması amacıyla yöntem ResNet50 sinir ağına yakın olması sebebiyle ResNeXt50 sinir ağı ile de eğitilmiştir. Saining Xie ve arkadaşlarının 2017 yılında yaptığı çalışma (Saining Xie, 2016) ile önerdikleri bu sinir ağı 2016 yılındaki ILSVRC sınıflandırma yarışmasında ikinci olmuştur. ResNet50 sinir ağı ile aynı parametre setleri kullanılarak ResNeXt50 sinir ağıyla da eğitim yapılmış ve bunun da sonuçları yine değerlendirme bölümünde paylaşılmıştır.




Şekil 5.6 ResNet ve ResNeXt blokları

ResNeXt, ResNet ile karşılaştırıldığında, derinlik ve genişlik boyutlarına ek olarak yeni bir boyut olan kardinaliteyi (dönüşümler kümesinin boyutu) önemli bir faktör olarak ortaya koymaktadır.

stage	output	ResNet-50	ResNeXt-50 (32×4d)
conv1	112×112	7×7, 64, stride 2	7×7, 64, stride 2
conv2	56×56	3×3 max pool, stride 2	3×3 max pool, stride 2
		$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128, C=32 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3	28×28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256, C=32 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
conv4	14×14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512, C=32 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$
conv5	7×7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 1024 \\ 3 \times 3, 1024, C=32 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	global average pool 1000-d fc, softmax	global average pool 1000-d fc, softmax
# params.		<b>25.5</b> ×10 <sup>6</sup>	<b>25.0</b> ×10 <sup>6</sup>
FLOPs		<b>4.1</b> ×10 <sup>9</sup>	<b>4.2</b> ×10 <sup>9</sup>

Şekil 5.7 ResNet50 ve ResNeXt50 katmanları



Şekil 5.8 ResNet ve ResNeXt Top-1 hata oranları

## 6. DEĞERLENDİRME

### 6.1 ResNet 50 Sinir Ağı ile Yapılan Çalışmalar

Sinir ağının eğitilmesinin ardından test kümesindeki görülmeyen sınıflara ait her bir görüntü için tahminleme yapılmıştır. Tahminleme işlemi vektörel uzaklık ile yapılmıştır. Uzaklık hesabı için literatürde sıklıkla kullanılan üç farklı yöntem kullanılmıştır: Hamming, Kosinüs ve Öklid. En düşük mesafeli karşılık vektörünün ait olduğu eğitim veri setindeki sınıf, test veri setindeki karşılık gelen sınıf ile eşleştirilmiştir. 24 farklı parametre kümesi ile eğitim yapılmıştır. Bu senaryolarda kullanılan parametrelerin detayları Çizelge 6.1'de gösterilmiştir.

Çizelge 6.1 ResNet50 sinir ağının eğitiminde kullanılan hiperparametrelerin senaryoları

Senaryo	Mesafe	Batch Size	Drop Out	Learning Rate	Epoch	Rotation	Resize	Parlaklık	Contrast	HistEq
1	Euclidean	4	0.25	0.00001	50	15	224	0.3	0.3	X
2	Euclidean	4	0.5	0.00001	50	15	224	0.3	0.3	X
3	Cosine	4	0.25	0.00001	50	15	224	0.3	0.3	X
4	Cosine	4	0.5	0.00001	50	15	224	0.3	0.3	X
5	Hamming	4	0.25	0.00001	50	15	224	0.3	0.3	X
6	Hamming	4	0.5	0.00001	50	15	224	0.3	0.3	X
7	Euclidean	24	0.5	0.00001	50	15	224	0.3	0.3	X
8	Cosine	24	0.5	0.00001	50	15	224	0.3	0.3	X
9	Hamming	24	0.5	0.00001	50	15	224	0.3	0.3	X
10	Euclidean	24	0.5	0.0001	50	15	224	0.3	0.3	X
11	Cosine	24	0.5	0.0001	50	15	224	0.3	0.3	X
12	Hamming	24	0.5	0.0001	50	15	224	0.3	0.3	X
13	Euclidean	24	0.25	0.0001	50	15	224	0.3	0.3	X
14	Cosine	24	0.25	0.0001	50	15	224	0.3	0.3	X
15	Hamming	24	0.25	0.0001	50	15	224	0.3	0.3	X
16	Euclidean	4	0.25	0.0001	50	15	224	0.3	0.3	X
17	Cosine	4	0.25	0.0001	50	15	224	0.3	0.3	X
18	Hamming	4	0.25	0.0001	50	15	224	0.3	0.3	X
19	Euclidean	4	0.75	0.00001	50	15	224	0.3	0.3	X
20	Euclidean	4	0.75	0.00001	50	5	224	0.3	0.3	X
21	Euclidean	4	0.75	0.00001	50	15	448	0.3	0.3	X
22	Euclidean	4	0.75	0.00001	60	15	448	0.3	0.3	X
23	Euclidean	4	0.75	0.00001	100	15	448	0.5	0.5	V
24	Euclidean	4	0.75	0.00001	100	15	448	0.3	0.3	V

Bu 24 senaryo dahilinde ResNet50 ağının eğitimi sonucunda elde edilen doğruluk değerleri sonuçları Çizelge 6.2 ve Çizelge 6.3'te verilmiştir. 24 senaryo ilk başta 50.

epoch'a kadar eğitilmiştir. Bu senaryolar içerisinde en yüksek doğruluk değerlerine sahip olan 22, 23 ve 24. senaryolar ise yeniden eğitilmiş, bu sefer epoch sayısı 100'e çıkarılmıştır. Bu işlem sonucunda doğruluk değerlerinin yükseldiği gözlemlenmiştir.

Doğruluk değeri ise şu şekilde hesaplanmıştır:

$$\frac{T_p}{T_p + T_N} \times 100 \quad (6.1)$$

$T_p$ , modelin test sınıfında yer alan örnekleri doğru bir şekilde tahmin ettiği sonuç anlamına gelir.  $F_p$ , modelin test sınıfında yer alan örnekleri yanlış tahmin ettiği sonuç anlamına gelir.

Çizelge 6.2 ResNet50 sinir ağının eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	5. Epoch	10. Epoch	15. Epoch	20. Epoch	25. Epoch	30. Epoch	35. Epoch	40. Epoch	45. Epoch	50. Epoch
1	13.68	13.67	14.62	15.44	17.12	17.97	18.95	17.51	17.7	17.32
2	13.66	14.13	13.82	14.26	16.67	18.11	17.78	17.54	19.03	18.99
3	9.11	8.73	7.02	7.14	5.99	5.41	7.34	7.45	10.06	7.34
4	8.06	10	6.82	5.29	6.57	7.35	8.04	7.14	6.49	8.07
5	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.73	16.73
6	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.73	16.72	16.72
7	13.66	13.66	13.69	13.67	13.74	13.73	14.71	14.88	15.16	15.87
8	13.06	7.7	6.77	8.11	8.09	6.97	8.28	7.09	7.68	7.92
9	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72
10	14.69	15.12	15.28	15.15	16.02	15.88	15.81	16.61	16.41	15.97
11	9.59	6.6	9.26	7.92	11.49	7.96	7.19	7.81	7.62	9.67
12	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72
13	13.72	14.79	16.19	15.55	15.23	15.8	16.99	16.66	15.92	16.94
14	10.08	10.94	6.19	6.42	8.14	7.68	9.18	7.35	9.75	11.68
15	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72
16	13.66	14.85	15.02	14.73	15.99	16.81	16.57	17.05	15.43	14.02
17	11.98	10.73	11.42	6.77	9.74	10.05	9.72	9.49	10.98	11.05
18	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.74
19	13.66	13.66	14.06	13.87	15.08	16.47	16.74	19.64	18.17	19.44
20	13.66	13.76	13.65	13.65	14.3	17.63	17.05	18.61	16.98	17.7
21	13.66	13.54	14.75	17.89	18.89	19.59	19.06	20.29	20.98	19.99
22	13.66	13.65	13.54	16.36	18.65	18.73	20.46	19.46	18.4	20.12
23	13.66	13.69	13.49	15.81	17.88	20.48	21.2	18.46	19.26	20.06
24	13.66	13.66	13.66	18.12	18.54	19.03	20.83	19.68	19.23	20.66

Çizelge 6.3 ResNet50 sinir ağının 22, 23 ve 24. senaryolar dahilinde eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	55. Epoch	60. Epoch	65. Epoch	70. Epoch	75. Epoch	80. Epoch	85. Epoch	90. Epoch	95. Epoch	100. Epoch
22	21.54	20.57								
23	19.64	19.78	18.74	21.26	20.22	21.04	20.67	21.61	22.97	18.67
24	20.44	21.54	20.62	20.07	19.08	<b>23.25</b>	21.66	20.04	18.93	18.98

En yüksek doğruluk değeri 24. senaryonun 80. epoch'unda elde edilmiştir: %23.25

Literatür bölümünde incelediğimiz çalışmalardaki başarı oranlarını değerlendirdiğimizde bu oranın mevcut çalışmalara nazaran daha iyi olduğu gözlemlenmiştir.

