

**DERİN ÖĞRENME İLE SOSYAL AĞLARDA RADYOLOJİK
GÖRÜNTÜ VE METİN TABANLI MEDİKAL KAVRAM TESPİTİ**

SÜMEYYE BAYRAKDAR

**DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

**DANIŞMAN
PROF. DR. İBRAHİM YÜCEDAĞ**

DÜZCE, 2023

T.C.
DÜZCE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DERİN ÖĞRENME İLE SOSYAL AĞLARDA RADYOLOJİK
GÖRÜNTÜ VE METİN TABANLI MEDİKAL KAVRAM TESPİTİ**

Sümeyye BAYRAKDAR tarafından hazırlanan tez çalışması aşağıdaki jüri tarafından Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı'nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. İbrahim YÜCEDAĞ

Düzce Üniversitesi

Jüri Üyeleri

Prof. Dr. İbrahim YÜCEDAĞ

Düzce Üniversitesi

Doç. Dr. Mehmet ŞİMŞEK

Milli Savunma Üniversitesi

Doç. Dr. İbrahim Alper DOĞRU

Gazi Üniversitesi

Doç. Dr. Gülçin ERSÖZ DEMİR

Düzce Üniversitesi

Dr. Öğr. Üyesi Ümit ŞENTÜRK

Bolu Abant İzzet Baysal Üniversitesi

Tez Savunma Tarihi: 18/01/2023

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

18 Ocak 2023

Sümeyye BAYRAKDAR

TEŐEKKÜR

Doktora öğrenimimde ve bu tezin hazırlanmasında gösterdiği her türlü destek ve yardımdan dolayı çok değerli Hocam Prof. Dr. İbrahim YÜCEDAĞ'a en içten dileklerle teşekkür ederim.

Tez çalışmam boyunca değerli katkılarını esirgemeyen tez jürisi Hocalarım Doç. Dr. Mehmet ŐİMŐEK'e ve Doç. Dr. İbrahim Alper DOĞRU'ya Őükranlarımı sunarım.

Doktora eğitimim boyunca her zaman yanımda olup bütün çalışmalarımnda beni motive eden ve desteğini hiç esirgemeyen çok değerli eşim Muhammed Enes BAYRAKDAR'a ve varlıklarıyla hayat enerjisi veren çok değerli kızlarım Asel'e ve Serra'ya en içten duygularıyla teşekkür ederim.

Beni bugünlere getiren ve desteklerini hiçbir zaman esirgemeyen canım Annem'e ve Babam'a, uzak şehirlerde olsak da desteğini her zaman yanımda hissettiğim canım Kardeşim'e sonsuz Őükranlarımı sunmaktan mutluluk duyarım.

BİDEB 2211-E Doğrudan Yurt İçi Doktora Burs Programı kapsamında sağlamış olduđu maddi destekten dolayı Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na (TÜBİTAK) teşekkür ederim.

18 Ocak 2023

Sümeyye BAYRAKDAR

İÇİNDEKİLER

Sayfa No

ŞEKİL LİSTESİ	vii
ÇİZELGE LİSTESİ	viii
KISALTMALAR.....	ix
ÖZET	xi
ABSTRACT	xii
EXTENDED ABSTRACT.....	xiii
1. GİRİŞ.....	1
2. SOSYAL AĞLAR.....	4
3. DERİN ÖĞRENME VE DERİN AĞLAR	9
3.1. DENETİMLİ/AYIRT EDİCİ ÖĞRENME İÇİN DERİN AĞLAR	14
3.1.1. Çok Katmanlı Algılayıcı (ÇKA).....	14
3.1.2. Evrişimsel Sinir Ağı (ESA).....	15
3.1.3. Tekrarlayan Sinir Ağı (TSA)	16
3.2. DENETİMSİZ/ÜRETKEN ÖĞRENME İÇİN DERİN AĞLAR	18
3.2.1. Üretken Çekişmeli Ağ (ÜÇA).....	19
3.2.2. Kısıtlı Boltzmann Makinesi (KBM).....	20
3.2.3. Kendi Kendini Düzenleyen Harita (KDH).....	21
3.2.4. Otomatik Kodlayıcı (OK)	23
3.2.5. Derin İnanç Ağı (DİA)	25
3.3. HİBRİT ÖĞRENME İÇİN DERİN AĞLAR	26
3.3.1. Hibrit Model-1	26
3.3.2. Hibrit Model-2.....	27
3.3.3. Hibrit Model-3.....	27
3.3.4. Derin Transfer Öğrenimi (DTL).....	27
3.3.5. Derin Takviyeli Öğrenme (DRL).....	29
4. HİBRİT DERİN ÖĞRENME SİSTEMLERİ İLE RADYOLOJİ GÖRÜNTÜLERİNDE MEDİKAL KAVRAM TESPİTİ.....	31
4.1. VERİ SETİ	33
4.1.1. Veri Seti Analizi.....	35
4.1.2. Veri Filtreleme.....	38
4.2. SİSTEM 1: ESA - TSA.....	39
4.3. SİSTEM 2: OK - ESA.....	42
4.4. SİSTEM 3: ESA - KNN.....	44
4.4.1. DenseNet-121	45
4.4.2. ResNet-101	46
4.4.3. Xception	46
4.4.4. EfficientNet-B7	47
4.5. SİSTEMLERİN DEĞERLENDİRİLMESİ.....	48

5. RADYOLOJİK SOSYAL AĞDA GÖRÜNTÜ VE METİN TABANLI MEDİKAL KAVRAM TAHMİNİ.....	53
6. SONUÇLAR VE ÖNERİLER.....	63
7. KAYNAKLAR.....	66
ÖZGEÇMİŞ.....	74



ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1. Sosyal ağlar.....	5
Şekil 3.1. Derin öğrenme.....	9
Şekil 3.2. Derin öğrenme ve makine öğrenmesi veri miktarı-performans karşılaştırması.....	11
Şekil 3.3. Derin öğrenme iş akışı.....	13
Şekil 3.4. Çok katmanlı algılayıcı (ÇKA) mimarisi.....	15
Şekil 3.5. Çoklu evrişim ve havuzlama katmanı içeren bir Evrişimsel Sinir Ağı (ESA) örneği.....	16
Şekil 3.6. Tekrarlayan Sinir Ağı (TSA) modeli.....	17
Şekil 3.7. Standart bir Üretken Çekişmeli Ağ (ÜÇA) çalışma yapısı.....	20
Şekil 3.8. Kısıtlı Boltzmann Makinesi (KBM)'nin ağ yapısı.....	21
Şekil 3.9. Kendi Kendini Düzenleyen Harita (KDH) modelinin genel çalışma yapısı.....	22
Şekil 3.10. Otomatik Kodlayıcı (OK) modelinin temel yapısı.....	24
Şekil 3.11. Derin İnanç Ağı (DİA)'nın ağ yapısı.....	25
Şekil 3.12. Derin transfer öğrenme sürecinin genel yapısı.....	28
Şekil 3.13. Derin takviyeli öğrenmenin şematik yapısı.....	30
Şekil 4.1. ImageCLEFmed Caption 2019 veri setinden alınan iki örnek görüntü ve onlara ait başlık, anahtar kelime ve kavram bilgileri.....	34
Şekil 4.2. Eğitim seti kavram frekansı-kavram sayısı dağılımı.....	37
Şekil 4.3. Geliştirme veri seti kavram sayısı-kavram frekansı dağılımı.....	38
Şekil 4.4. Sistem 1: ESA(VGG-19) – TSA (LSTM) hibrit modeli.....	41
Şekil 4.5. Sistem 2:OK – ESA hibrit model blok şeması.....	43
Şekil 4.6. Sistem 3:ESA – KNN yönteminin genel işleyişi.....	44
Şekil 4.7. Hibrit derin öğrenme sistemlerinin Vs, Vs,1 ve Vs,3 veri setleri üzerinde test F1 puanları için grafiksel sonuçlar.....	50
Şekil 4.8. Önceden eğitilmiş dört farklı ESA modeline ait Vs, Vs,1 ve Vs,3 veri setleri üzerinde test F1 puanları için grafiksel sonuçlar.....	51
Şekil 5.1. Facebook Radiopaedia.org radyolojik sosyal ağı.....	54
Şekil 5.2. Facebook Radiography-Radiopaedia.org radyolojik sosyal ağı.....	54
Şekil 5.3. Facebook Radiography-Radiopaedia radyolojik sosyal ağ sayfasından örnek bir görüntü ve görüntüye ait bazı yorumlar.....	55
Şekil 5.4. Radiopaedia.org sitesi üzerinden ilgili görüntü için paylaşılan medikal kavram ve başlık bilgisi.....	56
Şekil 5.5. Radyolojik görüntü yorumlarından medikal anahtar kelimelerin belirlenmesi.....	58
Şekil 5.6. Rdpd_Test_Vs'de yer alan örnek bir görüntü ve görüntü ile ilişkili bilgiler.....	60
Şekil 5.7. Rdpd_Test_Vs'de yer alan örnek bir görüntü için gerçek kavramlar ve ESA-TSA sisteminde tahmin edilen kavramlar.....	61
Şekil 5.8. Rdpd_Test_Vs üzerinde test edilen hibrit derin öğrenme sistemlerine ait grafiksel sonuçlar.....	62

ÇİZELGE LİSTESİ

	<u>Sayfa No</u>
Çizelge 4.1. Veri seti dağılımı.	33
Çizelge 4.2. Eğitim veri setinde yer almayan bazı CUI'ler ve onlara ait kavramlar.	35
Çizelge 4.3. Eğitim görüntülerine atanan kavram sayısı sıralaması ve karşılık gelen CUI'ler.	36
Çizelge 4.4. Eğitim seti ve tüm veri seti için en çok kullanılan 10 CUI, karşılık gelen UMLS kavramları ve bu kavramların atandıkları görüntü sayıları.	36
Çizelge 4.5. Hibrit sistemler için geliştirme ve test sonuçları.	50
Çizelge 4.6. Sistem 3 için dört farklı ESA kodlayıcı modelinin geliştirme ve test sonuçları.	51
Çizelge 4.7. 2019 ImageCLEFmed Caption görevi için F1 puanı değerlendirmesi.	52
Çizelge 5.1. Oluşturulan Radiopaedia veri setine (Rdpd_Test_Vs) ait sayısal bilgiler.	57
Çizelge 5.2. Rdpd_Test_Vs üzerinde test edilen hibrit derin öğrenme sistemlerine ait sonuçlar.	62

KISALTMALAR

4IR	Dördüncü Sanayi Devrimi
Adam	Uyarlamalı Moment Tahmini
BiLSTM	Çift Yönlü LSTM
CAE	Büzücü Otomatik Kodlayıcı (Contractive Autoencoder)
CLEF	Çapraz Dil Değerlendirme Forumu (Cross Language Evaluation Forum)
CNN	Evrişimsel Sinir Ağı (Convolutional neural network)
CRF	Koşullu Rastgele Alanlar
CUI	Kavram benzersiz tanımlayıcılarını (Concept Unique Identifiers)
ÇKA	Çok Katmanlı Algılayıcı
DAE	Gürültü Giderici Otomatik Kodlayıcı (Denosing Autoencoder)
DİA	Derin İnanç Ağları
DRL	Derin Takviyeli Öğrenme (Deep Reinforcement Learning)
DTL	Derin Transfer Öğrenimi (Deep Transfer Learning)
ESA	Evrişimsel Sinir Ağı
GAN	Üretken Çekişmeli Ağlar (Generative adversarial network)
GPU	Grafik İşlem Birimi
GTB	Geçitli tekrarlayan birim
KBM	Kısıtlı Boltzmann Makinesi
KDH	Kendi Kendini Düzenleyen Haritalar
KNN	K-En Yakın Komşular (K-Nearest Neighbors)
L-BFGS	Sınırlı Bellek Broyden-Fletcher- Goldfarb-Shanno
LSTM	Uzun kısa süreli bellek (Long Short- Term Memory)
OK	Otomatik Kodlayıcı
ReLU	Doğrultulmuş lineer birim (Rectified Linear Unit)
RL	Takviyeli Öğrenme (Reinforcement Learning)
ROCO	(Radiology Objects in COntext)
SAA	Sosyal Ağ Analizi
SAE	Seyrek Otomatik Kodlayıcı (Sparsity Autoencoder)
SGD	Stokastik Gradyan Düşüşü
SNOMED- CT	Sistematize Tıp-Klinik Terimler
SOM	Kendi Kendini Düzenleyen Haritalar (The Self-Organizing Map)