Öte yandan, eğitim çok etiketli bir veri seti ile yapıldığından, bazı sonuçlar tam olarak eşleşme bile çoğu zaman en az bir etiketin kesin referanslara<sup>1</sup> uygun olduğu görülmüştür. Örneğin, test veri setindeki Atelektazi, Konsolidasyon ve Efüzyon etiketlerine sahip bir görüntü, eğitim veri setindeki Efüzyon ve Sızma etiketlerine sahip bir görüntü ile eşleştirilmiştir. Burada tespit edilmesi beklenen 3 etiketten birisi tespit edilmiştir. Bu durum nedeniyle ek bir değerlendirme ihtiyacı ortaya çıkmıştır. Bu da 24 farklı senaryo dahilinde yapılan eğitim neticesinde test sonuçlarından en az bir etiket eşleşmesinin dikkate alınarak kesinlik değerlerinin yeniden hesaplanmasıdır. Bu sonuçlar da Çizelge 6.4'te sunulmuştur. Buradan da görüleceği üzere 23. senaryonun 80. epoch'unda en az 1 eşleşme doğruluk oranı %29.59'a yükselmiştir.

Çizelge 6.4 ResNet50 sinir ağı eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları


Senaryo	En Az 1 Eşleşme Doğruluk Oranları (%)
1	22.98
2	24.75
3	9.39
4	10.1
5	20.65
6	20.64
7	21.79
8	9.64
9	20.64

<sup>1</sup> Ground Truth

Çizelge 6.4 (devam) ResNet50 sinir ağı eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları

Senaryo	En Az 1 Eşleşme Doğruluk Oranları (%)
10	21.85
11	12.17
12	20.64
13	22.76
14	14.27
15	20.64
16	18.91
17	14.26
18	20.66
19	25.28
20	23.13
21	25.49
22	28.18
23	<b>29.59</b>
24	29.35

ResNet50 sinir ağı ile yapılan eğitim sonucunda elde edilen doğruluk oranlarının tümü Şekil 6.1’de grafiksel olarak sunulmuştur.



Şekil 6.1 ResNet50 sinir ağı ile yapılan eğitim sonucunda elde edilen doğruluk oranları

## 6.2 ResNeXt 50 Sinir Ağı ile Yapılan Çalışmalar

Çalışmanın sonuçlarını iyileştirebilmek amacıyla 18 farklı hiperparametre kümesiyle bu sefer ResNeXt50 sinir ağı eğitilmiştir. 18 farklı senaryo Çizelge 6.5'te, bunun sonucunda elde edilen doğruluk oranları Çizelge 6.6 ve Çizelge 6.7'de sunulmuştur.

Çizelge 6.5 ResNeXt50 sinir ağının eğitiminde kullanılan hiperparametrelerin senaryoları

Senaryo	Mesafe	Batch Size	Drop Out	Learning Rate	Epoch
1	Euclidean	4	0,25	0,00001	50
2	Euclidean	4	0,5	0,00001	50
3	Cosine	4	0,25	0,00001	50
4	Cosine	4	0,5	0,00001	50
5	Hamming	4	0,25	0,00001	50
6	Hamming	4	0,5	0,00001	50
7	Euclidean	24	0,5	0,00001	50
8	Cosine	24	0,5	0,00001	50
9	Hamming	24	0,5	0,00001	50
10	Euclidean	24	0,5	0,0001	50
11	Cosine	24	0,5	0,0001	50
12	Hamming	24	0,5	0,0001	50
13	Euclidean	24	0,25	0,0001	50
14	Cosine	24	0,25	0,0001	50
15	Hamming	24	0,25	0,0001	50
16	Euclidean	4	0,25	0,0001	50
17	Cosine	4	0,25	0,0001	50
18	Hamming	4	0,25	0,0001	50

Çizelge 6.6 ResNeXt50 sinir ağının eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	5. Epoch	10. Epoch	15. Epoch	20. Epoch	25. Epoch	30. Epoch	35. Epoch	40. Epoch	45. Epoch	50. Epoch
1	13.75	13.72	14.64	14.55	16.05	15.68	16.74	18.28	17.65	17.82
2	13.66	13.75	13.61	14.52	14.43	15.33	15.3	17.46	18.85	16.67
3	8.99	7.77	6.66	8.05	6.78	9.49	7.81	7.15	7.13	8.38
4	11.68	7.54	9.46	7.13	7.09	8.03	8.78	7.41	8.83	6.07
5	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72
6	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72
7	13.66	13.66	13.66	13.73	13.77	13.77	14.03	13.83	14.19	14.39
8	9.25	10.33	11.69	8.96	10.34	11.79	7.27	8.6	9.37	6.24
9	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72
10	14.65	14.41	14.9	17.4	16.31	15.59	18.26	16.45	17.31	17.3
11	5.03	7.07	6.62	8.59	8.4	5.68	8.58	7.99	1.1	9.71

Çizelge 6.6 ResNeXt50 sinir ağının eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%) (devam)

Senaryo	5. Epoch	10. Epoch	15. Epoch	20. Epoch	25. Epoch	30. Epoch	35. Epoch	40. Epoch	45. Epoch	50. Epoch
12	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72
13	13.74	14.67	14.81	14.66	15.81	15.84	15.9	<b>19.19</b>	18.11	18.37
14	9.44	6.36	6.87	4.11	5.6	7.11	8.77	10.71	11.84	12.3
15	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72
16	13.74	14.95	15.31	15.9	16.1	17.06	15.76	15.96	12.41	13.75
17	9.14	4.99	8.27	8.66	8.65	8.46	8.52	0.07	11.24	10.89
18	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.72	16.74	16.78

Bu sonuçlardan da görüleceği üzere ResNeXt 50 sinir ağı beklenen sonucu vermemiştir.

En yüksek doğruluk oranı 13. senaryonun 40. Epoch'unda elde edilmiştir: %19.19

En az 1 eşleşme doğruluk oranı bu sinir ağı için de hesaplanmış ve Çizelge 6.7'deki doğruluk oranları elde edilmiştir. Buradaki sonuçlara göre de en yüksek doğruluk oranı 13. senaryoda %23.56 olarak hesaplanmıştır.

Çizelge 6.7 ResNeXt50 sinir ağı eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları

Senaryo	En Az 1 Eşleşme Doğruluk Oranları (%)
1	23.06
2	23.36
3	10.63
4	7.95
5	20.64
6	20.64
7	20.43
8	7.77
9	20.64
10	22.65
11	12.04
12	20.64
13	<b>23.56</b>
14	15.65
15	20.64
16	18.35
17	13.7
18	20.67

## 6.3 Veri/Görüntü Artırımı ile Yapılan Çalışmalar

### 6.3.1 Klasik veri artırımı


Tıbbi verilerin toplanması, araştırmacıların ve radyologların iş birliğini gerektiren karmaşık ve pahalı bir prosedürdür. Tıbbi alanda büyük ölçekli açıklamalı veri setleri elde etmek bir sorun olmaya devam etmektedir. Bu nedenle bu alanda çalışma yapan araştırmacılar, veri artırma yöntemlerini kullanarak bu zorluğun üstesinden gelmeye çalışmaktadırlar. En yaygın veri artırma yöntemleri çeviri, döndürme, çevirme ve ölçeklendirme gibi veri seti görüntülerinin basit değişikliklerini içerir. Ağların eğitim sürecini iyileştirmek için yapılan çalışmalarda ilk olarak klasik veri artırmayı tercih etmek sıklıkla kullanılmaktadır. Dolayısıyla bu yöntem artık bilgisayarlı görü alanında standart bir prosedür haline gelmiştir.

Sınıflar arasındaki dengesizliğin doğruluk değerlerini etkileyebileceği öngörüsünden hareket ederek az sayıda örnek barındıran sınıflara veri artırma yöntemi uygulanmış ve sınıflardaki örnek sayısının artması sağlanmıştır. Bu kapsamda örnek sayısı 100'ün altında olan sınıflarda bu işlem uygulanmış, Şekil 6.2'deki sonuçlar ve Çizelge 6.8'de belirtilen sayıda örnek elde edilmiştir. Bu işlem sonucunda veri setindeki toplam örnek sayısı 112,958'den 120,410'a çıkmıştır. Uygulanan veri artırma işlemi [0.3, 1.5] aralığındaki yeniden boyutlandırma işlemidir.

Bu çalışma kapsamında keras<sup>1</sup> kütüphanesinin veri artırma yöntemleri kullanılmıştır.

---

<sup>1</sup> [https://www.tensorflow.org/tutorials/images/data\\_augmentation](https://www.tensorflow.org/tutorials/images/data_augmentation)



Şekil 6.2 Emphysema+Nodule+Pleural\_Thickening+Pneumothorax sınıfına ait 93309 numaralı örnek üzerinde uygulanan [0.3, 1.5] aralığındaki yeniden boyutlandırma sonuçları

Çizelge 6.8 Sınıflardaki ilk örnek sayısı ve veri artırma yöntemi uygulanması sonrası sayısı

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanması sonrasındaki Sayı
Atelectasis+Emphysema+Infiltration+Pneumothorax+Pneumonia	1	10
Emphysema+Nodule+Pleural_Thickening+Pneumothorax	1	10
Atelectasis+Consolidation+Fibrosis+Nodule	2	20
Effusion+Fibrosis+Nodule+Pleural_Thickening	3	30
Effusion+Mass+Pneumonia	3	30
Atelectasis+Consolidation+Effusion+Infiltration+Pleural_Thickening+Pneumothorax	1	10
Cardiomegaly+Effusion+Nodule+Infiltration	1	10
Atelectasis+Effusion+Infiltration+Pleural_Thickening	41	410
Infiltration+Mass+Nodule+Pleural_Thickening	8	80
Effusion+Emphysema+Infiltration+Pneumothorax	12	120
Consolidation+Edema+Effusion+Infiltration	5	50
Atelectasis+Consolidation+Effusion+Infiltration+Pleural_Thickening	6	60
Effusion+Nodule+Pleural_Thickening	31	310
Atelectasis+Consolidation+Fibrosis+Infiltration	1	10
Atelectasis+Cardiomegaly	88	880
Edema+Effusion+Nodule	10	100
Consolidation+Effusion+Infiltration+Mass+Pneumothorax	1	10
Atelectasis+Infiltration+Mass	67	670

Çizelge 6.8 Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemi uygulanması sonrası sayısı

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanması sonrasındaki Sayı
Effusion+Infiltration+Pleural_Thickening+Pneumothorax	3	30
Atelectasis+Consolidation+Effusion+Pneumothorax	7	70
Fibrosis+Pleural_Thickening+Pneumothorax	7	70
Mass+Pleural_Thickening+Pneumothorax	15	150
Edema+Infiltration+Mass+Nodule+Pleural_Thickening	1	10
Consolidation+Effusion+Mass	65	650
Consolidation+Effusion+Infiltration+Mass+Nodule	7	70
Emphysema+Fibrosis+Mass	1	10
Cardiomegaly+Effusion+Mass+Pneumothorax	2	20
Atelectasis+Cardiomegaly+Fibrosis+Mass+Pneumothorax	1	10
Atelectasis+Consolidation+Edema+Effusion+Infiltration+Pneumonia	1	10
Atelectasis+Effusion+Fibrosis+Infiltration	3	30
Atelectasis+Emphysema+Infiltration+Pneumothorax+Pneumonia	1	10
Consolidation+Pneumonia+Pneumothorax	1	10
Cardiomegaly+Edema	35	350
Atelectasis+Cardiomegaly+Infiltration+Pneumothorax	1	10
Atelectasis+Edema+Effusion+Hernia+Infiltration	1	10
Atelectasis+Mass+Nodule+Pneumothorax	1	10
Consolidation+Effusion+Mass+Pneumothorax	4	40
Emphysema+Hernia	1	10
Cardiomegaly+Consolidation+Edema+Infiltration	1	10
Atelectasis+Cardiomegaly+Effusion+Nodule	4	40
Edema+Effusion+Infiltration+Nodule	9	90
Cardiomegaly+Effusion+Infiltration+Mass+Pneumonia	1	10
Emphysema+Pneumonia	5	50
Atelectasis+Effusion+Infiltration+Mass+Pleural_Thickening	4	40
Effusion+Fibrosis+Pleural_Thickening	8	80
Consolidation+Infiltration+Pneumothorax	20	200
Edema+Effusion+Infiltration+Pleural_Thickening	10	100
Effusion+Emphysema+Infiltration+Pneumonia	1	10
Atelectasis+Emphysema+Nodule+Pneumothorax	2	20
Cardiomegaly+Effusion+Emphysema+Infiltration	1	10
Consolidation+Fibrosis+Pneumothorax	2	20
Infiltration+Pleural_Thickening+Pneumothorax	22	220
Cardiomegaly+Pneumonia	8	80
Fibrosis+Mass+Nodule+Pleural_Thickening	2	20
Atelectasis+Fibrosis+Infiltration+Nodule+Pneumothorax	1	10
Atelectasis+Cardiomegaly+Effusion+Infiltration+Mass+Pneumothorax	1	10
Atelectasis+Nodule+Pleural_Thickening	12	120
Emphysema+Fibrosis+Mass+Pleural_Thickening+Pneumothorax	1	10
Consolidation+Fibrosis	24	240
Cardiomegaly+Consolidation+Effusion+Mass+Nodule	3	30
Atelectasis+Cardiomegaly+Effusion+Infiltration+Mass	3	30
Consolidation+Pneumonia+Pneumothorax	1	10
Atelectasis+Cardiomegaly+Edema+Effusion+Infiltration+Pleural_Thickening	1	10

Çizelge 6.8 Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemi uygulanması sonrası sayısı (devam)

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanması sonrasındaki Sayı
Emphysema+Hernia+Pleural_Thickening	1	10
Atelectasis+Infiltration+Mass+Nodule	8	80
Cardiomegaly+Edema+Effusion+Infiltration+Mass+Pleural_Thickening+Pneumonia	1	10
Cardiomegaly+Nodule	22	220
Atelectasis+Effusion+Emphysema+Pleural_Thickening+Pneumothorax	1	10
Effusion+Infiltration+Pneumonia	42	420
Atelectasis+Consolidation+Edema+Infiltration+Pneumonia	4	40
Atelectasis+Consolidation+Effusion+Emphysema+Fibrosis+Mass+Nodule	1	10
Consolidation+Infiltration+Nodule+Pleural_Thickening	2	20
Atelectasis+Consolidation+Edema	6	60
Effusion+Atelectasis	2	20
Consolidation+Emphysema+Infiltration+Nodule	1	10
Infiltration+Mass+Pleural_Thickening	25	250
Cardiomegaly+Consolidation+Effusion+Infiltration+Mass	1	10
Cardiomegaly+Fibrosis	7	70
Consolidation+Edema+Infiltration+Pneumonia	3	30
Consolidation+Effusion+Infiltration+Pneumonia	5	50
Consolidation+Effusion+Mass+Nodule+Pneumothorax	1	10
Atelectasis+Emphysema+Nodule+Pleural_Thickening	2	20
Fibrosis+Pneumothorax	23	230
Atelectasis+Infiltration+Mass+Pneumothorax	5	50
Edema+Mass	18	180
Atelectasis+Edema+Mass	1	10
Nodule+Pneumonia+Mass	1	10
Fibrosis+Infiltration+Mass+Pleural_Thickening	3	30
Effusion+Pleural_Thickening+Pneumonia	1	10
Consolidation+Infiltration+Mass+Nodule+Pleural_Thickening	1	10
Emphysema+Pneumothorax+Pneumonia	1	10
Atelectasis+Cardiomegaly+Consolidation	10	100
Atelectasis+Cardiomegaly+Edema+Effusion+Infiltration+Pleural_Thickening	1	10
Emphysema+Hernia+Pleural_Thickening	1	10
Atelectasis+Consolidation+Effusion+Infiltration+Mass+Pleural_Thickening	7	70
Consolidation+Fibrosis+Mass+Pleural_Thickening	4	40
Consolidation+Infiltration+Mass+Pneumothorax	3	30
Fibrosis+Mass+Pleural_Thickening	3	30
Atelectasis+Emphysema+Fibrosis	1	10
Atelectasis+Consolidation+Infiltration+Pleural_Thickening	1	10
Atelectasis+Consolidation+Effusion+Emphysema+Mass	2	20
Edema+Effusion+Pleural_Thickening+Pneumonia+Pneumothorax	1	10
Atelectasis+Cardiomegaly+Effusion+Fibrosis+Pleural_Thickening	1	10

Çizelge 6.8 Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemi uygulanması sonrası sayısı (devam)

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanması sonrasındaki Sayı
Edema+Mass+Nodule	8	80
Atelectasis+Consolidation+Effusion+Infiltration+Mass+Pleural_Thickening	7	70
Atelectasis+Consolidation+Effusion+Mass+Pleural_Thickening	11	110
Effusion+Infiltration+Mass+Pneumonia	2	20

Veri arttırımı uygulanması sonrasında genişletilen veri seti üzerinde daha önceki testlerde en iyi sonucu veren 23 ve 24. senaryo yeniden çalıştırılmaya başlanmış ve Çizelge 6.9 ile Çizelge 6.10'da verilen sonuçlar elde edilmiştir.