SVM	Destek Vektör Makineleri (Support Vector Machine)
TSA	Tekrarlayan Sinir Ađı
UKSB	Uzun kısa süreli bellek
UMLS	Birleşik Tıbbi Dil Sistemi (Unified Medical Language System)
ÜÇA	Üretken Çekişmeli Ağlar
VAE	Varyasyonel Otomatik Kodlayıcı (Variational Autoencoder)
YSA	Yapay sinir ađı



ÖZET

DERİN ÖĞRENME İLE SOSYAL AĞLARDA RADYOLOJİK GÖRÜNTÜ VE METİN TABANLI MEDİKAL KAVRAM TESPİTİ

Sümeyye BAYRAKDAR

Düzce Üniversitesi

Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik ve Bilgisayar Mühendisliği Anabilim
Dalı

Doktora Tezi

Danışman: Prof. Dr. İbrahim YÜCEDAĞ

Ocak 2023, 73 sayfa

Günümüzde sağlık konulu sosyal ağların her geçen gün arttığı görülmektedir. Bu ağların etkisi ile çeşitli uzmanlar tarafından tanılanıp yorumlanan çok sayıda tıbbi görüntü ortaya çıkmaktadır. Bu nedenle, tıbbi görüntülerden kavram tespiti ve görüntü sınıflandırma zorlu bir görev olmaya devam etmektedir. Son yıllarda bu alanda yapılan çalışmalar, model olarak derin öğrenme üzerindeki faaliyetleri artırmıştır. Derin öğrenme modeline ilginin bu denli artmasının en önemli sebebi ise, yeteri kadar sayıda eğitilecek verinin bulunması ve bu verilerinin işlenmesinde gerekli fiziki alt yapının hazır olmasıdır. Tez çalışmasının temel amacı, bir sosyal ağ üzerinde paylaşılan radyolojik görüntülere atanması gereken medikal kavramları otomatik olarak seçerek, görüntülerin çok etiketli sınıflandırmasını gerçekleştirmektir. Kavramlar, Birleşik Tıp Dil Sisteminden (Unified Medical Language System -UMLS) gelir. Çalışmada, kavramları tahmin etmek amacıyla ileri beslemeli sinir ağları ile birleştirilen Evrişimsel Sinir Ağı (Convolutional Neural Network-CNN) ve çeşitli görüntü kodlayıcıları (VGG-19, DenseNet-121, ResNet-101, Xception, Efficient-B7) uygulanmıştır. Önerilen hibrit derin öğrenme modelleri, ImageCLEF 2019 veri seti üzerinde eğitilmiş ve test edilmiştir. Daha sonra, sosyal ağ üzerinden toplanan radyoloji görüntüleri ve onlara ait yorumlardan oluşturulan veri seti (Rdpd_Test_Vs) üzerinde modellerin başarımı değerlendirilmiştir. Değerlendirme, sistem tarafından tahmin edilen ve kesin doğruluk kavramları arasındaki F1 puanları açısından gerçekleştirilmiştir. Değerlendirme sonuçları umut verici olup, yüksek başarıma sahiptir.

Anahtar sözcükler: Derin öğrenme, Makine öğrenmesi, Medikal görüntüde kavram tespiti, Medikal sosyal ağ, Radyolojik sosyal ağ.

ABSTRACT

RADIOLOGICAL IMAGE AND TEXT BASED MEDICAL CONCEPT DETECTION IN SOCIAL NETWORKS WITH DEEP LEARNING

Sümeyye BAYRAKDAR

Düzce University

Institute of Graduate Studies, Department of Electrical-Electronics and Computer
Engineering

Doctoral Thesis

Supervisor: Prof. Dr. İbrahim YÜCEDAĞ

January 2023, 73 pages

Today, it is seen that social networks on health topic are increasing day by day. With the effect of these networks, a large number of medical images emerge that are identified and interpreted by various experts. Therefore, concept detection and image classification from medical images remains a challenging task. In recent years, studies in this field have increased the activities on deep learning as a model. The most important reason why the interest in the deep learning model has increased so much is that there is enough data to be trained and the necessary physical infrastructure is ready to process this data. The main purpose of the thesis work is to perform multi-label classification of images by automatically selecting the medical concepts that should be assigned to the radiological images shared on a social network. Concepts come from the Unified Medical Language System (UMLS). In order to predict the concepts in the study, convolutional neural network (CNN) combined with feed forward neural networks, and various image encoders (VGG-19, DenseNet-121, ResNet-101, Xception, Efficient-B7) are employed. The proposed hybrid deep learning models have been tried and tested on the ImageCLEF 2019 dataset. Then, the performance of the models was evaluated on the data set (Rdpd_Test_Vs) formed from the radiology images and their comments collected over the social network. Evaluation is performed in terms of F1 scores between system prediction and absolute accuracy concepts. Evaluation results are promising and have high performance.

Keywords: Concept detection in medical image, Deep learning, Machine learning, Medical social network, Radiological social network.

EXTENDED ABSTRACT

RADIOLOGICAL IMAGE AND TEXT BASED MEDICAL CONCEPT DETECTION IN SOCIAL NETWORKS WITH DEEP LEARNING

Sümeyye BAYRAKDAR

Düzce University

Institute of Graduate Studies, Department of Electrical-Electronics and Computer
Engineering

Doctoral Thesis

Supervisor: Prof. Dr. İbrahim YÜCEDAĞ

January 2023, 73 pages

1. INTRODUCTION

Concept detection and image classification from medical images are two important tasks for efficient and robust medical image retrieval systems. These tasks also assist with subtasks such as knowledge discovery, medical report generation, medical question answering, and clinical decision making. Deep learning methods are being developed to automatically interpret biomedical images to assist clinicians who view large numbers of images daily. However, recently, it is seen that social networks on health are increasing.