Çizelge 6.9 ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	5. Epoch	10. Epoch	15. Epoch	20. Epoch	25. Epoch	30. Epoch	35. Epoch	40. Epoch	45. Epoch	50. Epoch
23	11.81	11.75	11.91	15.25	15.86	15.05	18.93	16.73	19.01	18.83
24	11.81	11.75	11.91	15.25	15.86	15.5	18.93	16.73	19.1	18.83

Çizelge 6.10 ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	55. Epoch	60. Epoch	65. Epoch	70. Epoch	75. Epoch	80. Epoch	85. Epoch	90. Epoch	95. Epoch	100. Epoch
23	15.82	16.13	17.15	17.74	16.91	18.23	17.88	16.96	18.47	17.29
24	16.13	17.15	17.74	16.91	18.23	17.89	16.96	18.47	17.29	16.13

Önceki adımlarda uygulanan en az bir eşleşme doğruluk hesaplaması veri arttırımı sonrasında da hesaplanmış ve Çizelge 6.11'deki sonuçlar elde edilmiştir.

Çizelge 6.11 ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları

Senaryo	En Az 1 Eşleşme Doğruluk Oranları (%)
23	26.13
24	<b>26.39</b>


Buradan da görüleceği üzere ResNet50 ile orijinal veri setinin eğitimi sonucunda elde edilen %29.59'luk doğruluk payını geçememiştir. Bu yüzden uyguladığımız veri arttırımı yönteminin çalışmamızın sonuçlarını iyileştirmediği tespitini ekleyebiliriz.

### 6.3.2 GAN ile veri arttırımı


Tıbbi görüntüleme alanındaki en büyük zorluklardan birisi de sınırlı veri setleri ve sınırlı miktarda etiketlenmiş örneklerle yapılan eğitimlerdeki başarı oranının yükseltilmesidir. Her ne kadar araştırmacıların kullanımına sunulmuş açık veri setleri varsa da bunların boyutu yeterli düzeyde değildir ve genelde çok spesifik alanlara özgüdür. Tıbbi verilerin toplanması aşamasında araştırmacıların, hekimlerin ve radyologların iş birliğini yapması gerekmektedir. (Frid-Adar, ve diğerleri, 2018). Tıbbi görüntüleme alanındaki sınırlı veri sorunu nedeniyle tıbbi veri setlerini genişletmek için sentetik veri arttırma yöntemleri üzerine yapılan çalışmalar son yıllarda giderek artmaktadır.

Bu tez kapsamında (Radford , Metz , & Chintala, 2016) tarafından önerilen ve veri arttırımında kullanılan GAN mimarisi (Radford , Metz , & Chintala, 2016) Şekil 6.3'te sunulan CNN kullanılmıştır. Burada  $D$  ve  $G$  ile ifade edilen ağların ikisi de CNN'dir. İlk ağ olan  $D$  gerçek ve sahte görselleri ayrıştırıcı görevi üstlenmektedir. Bir örnek  $x$  girdisi alır ve gerçek bir örnek olma olasılığı olan  $D(x)$  çıktısı verir.

İkinci ağ ise üretici ağ adı verilmektedir ve  $G$  ile gösterilmektedir. Üretici,  $D(x)$ 'in yüksek olasılıkla gerçek örnekler olarak kabul edeceği örnekleri sentezler.  $G$ , bilinen basit bir dağılım olan  $p_z$ 'den girdi olarak  $z^{(1)}, z^{(2)}, \dots, z^{(m)}$  alır. Bu genellikle tek biçimli bir dağılımdır ve  $G_{(z)}$ 'yi  $p_g$  dağılımının görüntü uzayına eşler. Üretici ağ  $G$ , girdi olarak tek düze dağılımdan çekilen rastgele 100 sayıdan oluşan bir vektör alır ve  $64 \times 64 \times 1$  boyutunda bir çıktı görüntüsü verir.



Şekil 6.3 Veri arttırmında kullanılan GAN mimarisi (Radford , Metz , & Chintala, 2016)



Şekil 6.4 Veri arttırmında kullanılan GAN mimarisi (Radford , Metz , & Chintala, 2016)

GAN ile yapılan veri arttırımının uygulandığı sınıflarında orijinal veri sayısı ile veri arttırma işlemi sonrasındaki veri sayısı

Çizelge 6.12’de yer almaktadır.

Rakip ağlar, (6.3) denkleminde verilen kayıp fonksiyonunu optimize ederek eğitir:

$$\min_G \min_D \mathbb{E}_{x \sim p_{data}} \log D(x) + \mathbb{E}_{z \sim p_z} [\log(1 - D(G(z)))] \quad (6.3)$$



Çizelge 6.12 Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemi uygulanması sonrası sayısı

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanması Sonrasındaki Sayı
Atelectasis+Cardiomegaly	88	588
Atelectasis+Cardiomegaly+Consolidation	10	510
Atelectasis+Cardiomegaly+Edema+Effusion+Infiltration+Pleural_Thickening	1	501
Atelectasis+Cardiomegaly+Effusion+Fibrosis+Pleural_Thickening	1	501
Atelectasis+Cardiomegaly+Effusion+Infiltration+Mass	3	503
Atelectasis+Cardiomegaly+Effusion+Infiltration+Mass+Pneumothorax	1	501
Atelectasis+Cardiomegaly+Effusion+Nodule	4	504
Atelectasis+Cardiomegaly+Fibrosis+Mass+Pneumothorax	1	501
Atelectasis+Cardiomegaly+Infiltration+Pneumothorax	1	501
Atelectasis+Consolidation+Edema	6	506
Atelectasis+Consolidation+Edema+Effusion+Infiltration+Pneumonia	1	501
Atelectasis+Consolidation+Edema+Infiltration+Pneumonia	4	504
Atelectasis+Consolidation+Effusion+Emphysema+Fibrosis+Mass+Nodule	1	501
Atelectasis+Consolidation+Effusion+Emphysema+Mass	2	502
Atelectasis+Consolidation+Effusion+Infiltration+Mass+Pleural_Thickening	7	507
Atelectasis+Consolidation+Effusion+Infiltration+Pleural_Thickening	6	506
Atelectasis+Consolidation+Effusion+Infiltration+Pleural_Thickening+Pneumothorax	1	501
Atelectasis+Consolidation+Effusion+Mass+Pleural_Thickening	11	511
Atelectasis+Consolidation+Effusion+Pneumothorax	7	507
Atelectasis+Consolidation+Fibrosis+Infiltration	1	501
Atelectasis+Consolidation+Fibrosis+Nodule	2	502
Atelectasis+Consolidation+Infiltration+Pleural_Thickening	1	501
Atelectasis+Edema+Effusion+Hernia+Infiltration	1	501
Atelectasis+Edema+Mass	1	501
Atelectasis+Effusion+Emphysema+Pleural_Thickening+Pneumothorax	1	501
Atelectasis+Effusion+Fibrosis+Infiltration	3	503
Atelectasis+Effusion+Infiltration+Mass+Pleural_Thickening	4	1004
Atelectasis+Effusion+Infiltration+Pleural_Thickening	41	541
Atelectasis+Emphysema+Fibrosis	1	501
Atelectasis+Emphysema+Infiltration+Pneumothorax+Pneumonia	1	501
Atelectasis+Emphysema+Nodule+Pleural_Thickening	2	502
Atelectasis+Emphysema+Nodule+Pneumothorax	2	502
Atelectasis+Fibrosis+Infiltration+Nodule+Pneumothorax	1	501
Atelectasis+Infiltration+Mass	67	567
Atelectasis+Infiltration+Mass+Nodule	8	508
Atelectasis+Infiltration+Mass+Pneumothorax	5	505
Atelectasis+Mass+Nodule+Pneumothorax	1	501
Atelectasis+Nodule+Pleural_Thickening	12	512
Cardiomegaly+Consolidation+Edema+Infiltration	1	501
Cardiomegaly+Consolidation+Effusion+Infiltration+Mass	1	501
Cardiomegaly+Consolidation+Effusion+Mass+Nodule	3	503