2. MATERIAL AND METHODS

In the study of the thesis, ImageCLEFmed 2019 Concept Detection task was handled and three different hybrid deep learning methods were applied on the ImageCLEFmed Caption 2019 dataset. In the first hybrid system, two different supervised learning techniques, ESA and TSA, were applied together. In the second hybrid system, the OK-ESA combination, in which unsupervised and supervised learning techniques are combined, is presented. In the third hybrid system, four different pre-trained encoder models, namely DenseNet-121, ResNet-101, Xception and Efficient-B7 of ESA, which is a supervised learning technique, and the KNN algorithm, which is a machine learning classifier, were used together. Training and testing processes were performed on the data set for each model and the results were presented comparatively. Models are built in Python 3.7 using Keras library with Tensorflow background.

In addition, data set analysis and data filtering processes were carried out. In addition, the developed hybrid deep learning approaches were tested on the radiological images collected from the training pages created with the names Radiopaedia.org and Radiography-Radiopaedia.org on the Facebook social network and the data set (Rdpd_Test_Vs) formed from the comments of these images.

3. RESULTS AND DISCUSSIONS

Evaluation was performed in terms of F1 scores between system-predicted and absolute accuracy concepts. F1 scores both calculated per image and averaged over the entire test image are presented. When the results are evaluated, it is seen that the Xception model performs best in the ESA-KNN architecture, and the best results are obtained in the ESA-TSA architecture when examined in terms of all systems. It is seen that the highest results are obtained for the filtered data set Vs,1 as the data set. Although the results of Vs,3 are not as good as Vs,1, they are better than the results on the original dataset with no filtering. This shows us that filtering is necessary in the data set, but filtering at high frequency will reduce the F1 score as it may cause data loss. Because, concepts that have been deleted from the training dataset may be encountered as a result of the filtering process in the test dataset. According to the F1 score test results obtained from the Rdpd_Test_Vs data set of three different hybrid deep learning approaches proposed, the highest performance was again obtained with the ESA-TSA model. And, all F1 values were higher than the F1 values in the ImageCLEFmed Caption 2019 test data set. This shows that the concepts extracted from the interpretations of the radiological images in the prepared data set describe the image quite well and correctly.

4. CONCLUSION AND OUTLOOK

Medical images and interpretations present key areas specifically aimed at interaction between patients and doctors. Therefore, the attempt to identify the content of medical images shared via the social networking site is an important task, due to the large number of comments expressing the analysis and reviews of the experts. Therefore, in the thesis, an analysis approach that extracts key concepts from the comments is used to provide an overview of what is present in the comments. Although radiological diagnosis is often challenging and time consuming for many radiologists today, it is still far from the performance required for both training in medical social networks and the deployment of this process by machines in a real world environment. But, it is an open field for new methods and studies. Emerging technology and hardware resources will also play an important role in these systems. As deep learning uses neural networks that have incredible computational power, it also requires a lot of accurate data and powerful hardware to produce good results.

1. GİRİŞ

Sosyal ağlar, kullanıcıların her türlü metin ve multimedya içeriğini paylaşarak kullanabildiği günümüz internetinde gün geçtikçe daha fazla insanı içine çekmektedir. Son yıllarda, çeşitli alanlardaki sosyal ağ sitelerinde görülen bu önlenemez artış, sosyal uygulamaların da küresel ölçekte yayılımını beraberinde getirmiştir [1]. Eğitim, sağlık, haberleşme, eğlence, akademik ve daha birçok alanda ortaya çıkan farklı sosyal ağlar özellikle akıllı mobil cihazların ve internet imkanlarının yaygınlaşması ile insanlar tarafından aktif bir şekilde kullanılır hale gelmiştir. Sosyal ağların bu kadar çok kullanılması sosyal ağları oluşturan yapıların ve paylaşılan içeriklerin incelenip analiz edilmesi konusunu gündeme getirmiştir.

Biyomedikal ve klinik alanda, görsel ve metinsel kaynaklardan bilgi çıkarmak ve bunları bilgi kaynaklarına haritalamak, yeni tür akıllı tanıma yöntemleri aracılığıyla hızla ilerleyen bir araştırmadır. Bu yöntemler, görüntü işleme, içerik analizi, doğal dil işleme ve metin madenciliği yaklaşımları içerisinde yer almaktadır. Bu araçlar, görüntülerden ve metinlerden yararlı bilgiler çıkarmak için makine öğrenmesi ve istatistiklerden yararlanır. Makine öğrenmesi ve yapay zekanın bir dalı olan derin öğrenme, günümüzde Dördüncü Sanayi Devrimi'nin (4IR veya Endüstri 4.0) temel teknolojisi olarak kabul edilmektedir. Temeli Yapay Sinir Ağlarına (YSA) dayanan derin öğrenme teknolojisi verilerden öğrenme yeteneğiyle bilgi işlem bağlamında sıcak bir konu haline gelmiştir ve sağlık hizmetleri, görsel tanıma, metin analitiği, siber güvenlik ve daha pek çok farklı uygulama alanında kullanılmaktadır [2].

Makine öğrenmesinin özel bir dalı olan derin öğrenme, son zamanlarda çeşitli görevlerdeki üstün performansı nedeniyle büyük ilgi görmektedir. Bir derin öğrenme sistemi, yalnızca özelliklerin kendi sınıflarıyla eşlenmesini öğrenmekle kalmayıp, aynı zamanda insan beynine çok benzeyen çeşitli soyutlama düzeylerinde özellikleri otomatik olarak öğrenen çok sayıda birbirine bağlı nöron kullanır. Derin öğrenme çerçevesi, makinelerin daha sonra doğru veri analizi yapmak amacıyla kullanılabileceği çok karmaşık matematiksel modelleri öğrenmesine olanak tanır. Bu modeller, model parametreleri tarafından ağırlıklandırılan girdi verilerinin doğrusal olmayan ve/veya doğrusal işlevlerini hiyerarşik olarak hesaplar. Bu işlevleri, veri işleme katmanları olarak

ele alan çok sayıda katmanın hiyerarşik kullanımını derin öğrenme adına ilham vermiştir [3].