Çizelge 6.12 (devam) Sınıflardaki ilk örnek sayısı ve veri artırma yöntemi uygulanması sonrası sayısı

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanması Sonrasındaki Sayı
Cardiomegaly+Edema	35	535
Cardiomegaly+Edema+Effusion+Infiltration+Mass+Pleural_Thickenin g+Pneumonia	1	501
Cardiomegaly+Effusion+Emphysema+Infiltration	1	501
Cardiomegaly+Effusion+Infiltration+Mass+Pneumonia	1	501
Cardiomegaly+Effusion+Mass+Pneumothorax	2	502
Cardiomegaly+Effusion+Nodule+Infiltration	1	501
Cardiomegaly+Fibrosis	7	507
Cardiomegaly+Nodule	22	522
Cardiomegaly+Pneumonia	8	508
Consolidation+Edema+Effusion+Infiltration	5	505
Consolidation+Edema+Infiltration+Pneumonia	3	503
Consolidation+Effusion+Infiltration+Mass+Nodule	7	507
Consolidation+Effusion+Infiltration+Mass+Pneumothorax	1	501
Consolidation+Effusion+Infiltration+Pneumonia	5	505
Consolidation+Effusion+Mass	65	565
Consolidation+Effusion+Mass+Nodule+Pneumothorax	1	501
Consolidation+Effusion+Mass+Pneumothorax	4	504
Consolidation+Emphysema+Infiltration+Nodule	1	501
Consolidation+Fibrosis	24	524
Consolidation+Fibrosis+Mass+Pleural_Thickening	4	504
Consolidation+Fibrosis+Pneumothorax	2	502
Consolidation+Infiltration+Mass+Nodule+Pleural_Thickening	1	501
Consolidation+Infiltration+Mass+Pneumothorax	3	503
Consolidation+Infiltration+Nodule+Pleural_Thickening	2	502
Consolidation+Infiltration+Pneumothorax	20	520
Consolidation+Pneumonia+Pneumothorax	1	501
Edema+Effusion+Infiltration+Nodule	9	509
Edema+Effusion+Infiltration+Pleural_Thickening	10	510
Edema+Effusion+Nodule	10	510
Edema+Effusion+Pleural_Thickening+Pneumonia+Pneumothorax	1	501
Edema+Infiltration+Mass+Nodule+Pleural_Thickening	1	501
Edema+Mass	18	518
Edema+Mass+Nodule	8	508
Effusion+Atelectasis	2	502
Effusion+Emphysema+Infiltration+Pneumonia	1	501
Effusion+Emphysema+Infiltration+Pneumothorax	12	512
Effusion+Fibrosis+Nodule+Pleural_Thickening	3	503
Effusion+Fibrosis+Pleural_Thickening	8	508
Effusion+Infiltration+Mass+Pneumonia	2	502
Effusion+Infiltration+Pleural_Thickening+Pneumothorax	3	503
Effusion+Infiltration+Pneumonia	42	542
Effusion+Mass+Pneumonia	3	503
Effusion+Nodule+Pleural_Thickening	31	531
Effusion+Pleural_Thickening+Pneumonia	1	501
Emphysema+Fibrosis+Mass	1	501
Emphysema+Fibrosis+Mass+Pleural_Thickening+Pneumothorax	1	501
Emphysema+Hernia	1	501

Çizelge 6.12 (devam) Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemi uygulanması sonrası sayısı

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanması Sonrasındaki Sayı
Emphysema+Hernia+Pleural_Thickening	1	501
Emphysema+Nodule+Pleural_Thickening+Pneumothorax	1	501
Emphysema+Pneumonia	5	505
Emphysema+Pneumothorax+Pneumonia	1	501
Fibrosis+Infiltration+Mass+Pleural_Thickening	3	503
Fibrosis+Mass+Nodule+Pleural_Thickening	2	502
Fibrosis+Mass+Pleural_Thickening	3	503
Fibrosis+Pleural_Thickening+Pneumothorax	7	507
Fibrosis+Pneumothorax	23	523
Infiltration+Mass+Nodule+Pleural_Thickening	8	508
Infiltration+Mass+Pleural_Thickening	25	525
Infiltration+Pleural_Thickening+Pneumothorax	22	522
Mass+Pleural_Thickening+Pneumothorax	15	515
Nodule+Pneumonia+Mass	1	501

Çizelge 6.13 ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 5. Epoch ile 50. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	5. Epoch	10. Epoch	15. Epoch	20. Epoch	25. Epoch	30. Epoch	35. Epoch	40. Epoch	45. Epoch	50. Epoch
23	6.12	6.13	6.20	6.33	7.23	6.49	7.31	7.00	7.51	7.13
24	6.17	6.78	6.12	6.09	6.62	6.94	7.07	7.05	6.89	7.67

Çizelge 6.14 ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	55. Epoch	60. Epoch	65. Epoch	70. Epoch	75. Epoch	80. Epoch	85. Epoch	90. Epoch	95. Epoch	100. Epoch
23	7.04	6.96	7.39	7.68	8.09	7.73	7.31	7.89	8.03	8.29
24	7.03	7.65	7.33	7.87	8.01	8.22	7.71	8.24	7.83	7.79

Önceki adımlarda uygulanan en az bir eşleşme doğruluk hesaplaması veri arttırımı sonrasında da hesaplanmış ve Çizelge 6.15'deki sonuçlar elde edilmiştir.

Çizelge 6.15 ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları

Senaryo	En Az 1 Eşleşme Doğruluk Oranları (%)
23	39.45
24	<b>40.68</b>

### 6.3.3 Klasik veri arttırımı ve GAN ile veri arttırımı yöntemlerinin birleştirilmesi

Bu bölümde son olarak 6.3.1 ve 6.3.2 bölümlerinde yapılan arttırma işlemleri sonucunda elde edilen veri setleri birleştirilmiş ve ResNet50 sinir ağı 23 ve 24. Senaryolardaki parametrelerle yeniden çalıştırılmıştır. Sınıfların orijinal veri setindeki örnek sayısı ile iki kümenin birleştirilmesi sonrasındaki durumu Çizelge 6.16'da yer almaktadır.

Çizelge 6.16 Sınıflardaki ilk örnek sayısı ve veri arttırma yöntemlerinin birleştirilmesi sonrası sayısı

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanmaları Sonrasındaki Sayı
Atelectasis+Cardiomegaly	88	1380
Atelectasis+Cardiomegaly+Consolidation	10	600
Atelectasis+Cardiomegaly+Edema+Effusion+Infiltration+Pleural_Thickening	1	510
Atelectasis+Cardiomegaly+Effusion+Fibrosis+Pleural_Thickening	1	510
Atelectasis+Cardiomegaly+Effusion+Infiltration+Mass	3	530
Atelectasis+Cardiomegaly+Effusion+Infiltration+Mass+Pneumothorax	1	510
Atelectasis+Cardiomegaly+Effusion+Nodule	4	540
Atelectasis+Cardiomegaly+Fibrosis+Mass+Pneumothorax	1	510
Atelectasis+Cardiomegaly+Infiltration+Pneumothorax	1	510
Atelectasis+Consolidation+Edema	6	560
Atelectasis+Consolidation+Edema+Effusion+Infiltration+Pneumonia	1	510
Atelectasis+Consolidation+Edema+Infiltration+Pneumonia	4	540
Atelectasis+Consolidation+Effusion+Emphysema+Fibrosis+Mass+Nodule	1	510
Atelectasis+Consolidation+Effusion+Emphysema+Mass	2	520
Atelectasis+Consolidation+Effusion+Infiltration+Mass+Pleural_Thickening	7	570
Atelectasis+Consolidation+Effusion+Infiltration+Pleural_Thickening	6	560
Atelectasis+Consolidation+Effusion+Infiltration+Pleural_Thickening+Pneumothorax	1	510
Atelectasis+Consolidation+Effusion+Mass+Pleural_Thickening	11	610
Atelectasis+Consolidation+Effusion+Pneumothorax	7	570
Atelectasis+Consolidation+Fibrosis+Infiltration	1	510
Atelectasis+Consolidation+Fibrosis+Nodule	2	520
Atelectasis+Consolidation+Infiltration+Pleural_Thickening	1	510
Atelectasis+Edema+Effusion+Hernia+Infiltration	1	510