Radyolojik görüntüler hastalık tanı ve tedavisinde yaygın olarak kullanılmaktadır. Bu görüntülerin okunması ve özetlenmesi genellikle deneyimli tıp uzmanları tarafından yapılır ve bu görüntülerden bilgi elde etmek zaman alıcı ve zahmetli bir iştir. Bu nedenle, tıbbi görüntülerden hayati bilgileri otomatik ve verimli bir şekilde çıkarmak çok önemlidir. Medikal kavram çıkarmanın amacı, tıbbi belgelerden problemler, tedaviler ve testler gibi ilgi duyulan medikal kavramlara atıfta bulunan ifadeleri belirlemektir. Kavramların ve bağlamların tıbbi kategori çıkarımı, sağlık alanında yeni ortaya çıkan çok disiplinli bir araştırma alanıdır. Bununla birlikte, alana özgü sözlüklerin ve kategorileri etiketlemeye uygun uzmanların olmaması nedeniyle, bu alan birden fazla zorlukla karşı karşıyadır. Son yıllarda araştırmacılar, bu zorlukların üstesinden gelmek için Birleşik Tıbbi Dil Sistemi (UMLS), GENIA ve Sistematize Tıp-Klinik Terimler (SNOMED-CT) gibi bir dizi bilgi çıkarma sistemi geliştirmişlerdir [4]. En sık kullanılan ve tüm biyomedikal alanı kapsayan UMLS, ABD Ulusal Tıp Kütüphanesi tarafından sunulmuş ve 30 yılı aşkın süredir geliştirilmekte olan bir biyomedikal sözlük deposudur [5].

Bu tez çalışmasında, bir sosyal ağ üzerinde paylaşılan radyolojik görüntülere atanması gereken medikal kavramları otomatik olarak seçerek, görüntülerin çok etiketli sınıflandırmasını gerçekleştirmek amaçlanmıştır. Tez çalışmasında özellikle birden fazla derin öğrenme tekniği birleştirilerek hibrit sistemler oluşturulmuştur. Çünkü bu teknikler etiketlenmiş imge içeren eğitim setlerinde kendiliğinden özellik çıkarma işlemini becerebilen, makine öğrenmesinin aksine çok katmanlı sinir ağlarını bir arada kullanılmasına olanak sağlayan sistemlerdir. Yapılan araştırmalar sonucunda, sosyal ağlar için olmasa da medikal görüntüler üzerinde çalışan sistemlerin değerlendirilmesi için kıyaslama kaynakları geliştiren ve yeni zorluklar öneren ImageCLEF aksiyonu ele alınmıştır. ImageCLEF 2019'un [6] bir parçası olarak, tıbbi görüntü altyazısı sorununu analiz etmek ve çözmek için başlatılan ImageCLEFmed Caption [7] görevi incelenmiştir. ImageCLEFmed Caption görevi altında tanımlanan ImageCLEFmed 2019 Kavram Tespit görevinin ise tez çalışmasının amacına hizmet edeceği öngörülmüştür. Bu kapsamda, araştırmacılara sunulan ImageCLEFmed Caption 2019 veri seti üzerinde derin öğrenme için hibrit sistemlerin oluşturulduğu yöntemler uygulanmıştır.

Medikal kavram çıkarımının amacı, tıbbi belgelerden problemler, tanı, tedaviler ve testler gibi ilgili medikal kavramlara atıfta bulunan ifadeleri belirlemektir. Tez çalışmasında, bu

görevi radyolojik bir sosyal ağ üzerinde gerçekleştirebilmek için Facebook sosyal ağı üzerinde Radiopaedia.org ve Radiography-Radiopaedia.org adları ile oluşturulmuş eğitim sayfaları kullanılmıştır. Bahsi geçen hibrit derin öğrenme sistemlerini test etmek için, radyolojik görüntü ve görüntülere ait yorumlar toplanarak Radiopaedia veri seti (Rdpd_Test_Vs) hazırlanmıştır.

Tez çalışmasının bundan sonraki bölümleri şu şekilde organize edilmiştir: 2. Bölümde, sosyal ağlar ile ilgili genel bilgilere ve literatürdeki çalışmalara yer verilmiştir. 3. Bölümde, derin öğrenme ve derin ağlar teknikleri ile birlikte detaylandırılmıştır. 4. Bölümde, hibrit derin öğrenme sistemleri ile radyoloji görüntüleri üzerinde gerçekleştirilen kavram tespiti için kullanılan veri seti ve modeller detaylarıyla birlikte sunulmuş ve sonuçlar değerlendirilmiştir. 5. Bölümde ise, radyolojik sosyal ağ üzerinden oluşturulan test veri seti ve bu veri seti üzerinde görüntü ve metin tabanlı medikal kavram tahmini için yapılan işlemler açıklanıp sonuçlar sunulmuştur. Son olarak 6. Bölümde, genel değerlendirme ile birlikte sonuç ve öneriler yer almaktadır.



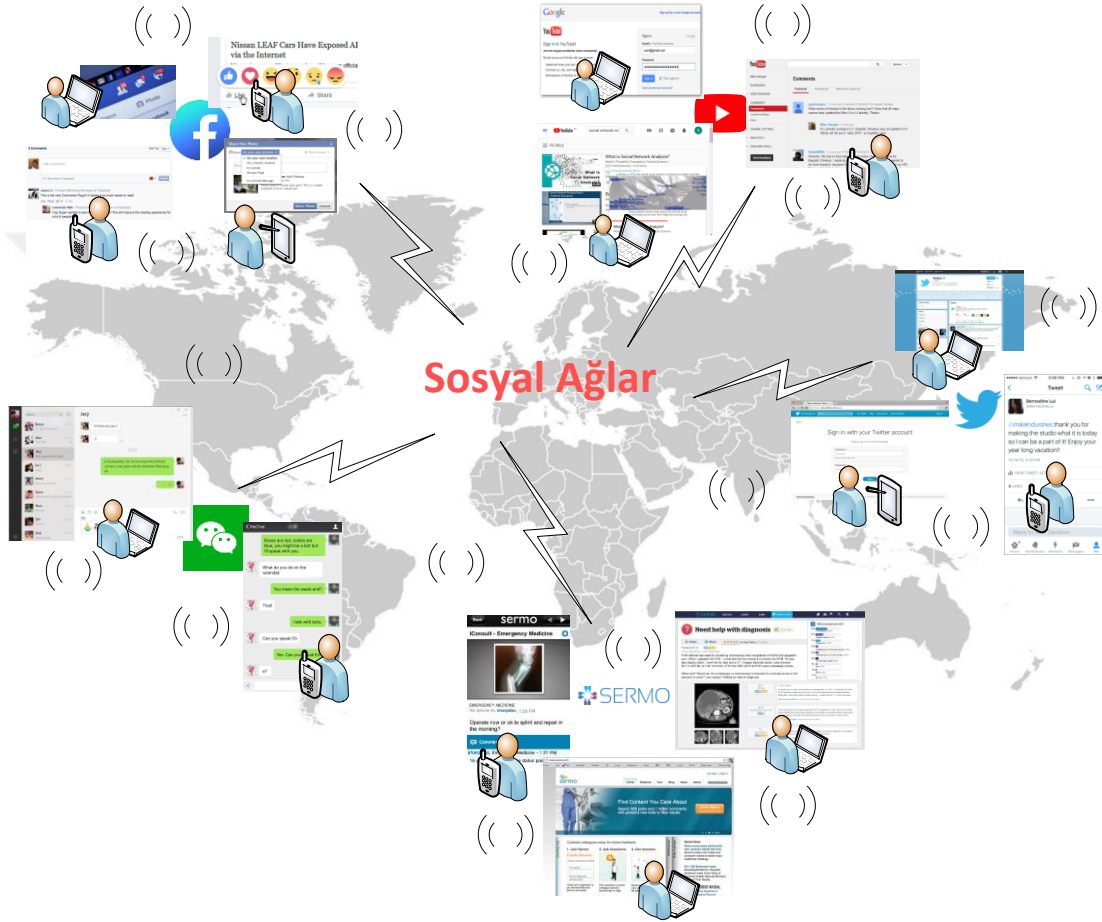
2. SOSYAL AĞLAR

Sosyal ağlar, kullanıcıların duygu ve düşüncelerini ifade etme, içerik paylaşımı, reklamlar, bilgi edinme/yayma ve çevrimiçi sosyalleşme gibi konularda birbirleriyle bağlantı kurmasına izin verir. Kullanıcılar gönderiler veya durum güncellemeleri oluşturduğunda, bunlar kullanıcının sosyal ağına dağıtılır. Geleneksel web sayfalarından en önemli farkı, kullanıcıların yalnızca pasif bilgi tüketicileri değil, çok çeşitli içerik oluşturucu olmalarıdır. Sosyal ağ içerikleri dinamiktir, kullanıcıların duygusal ve toplumsal dalgalanmalarını yansıtır. Sosyal ağ sitelerindeki kullanıcı faaliyetleri sıklıkla kutlamalar, spor, seçim, krizler ve salgın hastalıklar gibi belirli popüler olaylar ve iklim değişikliği, çevre kirliliği, terörizm ve göç gibi konular tarafından tetiklenebilir [8].

Kullanıcıların her türlü metin ve multimedya içeriğini paylaşabildiği ve kullanabildiği sosyal ağlar, günümüz internetinde giderek daha fazla insanın ilgisini çekmektedir. Örneğin, Facebook, 2012'nin sonuna doğru 1 milyar kayıtlı hesabı aşan ilk sosyal ağ olmuştur ve şu anda Ocak 2022'den bu yana aylık 2,91 milyar aktif kullanıcıya sahiptir [9]. Dünyanın en popüler mikroblog ağ hizmetlerinden biri olan Twitter, 2022'in dördüncü çeyreği itibarıyla aylık ortalama 290,5 milyon aktif kullanıcıya sahiptir ve 2024 yılına kadar 340 milyondan fazla kullanıcıya ulaşmaya devam edeceği tahmin edilmektedir [10]. Çin'de Twitter benzeri bir mikroblog platformu olan Sina Weibo'nun Eylül 2022 itibarıyla Çin'de aylık yaklaşık 584 milyon aktif kullanıcısı vardır [11]. Yaygın olarak kullanılan bir diğer sosyal ağ servisi de Instagram'dır. Kullanıcıların dijital filtre seçeneği ile kendi içeriklerini düzenlemelerine olanak tanıyan bir sosyal fotoğraf ve video paylaşım hizmeti olan Instagram, Haziran 2018 itibarıyla dünya çapında aylık 1 milyardan fazla aktif kullanıcıya bildirimde bulunmuştur ve sosyal medya ağının günlük aktif kullanıcısı 500 milyona ulaşmıştır [12]. Ekim 2022 itibarıyla ise sadece Türkiye'deki Instagram kullanıcı sayısı yaklaşık 52,5 milyon olarak kaydedilmiştir [13].

Sosyal ağ temel olarak kişilerin, grupların veya kuruluşların ve bunların bağlantılarının bir yapısı olarak görülmektedir. Sosyal ağ platformlarında, kullanıcılar diğer kullanıcılarla bilgi paylaştığında veya bağlantı kurduğunda, onlarla etkileşim kurarak bir ağ oluşturmaktadırlar [17]. Ağ içindeki yapılar 'düğüm' olarak sembolize edilmektedir ve düğümler arasındaki ilişkiler de 'bağlantılar' olarak adlandırılmaktadır [18]. Düğümler

geleneksel olarak aile, arkadaşlık, iş veya din gibi karşılıklı bağımlılıklar nedeniyle bağlantılar oluşturur ve bağlantılar, çoğu durumda sosyal ağ sitelerinin amacını yansıtır. Sosyal ağ perspektifinden sosyal medya araştırması, bireysel özelliklerden ziyade sosyal varlıklar arasındaki ilişkisel bağlantılara odaklanmaktadır. Tüm bu bağlantılar, ortaya çıkan ağ modellerini ortaya oluşturmaktadır. Şekil 2.1, çeşitli sosyal ağ sitelerinin örnek bir gösterimini sunmaktadır.



Şekil 2.1. Sosyal ağlar.