Çizelge 6.16 Sınıflardaki ilk örnek sayısı ve veri artırma yöntemlerinin birleştirilmesi sonrası sayısı (devam)

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanmaları Sonrasındaki Sayı
Atelectasis+Edema+Mass	1	510
Atelectasis+Effusion+Emphysema+Pleural_Thickening+Pneumothorax	1	510
Atelectasis+Effusion+Fibrosis+Infiltration	3	530
Atelectasis+Effusion+Infiltration+Mass+Pleural_Thickening	4	1040
Atelectasis+Effusion+Infiltration+Pleural_Thickening	41	910
Atelectasis+Emphysema+Fibrosis	1	510
Atelectasis+Emphysema+Infiltration+Pneumothorax+Pneumonia	1	510
Atelectasis+Emphysema+Nodule+Pleural_Thickening	2	520
Atelectasis+Emphysema+Nodule+Pneumothorax	2	520
Atelectasis+Fibrosis+Infiltration+Nodule+Pneumothorax	1	510
Atelectasis+Infiltration+Mass	67	1170
Atelectasis+Infiltration+Mass+Nodule	8	580
Atelectasis+Infiltration+Mass+Pneumothorax	5	550
Atelectasis+Mass+Nodule+Pneumothorax	1	510
Atelectasis+Nodule+Pleural_Thickening	12	620
Cardiomegaly+Consolidation+Edema+Infiltration	1	510
Cardiomegaly+Consolidation+Effusion+Infiltration+Mass	1	510
Cardiomegaly+Consolidation+Effusion+Mass+Nodule	3	530
Cardiomegaly+Edema	35	850
Cardiomegaly+Edema+Effusion+Infiltration+Mass+Pleural_Thickening+Pneumonia	1	510
Cardiomegaly+Effusion+Emphysema+Infiltration	1	510
Cardiomegaly+Effusion+Infiltration+Mass+Pneumonia	1	510
Cardiomegaly+Effusion+Mass+Pneumothorax	2	520
Cardiomegaly+Effusion+Nodule+Infiltration	1	510
Cardiomegaly+Fibrosis	7	570
Cardiomegaly+Nodule	22	720
Cardiomegaly+Pneumonia	8	580
Consolidation+Edema+Effusion+Infiltration	5	550
Consolidation+Edema+Infiltration+Pneumonia	3	530
Consolidation+Effusion+Infiltration+Mass+Nodule	7	570
Consolidation+Effusion+Infiltration+Mass+Pneumothorax	1	510
Consolidation+Effusion+Infiltration+Pneumonia	5	550
Consolidation+Effusion+Mass	65	1150
Consolidation+Effusion+Mass+Nodule+Pneumothorax	1	510
Consolidation+Effusion+Mass+Pneumothorax	4	540
Consolidation+Emphysema+Infiltration+Nodule	1	510
Consolidation+Fibrosis	24	740
Consolidation+Fibrosis+Mass+Pleural_Thickening	4	540

Çizelge 6.16 Sınıflardaki ilk örnek sayısı ve veri artırma yöntemlerinin birleştirilmesi sonrası sayısı (devam)

Sınıf Adı	Orijinal Sayı	Veri Arttırımı Uygulanmaları Sonrasındaki Sayı
Consolidation+Fibrosis+Pneumothorax	2	520
Consolidation+Infiltration+Mass+Nodule+Pleural_Thickening	1	510
Consolidation+Infiltration+Mass+Pneumothorax	3	530
Consolidation+Infiltration+Nodule+Pleural_Thickening	2	520
Consolidation+Infiltration+Pneumothorax	20	700
Consolidation+Pneumonia+Pneumothorax	1	510
Edema+Effusion+Infiltration+Nodule	9	590
Edema+Effusion+Infiltration+Pleural_Thickening	10	600
Edema+Effusion+Nodule	10	600
Edema+Effusion+Pleural_Thickening+Pneumonia+Pneumothorax	1	510
Edema+Infiltration+Mass+Nodule+Pleural_Thickening	1	510
Edema+Mass	18	680
Edema+Mass+Nodule	8	580
Effusion+Atelectasis	2	520
Effusion+Emphysema+Infiltration+Pneumonia	1	510
Effusion+Emphysema+Infiltration+Pneumothorax	12	620
Effusion+Fibrosis+Nodule+Pleural_Thickening	3	530
Effusion+Fibrosis+Pleural_Thickening	8	580
Effusion+Infiltration+Mass+Pneumonia	2	520
Effusion+Infiltration+Pleural_Thickening+Pneumothorax	3	530
Effusion+Infiltration+Pneumonia	42	920
Effusion+Mass+Pneumonia	3	530
Effusion+Nodule+Pleural_Thickening	31	810
Effusion+Pleural_Thickening+Pneumonia	1	510
Emphysema+Fibrosis+Mass	1	510
Emphysema+Fibrosis+Mass+Pleural_Thickening+Pneumothorax	1	510
Emphysema+Hernia	1	510
Emphysema+Hernia+Pleural_Thickening	1	510
Emphysema+Nodule+Pleural_Thickening+Pneumothorax	1	510
Emphysema+Pneumonia	5	550
Emphysema+Pneumothorax+Pneumonia	1	510
Fibrosis+Infiltration+Mass+Pleural_Thickening	3	530
Fibrosis+Mass+Nodule+Pleural_Thickening	2	520
Fibrosis+Mass+Pleural_Thickening	3	530
Fibrosis+Pleural_Thickening+Pneumothorax	7	570
Fibrosis+Pneumothorax	23	730
Infiltration+Mass+Nodule+Pleural_Thickening	8	580
Infiltration+Mass+Pleural_Thickening	25	750
Infiltration+Pleural_Thickening+Pneumothorax	22	720
Mass+Pleural_Thickening+Pneumothorax	15	650
Nodule+Pneumonia+Mass	1	510

Çizelge 6.17 ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 5. Epoch ile 55. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	5. Epoch	10. Epoch	15. Epoch	20. Epoch	25. Epoch	30. Epoch	35. Epoch	40. Epoch	45. Epoch	50. Epoch
23	6	6.1	6.38	6.27	6.37	6.47	6.97	7.62	6.92	8.31
24	5.96	6.35	6.42	6.57	6.32	7.21	6.51	7.21	8.38	7.45

Çizelge 6.18 ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	55. Epoch	60. Epoch	65. Epoch	70. Epoch	75. Epoch	80. Epoch	85. Epoch	90. Epoch	95. Epoch	100. Epoch
23	7.12	7.76	7.93	8.08	7.99	8.29	7.76	9.29	8.34	7.77
24	7.22	7.58	7.49	7.56	8.02	7.77	8.81	8.45	7.56	7.97

Çizelge 6.19 ResNet50 sinir ağının görüntü arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları

Senaryo	En Az 1 Eşleşme Doğruluk Oranları (%)
23	45.05
24	<b>45.73</b>

#### 6.4 Tekil Etiketle Yapılan Çalışmalar

Bu bölümde son olarak sınıf sayısını azaltmak amacıyla veri setindeki X-Ray görüntülerinin birden çok etiketleri kullanılarak birden çok sınıfa yerleştirdik. Örnek vermek gerekirse 7 etiketli olan bir görüntüyü 7 sınıfa da dahil ettik ve bu dağılım ile eğitimi 23 ve 24. senaryodaki parametre kümesi ile yineledik.

Bu dağılım sonrasında veri setindeki sınıflar ve örnek sayıları Çizelge 6.20’de yer almaktadır.