Dünyada sosyal ağ kullanımı her geçen gün artmaktadır. Küresel istatistiklere göre, dünya çapında 2017’de toplam 2,46 milyar olan aylık aktif sosyal ağ kullanıcı sayısı, 2021’de 3,02 milyara yükselmiştir [14]. Son yıllarda sosyal paylaşım sitelerindeki bu kaçınılmaz artış, sosyal uygulamaları küresel bir boyuta taşımıştır [5]. Eğitim, iletişim, sağlık, eğlence, akademi ve daha birçok alanda ortaya çıkan farklı sosyal ağlar, özellikle akıllı mobil cihazların kullanımının yaygınlaşması ve internet imkanları ile insanlar tarafından aktif olarak kullanılmaya başlanmıştır. Sosyal ağların bu kadar fazla kullanılması, sosyal ağları oluşturan yapıların ve paylaşılan içeriklerin gözden geçirilmesi ve analiz edilmesi

sorununu gündeme getirmiştir. Ve sonra, sosyal ağ analizi (SAA) araştırması artan bir ilgi görmüştür. Çalışma [15]'te, bir sosyal ağdaki en etkin kullanıcı (merkezi aktör) tarafından yapılan yorumları kullanarak yarı otomatik şekilde ontoloji tabanlı ek açıklamalar üreten bir sistem önermişlerdir. Bir görüntünün sosyal içeriği, yaklaşımlarında merkezi öneme sahiptir. Bir görüntü içeriği için, sosyal ağlardaki aktörler arasından coğrafi referans, zaman ve ilişki gibi birkaç faktörü göz önüne almışlardır. Ayrıca, göz önüne alınan aktörler arasındaki ilişkilerin ayrıntılarını hesaba katarak sosyal ağ analizi tekniklerini genişletmişler ve ilişkilerin çeşitliliği ile ilgilenmek için bir semantik web çerçevesi kullanmışlardır. Geliştirdikleri OntoCAIM ontolojisi yalnızca sosyal ağ analizi işlevselliğini yerine getirmekle kalmayıp, aynı zamanda altta yatan bir ontoloji ile resimlere ek açıklama mekanizması tanımlamaktadır.

Günümüzde birçok alanda olduğu gibi sosyal ağların özellikle sağlık hizmetlerinde artan kullanımı ile birçok farklı medikal sosyal ağ oluşumu ortaya çıkmıştır. Bu ağlar genellikle, doktorları veya sağlık çalışanlarını bir araya getirerek hızlıca ve güvenle fikir alışverişinde bulunmalarını sağlamayı amaçlamaktadır. Bu amaçla, son yıllarda Doximity [16], Sermo [17], Student Doctors Network [18] PatientsLikeMe [19], Figure1 [20] ve MomMD [21] gibi çok sayıda medikal sosyal ağ geliştirilmiştir. Ayrıca en popüler sosyal ağlardan biri olan Facebook üzerinde, örneğin radyologlar ve radyoloji görüntüleri üzerine oluşturulmuş, Radiopaedia.org [22], Radiography-Radiopaedia.org [23], LearningRadiology [24] ve The Radiologist [25] gibi birçok eğitim ve bilim sayfası vardır. Bununla birlikte doktor, sağlık çalışanı ve hastaların da çevrimiçi sanal topluluğa katılımını sağlayan ağlar büyük hacimlerde içerik paylaşımlarını etkinleştirmiştir [26]. Bu ağların etkisi günlük olarak büyümekte ve değişmekte, farklı dillerde çeşitli uzmanlar tarafından tanılanıp yorumlanan çok sayıda medikal görüntü ortaya çıkmaktadır. Bu koleksiyonların zenginliği faydalı bilgilere erişimi de giderek zorlaştırmaktadır. Çünkü sağlık profesyonellerinin artan bir çoğunluğu, hatta hastalar bile, sağlık bilgisi almak için tıbbi sosyal ağları aramaktadır. Bu amaçla çalışma [27]'de, Suudi Arabistan'da meme kanseri hastalarını eğitmek için semantik bir sosyal ağ sistemi kurma fikrini ortaya koymuşlardır. Önerdikleri sistemde, sosyal ağların genel özelliklerini anlamsal ağ teknolojilerinin gücü ile harmanlayarak, Suudi Arabistan'daki meme kanseri hastalarının eğitiminde web uygulamalarının kullanılmasını amaçlamışlardır. Bu hastaların profillerini bir semantik katmanla zenginleştirerek akıllı arama sorgularının hasta için uygun materyalleri almasını sağlayacaklardır. Sistemlerinin hedefi, meme kanseri

hastalarının birbirleriyle ve dış dünyayla konuşmalarını ve iletişim kurmalarını sağlamak, aynı zamanda hastaların meme kanseri konusundaki farkındalıklarını artırmak için bilgi alışverişinde bulunabilecekleri bir platform oluşturmaktır.

Sosyal ağların artarak devam eden bu potansiyeli ile gerek sosyal ağ analizi, gerekse içerik analizi olarak çok fazla sayıda akademik çalışma ortaya çıkmıştır Çalışma [28]'de, sosyal ağa yüklenen bir görüntü üzerine yapılan yorumlardan duygu çıkarımı yapan bir yaklaşım önermişlerdir ve gizli anlamsal analiz yönteminin genişletilmiş ve iyileştirilmiş eklentileri ile yeni bir metodoloji geliştirmişlerdir. Çalışma [29]'da, hem görsel içeriği hem de resimlere ilişkin yorum, altyazı vb. gibi bağlamsal bilgileri dikkate alarak büyük ölçekli sosyal medya görüntülerinden insani duyguları anlama sorununu incelemişlerdir. Bu problemin zorluğu, düşük seviye görsel özellikler ve üst düzey resim duyguları arasındaki anlamsal boşluktur. Sosyal medya imgelerinin büyük çoğunluğunda uygun ek açıklamaların ve etiketlerin bulunmaması başka bir zorluğu meydana getirmektedir. Bu iki sorunu çözmek amacıyla, sosyal medya görüntüleri için yeni bir Denetimsiz Duygu Analizi çerçevesi önermişlerdir. Resim duygularının tahminindeki anlamsal boşluğu aşmak için, görsel içerik ve ilgili içeriğe dayalı bilgiler arasındaki ilişkileri kullanmışlardır. Çalışma [30]'da, komorbiditeye (tıp dilinde iki veya daha fazla hastalığın belirli bir zaman diliminde birlikte bulunması) neden olan ve aynı anda var olan ortak koşulların vurgulandığı akıl sağlığı ve davranışsal çalışmalar alanındaki giderek artan eğilimlerin tespit edilmesini amaçlamışlardır. Hastaların yapılandırılmamış metinlerinden elde edilen kişilik özelliklerinin ve genel sosyal kullanıcı ifadelerinin istatistiksel analizle karşılaştırıldığı yeni bir yaklaşım sunmuşlardır. Bu yaklaşımın temelini, psikiyatrik bozukluk belirleme algoritmaları ile sağlamışlardır. Ayrıca, hastaların kişilik özelliklerini gösteren kullanıcıların, sosyal medya verilerini bağımlılık kategorisi belirleme algoritmalarından doğal dil işleme ve ontoloji tabanlı bilgi çıkarma tekniklerini kullanarak semantik tabanlı metin sınıflandırmasına tabi tutmuşlardır.