Çizelge 6.20 Tekil etiketle yapılan çalışmalarda kullanılan veri seti dağılımı

Sınıf Adı	Örnek Sayısı
Atelectasis	11559
Cardiomegaly	2776
Consolidation	4667
Edema	2303
Effusion	13317
Emphysema	2516
Fibrosis	1686
Hernia	227
Infiltration	19894
Mass	5782
Nodule	6331
No_Finding	60361
Pleural_Thickening	3385
Pneumonia	1431
Pneumothorax	5302

Toplamda 141.537 örneğe yükselen bu veri setindeki 3 sınıf (Atelectasis, Pleural\_Thickening, Effusion) test için ayrılmıştır. Böylelikle 28.291 örnek test için ayrılırken geriye kalan 113.246 örnek de eğitimde kullanılmıştır. Bu dağılım, evrimsel sinir ağlarının eğitiminde artık standart bir yaklaşım haline gelen, veri setlerinin %80'inin eğitim, %20'sinin test ve validasyon için ayrılması yaklaşımı doğrultusunda belirlenmiştir. Böylece 28.291 örnek testte, 113.246 örnek ise eğitimde kullanılmıştır.

Çizelge 6.21 ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 5. Epoch ile 55. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	5. Epoch	10. Epoch	15. Epoch	20. Epoch	25. Epoch	30. Epoch	35. Epoch	40. Epoch	45. Epoch	50. Epoch
23	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97
24	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97

Çizelge 6.22 ResNet50 sinir ağının veri arttırma sonucu elde edilen yeni veri setinin eğitimi sonucunda 55. Epoch ile 100. Epoch arasında elde edilen doğruluk değerleri (%)

Senaryo	55. Epoch	60. Epoch	65. Epoch	70. Epoch	75. Epoch	80. Epoch	85. Epoch	90. Epoch	95. Epoch	100. Epoch
23	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97
24	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97	11.97

Çizelge 6.23 ResNet50 sinir ağının görüntü artırma sonucu elde edilen yeni veri setinin eğitimi sonucunda en az 1 eşleşme doğruluk oranları sonuçları

Senaryo	En Az 1 Eşleşme Doğruluk Oranları (%)
23	11.97
24	11.97

## 6.5 Kısıtlar

Eğitim ve test görüntü boyutları (224 ve 448) ve batch boyutları (4 ve 24), ImageNet tarafından eğitilmiş modellerle uyumludur. Donanım kısıtlamaları nedeniyle batch boyutu artırılmamıştır.

## 6.6 Geliştirme Ortamı

Bu tez kapsamında yapılan çalışmalar sırasında kullanılan geliştirme ortamında şu framework'ler ve kütüphaneler kullanılmıştır:

- Python 3.7
- Conda (açık kaynak)
- Torch 1.10
- Torchvision 0.10.0
- CUDA Toolkit 11.5

Bu framework'ler ve kütüphanelerin üstünde koştuğu;

- GPU kartı: NVIDIA GeForce RTX 3090/PCIe/SSE2 / NVIDIA GeForce RTX 3090/PCIe/SSE2
- İşlemci IntelB
- Core i9-10900X CPU @ 3.70GHz C-20
- İşletim sistemi: Ubuntu 20.04.02 LTS

## 7. SONUÇ VE TARTIŞMA

Sıfır Atış Öğrenme veya son zamanlardaki yaygın kullanımı ile Örneksiz Öğrenme yöntemi veri setlerinin sınırlı veya veri setlerindeki etiketlemelerin yeterli olmadığı durumlarda kullanılabilecek bir yöntemdir. Veri setlerini genişletmenin maliyetli ve öznellik problemi barındırması nedeniyle Sıfır Atış Öğrenmesi bu alandaki zorlukları aşmaya aday konumdadır. Özellikle tıbbi görüntüleme alanında veri setlerinin sınırlı olması, var olan veri setlerinin genişletilmesi, etiketlenmesi ve yeni veri setlerinin hazırlanmasının zorluğu da dikkate alındığında bu yöntemin sağlık alanında etkin bir şekilde kullanılmasının önünde bir engel bulunmamaktadır. Ontolojinin anlambilim gücü de sınıf gömmelerinde destekleyici bir yöntem olarak kullanıldığında bu yöntemin daha da güçlenmesinin önünde bir engel bulunmamaktadır.

Bu tez kapsamında da buna ön ayak olmak için çok etiketli ChestX-ray14 veri seti kullanılmıştır. Yardımcı bilgi olarak da sınıf etiketlerinin ilişkili olduğu kavramlar DBpedia'dan çekilmiştir. Bu veri seti öncelikle ResNet50 ve ResNext50 sinir ağları kullanılarak eğitilmiş ve hiperparametrelerin optimize edilmesi sağlanmıştır. ResNeXt50 sinir ağı üzerinde yapılan eğitimler beklenen sonuçları vermediği için eğitimlere ResNet50 sinir ağı ile devam edilmiştir. Toplamda 24 farklı hiperparametre setinin varyasyonları test edilmiştir. Daha iyi sonuçları verdiği tespit edilen ResNet50 sinir ağının 23 ve 24. senaryoları dahilindeki hiperparametre kümeleri ilerleyen bölümlerde konfigüre edilerek kullanılmıştır. Özet olarak Çizelge 7.1'den de özet olarak görülebileceği üzere en az 1 eşleşme sonuçlarına göre veri seti genişledikçe kesinlik (precision) değeri artmaktadır. Veri setinin tek bir yöntemle değil, hem GAN hem de klasik yöntemlerle genişletilmesi verinin temsil düzeyini arttırdığı gibi başarı oranını da yükseltmektedir.

Çizelge 7.1 Değerlendirme bölümündeki yöntemlerin en az 1 eşleşme sonuçlarını karşılaştırmalı gösteren çizelge

	6.1 ResNet 50 Sinir Ağı ile Yapılan Çalışmalar	6.3.1 Klasik veri arttırımı	6.3.2 GAN ile veri arttırımı	6.3.3 Klasik veri arttırımı ve GAN ile veri arttırımı yöntemlerinin birleştirilmesi	0 Tekil Etiketle Yapılan Çalışmalar
23	29,59	26,13	39,45	45,05	11,97
24	29,35	26,39	40,68	45,73	11,97

Bu tez çalışmasının görünmeyen hastalık tespit edilerek/tanınarak tıbbi görüntü alanına önemli bir katkı sağlayacağı düşünülmektedir.

## 7.1 Gelecek Çalışmalar

Bu tez kapsamında tüm veri setinde veri arttırımı uygulanmamıştır. Fakat yapılan çalışmalar göstermiştir ki, bu haliyle bile kesinlik değerinde iyileşmeler gözlenmektedir. Bu sebeple hem klasik hem de GAN ile veri arttırımının tüm veri setinde uygulanması, sınıf dengesizliğinin giderilmesi ilerleyen dönemde test edilecektir. Bu yöntemin kesinlik değerlerine etkisi gözlemlenecektir. Yine bu veri seti üzerinde ve arttırılmış veri ile diğer sinir ağlarının test edilmesi ve performanslarının değerlendirilmesi, bu sonuçların da yine bir akademik yayın haline getirilmesi hedeflenmektedir. Tez kapsamında kullanılan ontolojinin dinamik hale getirilmesi, böylece çıkarım yapılarak hastalıklar, bunların neden-sonuç ilişkilerinin tespit edilebilir olması da gelecek çalışmalar içerisinde değerlendirilecektir.

## KAYNAKLAR

- Akata, Z. a. (2015). Evaluation of Output Embeddings for Fine-Grained Image Classification. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 2927-2936). Computer Vision Foundation.
- Al-Halah, Z. a. (2015). How to Transfer? Zero-Shot Object Recognition via Hierarchical Transfer of Semantic Attributes. *Proceedings of the 2015 IEEE Winter Conference on Applications of Computer Vision* (s. 837–843). IEEE Computer Society.
- Auer, S. a. (2007). DBpedia: A Nucleus for a Web of Open Data. (s. 722-735). Springer Berlin Heidelberg.
- Bansal, A. a. (2018). Zero-Shot Object Detection. *arXiv*.
- Ben-Cohen, A., Klang, E., Raskin, S., Amitai, M., & Greenspan, H. (2017). Virtual pet images from ct data using deep convolutional networks:. *arXiv preprint*.
- Bucher, M. a. (2016). Improving Semantic Embedding Consistency by Metric Learning for Zero-Shot Classification. *Computer Vision -- ECCV 2016* (s. 730-746). Springer International Publishing.
- Chlap, P., Min , H., Vandenberg , N., Dowling , J., Holloway, L., & Haworth, A. (2021). A review of medical image data augmentation techniques for deep learning applications. *Journal of medical imaging and radiation oncology*, 545-563.
- Corcho, A. G.-P.-L. (2004). Ontological Engineering: With Examples from the Areas of Knowledge Management, e-Commerce and the Semantic Web. *Advanced Information and Knowledge Processing*. içinde
- Costa, P., Galdran, A., Meyer, M., Abramoff, M., Niemeijer, M., Mendonc, A., & Campilho, A. (2017). Towards adversarial retinal image. *arXiv preprint*.
- Courville, I. G. (2016). *Deep Learning*. MIT Press.
- Demirel, B. a.-C. (2018). Zero-Shot Object Detection by Hybrid Region Embedding. *arXiv*.
- Demirel, B. a.-C. (2019). Image Captioning with Unseen Objects. *The British Machine Vision Conference*.
- Deselaers, T. a. (2011). Visual and semantic similarity in ImageNet. *CVPR 2011*, (s. 1777-1784).
- Fensel, R. S. (1998). Knowledge engineering: Principles and methods. *Data & Knowledge Engineering*, 161-197.

- Frid-Adar, M., Diamant, I., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification. *Neurocomputing*, 321-331.
- Fu, Y. a.-G. (2017). Recent Advances in Zero-shot Recognition. *arXiv*.
- Fully Connected Layers in Convolutional Neural Networks*. (tarih yok). Indian Tech Warrior: <https://indiantechwarrior.com/fully-connected-layers-in-convolutional-neural-networks/> adresinden alındı
- G. Sumbul, R. G. (2018). Fine-Grained Object Recognition and Zero-Shot Learning in Remote Sensing Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 770-779.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., . . . Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, 2672-2680.
- Gruber, T. R. (1993). A translation approach to portable ontology specifications. *Knowledge Acquisition*, 199-220.
- Han, Z. a. (2020). Learning the Redundancy-Free Features for Generalized Zero-Shot Object Recognition. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 12865-12874). Computer Vision Foundation.
- He, K., Zhang, X., Sun, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition. *CoRR*.
- Hoffman, J. a. (2014). LSDA: Large Scale Detection Through Adaptation. *arXiv*.
- Huynh, D. a. (2020). A Shared Multi-Attention Framework for Multi-Label Zero-Shot Learning. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 8776-8786). Computer Vision Foundation.
- Huynh, D. a. (2020). Fine-Grained Generalized Zero-Shot Learning via Dense Attribute-Based Attention. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 4483-4493). Computer Vision Foundation.
- İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 85-104.
- Keshari, R. a. (2020). Generalized Zero-Shot Learning via Over-Complete Distribution. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 13300-13308). Computer Vision Foundation.
- Kızrak, A. (2018, Nisan 30). *ŞU KARA KUTUYU AÇALIM: Yapay Sinir Ağları*. Medium: <https://ayyucekizrak.medium.com/%C5%9Fu-kara-kutuyu-a%C3%A7alim-yapay-sinir-a%C4%9Flar%C4%B1-7b65c6a5264a> adresinden alındı

- Krivov, E., Pisov, M., & Belyaev, M. (2018). MRI Augmentation via Elastic Registration for Brain Lesions Segmentation. *Lecture Notes in Computer*, 369-380.
- Krizhevsky, A. (2012). *ImageNet Classification with Deep Convolutional*. Curran Associates, Inc.
- Liu, S. a.-W.-S.-G. (2020). Hyperbolic Visual Embedding Learning for Zero-Shot Recognition. *Hyperbolic Visual Embedding Learning for Zero-Shot Recognition* (s. 9273-9281). Computer Vision Foundation.
- N. Lakshmi Prasanna, R. V. (2021). MULTI LABEL CLASSIFICATION FOR AN IMAGE USING CONVOLUTIONAL NEURAL NETWORKS. *International Journal of Computer Science and Mobile Computing*, 01-09.
- Neches, R. F. (1991). Enabling Technology for Knowledge Sharing. *AI Magazine*, 36-56.
- Radford , A., Metz , L., & Chintala, S. (2016). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks.
- Rahman, S. a. (2019). Zero-Shot Object Detection: Learning to Simultaneously Recognize and Localize Novel Concepts. *Computer Vision -- ACCV 2018* (s. 547-563). Springer International Publishing.
- Rahman, S. a. (2020). Polarity Loss for Zero-shot Object Detection. *arXiv preprint arXiv:1811.08982*.
- Redmon, J. a. (2016). YOLO9000: Better, Faster, Stronger. *arXiv*.
- Rohrbach, M. a. (2011). Evaluating knowledge transfer and zero-shot learning in a large-scale setting. *CVPR 2011*, (s. 1641-1648).
- Saining Xie, R. B. (2016). Aggregated Residual Transformations for Deep Neural Networks. *CoRR*.
- Say, C. (2018). *50 Soruda Yapay Zeka*. İstanbul: Bilim Ve Gelecek Kitaplığı.
- SESTILI, C. (2018, Şubat 12). *Deep Learning: Going Deeper toward Meaningful Patterns in Complex Data*. Carnegie Mellon University Software Institute: <https://insights.sei.cmu.edu/blog/deep-learning-going-deeper-toward-meaningful-patterns-in-complex-data/> adresinden alındı
- Siegler, M. (2010, July 20). *Google Image Search: Over 10 Billion Images, 1 Billion Pageviews A Day*. TechCrunch: <https://techcrunch.com/2010/07/20/google-image-search/> adresinden alındı
- Simith, K. (2019, June 1). *53 Incredible Facebook Statistics and Facts*. Brandwatch: <https://www.brandwatch.com/blog/facebook-statistics/> adresinden alındı

- Simperl, E. P. (2006). Ontology Engineering: A Reality Check. *On the Move to Meaningful Internet Systems 2006: CoopIS, DOA, GADA, and ODBASE* (s. 836-854). içinde Springer Berlin Heidelberg.
- Sorin Grigorescu, B. T. (2020). A Survey of Deep Learning Techniques for Autonomous Driving. *Journal of Field Robotics*, 362-386.
- Soysal, O. A., Guzel, M. S., Dikmen, M., & Bostanci, G. E. (2022). Lung Disease Detection on ChestX-Ray 14 Dataset Using Zero-Shot Learning With Ontology. *2022 International Conference on Theoretical and Applied Computer Science and Engineering (ICTASCE)*.
- Soysal, Ö. A., & Güzel, M. S. (2020). An Introduction to Zero-Shot Learning: An Essential Review. *2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)* (s. 1-4). Ankara: 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA). doi:10.1109/HORA49412.2020.9152859
- Soysal, Ö. A., Güzel, M. S., Dikmen, M., & Bostanci, G. E. (2023). Common Thorax Diseases Recognition Using Zero-Shot Learning With Ontology in the Multi-Labeled ChestX-ray14 Data Set. *IEEE Access*, 27883-27892.
- Staff, R. (2013, December 12). *Instagram's user base grows to more than 500 million*. Reuters: <https://www.reuters.com/article/us-facebook-instagram-users/instagrams-user-base-grows-to-more-than-500-million-idUSKCN0Z71LN> adresinden alındı
- Sun, K. H. (2015). Deep Residual Learning for Image Recognition. *CoRR*.
- Turing, A. M. (1950). COMPUTING MACHINERY AND INTELLIGENCE. *Computing Machinery and Intelligence*, 433-460.
- Wang, S. a.-H.-P. (2020). Discovering Human Interactions With Novel Objects via Zero-Shot Learning. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 11652-11661). Computer Vision Foundation.
- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., & Summers, R. M. (2017). ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases. *2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, (s. 3462-3471).
- Wu, B. L. (2018). Combining ontology and reinforcement learning for zero-shot classification. *Knowledge-Based Systems*, 42-50.
- Xian, Y. a. (2017). Zero-Shot Learning -- The Good, the Bad and the Ugly. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 4582-4591). Computer Vision Foundation.

- Yu, Y. a. (2020). Episode-Based Prototype Generating Network for Zero-Shot Learning. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 14035-14044). Computer Vision Foundation.
- Zeynep Akata, F. P. (2013). Label-Embedding for AttributeBased Classification. *IEEE Computer Vision and Pattern Recognition (CVPR)*. Portland: IEEE.
- Zhang, L. a. (2017). Learning a Deep Embedding Model for Zero-Shot Learning. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 3010-3019). IEEE.
- Zhang, L., Zhu, M., & Huang, W. (2009). A Framework for an Ontology-based E-commerce Product Information Retrieval System. *Journal of Computers*, 436-443.