Çalışma [31]'de, sosyal medyada paylaşılan resimlerden özellikle cinsiyet bilgilerini içeren kullanıcı özniteliklerini çıkarmak için bir yöntem önermişlerdir. Cinsiyet tahmininde bulunmak için, bir kişinin tüm özet akışından gelen resimlerdeki anlamsal bilgi dağılımını göz önüne almışlardır. Bu anlamsal dağılımı hesaplamak için, nesnelere, sahneleri ve etkinlikleri tanımak amacıyla modeller eğitmişlerdir ve bunları her bir kullanıcının resimlerine uygulamışlardır. On bin twitter kullanıcısı üzerinde gerçekleştirilen denemeler ve yarım milyon görüntü koleksiyonu, cinsiyetin kullanıcıların

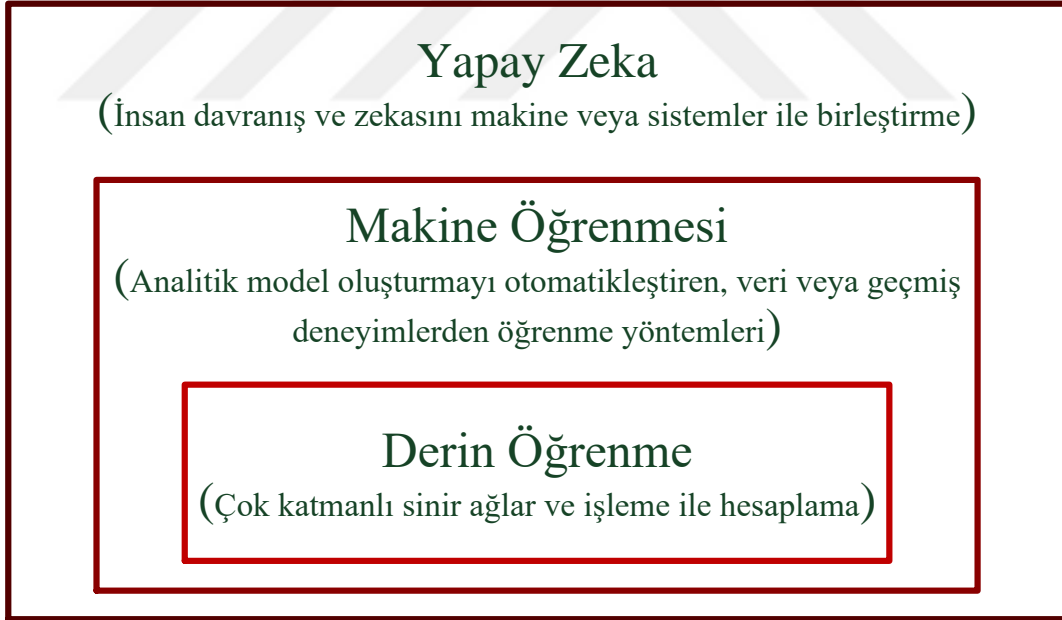
resim paylaşımlarından ortaya çıkarılabildiğini % 75.6 doğruluk ile göstermiştir. Ayrıca, görsel ipuçları kombinasyonu metinsel verilerle kombine edildiğinde cinsiyet tahmini doğruluk oranının % 88'e çıkarılabileceğini gözler önüne sermişlerdir. Çalışma [32]'de, düşük seviyeli görsel görüntü özelliklerinin (renk, şekil ve doku özellikleri) etkili bir şekilde birleştirilmesine dayanan içerik tabanlı görüntü elde etme yönteminin medikal sosyal ağ ile birlikte çalıştığı bir yaklaşım önermişlerdir. İçerik tabanlı medikal görüntü elde etme sistemi; yeni bir görüntü ile görsel olarak benzer kayıtlı görüntülerin depolanmasına, uzman ve hastaların geçmişteki muayene teşhislerini ve diğer doktorların ek açıklamalarını kontrol etmesine, sonuç olarak da yeni bir teşhis koymasına veya görüntü muayenesi için yeni bir rapor hazırlanmasına olanak sağlamaktadır.

Sosyal ağ verilerinin, kullanıcılar için tavsiye sistemlerinin geliştirilmesi, eğitim alanında değerlendirmeler yapılması, duygu ve düşünce analizi, eksik bilgi çıkarımı ve sosyal ilişki analizi gibi birçok kullanım alanı ortaya çıkmıştır [33].



3. DERİN ÖĞRENME VE DERİN AĞLAR

Günümüzde yapay zeka, makine öğrenmesi ve derin öğrenme, akıllıca davranan sistemleri veya yazılımları tanımlamak için bazen birbirinin yerine kullanılan üç popüler terimdir. Şekil 3.1'de, makine öğrenmesi ve yapay zeka ile karşılaştırıldığında derin öğrenmenin konumu gösterilmektedir. Buna göre, makine öğrenmesi derin öğrenmeyi kapsamakla birlikte, her ikisi de geniş alanda yapay zekanın bir parçasıdır. Genel olarak yapay zeka, insan davranışını ve zekasını makinelere veya sistemlere dahil ederken [34], makine öğrenmesi ise analitik model oluşturmayı otomatikleştiren verilerden veya deneyimlerden öğrenir [35]. Derin öğrenme ise, hesaplamaların çok katmanlı sinir ağları yoluyla yapıldığı verilerden öğrenme yöntemlerini temsil eder. Derin öğrenme metodolojisindeki "derin" terimi, veriye dayalı bir model oluşturmak için verilerin işlendiği birden çok düzey veya aşama kavramını ifade eder.



Şekil 3.1. Derin öğrenme.

Derin Öğrenme, hayatın neredeyse her alanında Yapay Zekanın modern yükselişine önemli bir katkıda bulunur [3]. Bu, bilgisayarlı görü [36], doğal dil işleme [37], DNA analizi [38], parçacık fiziği [39], kimyasal yapı analizi [40] ve beyin devreleri çalışmaları [41] vb. gibi çok çeşitli bilimsel alanlara uygulanmasından kaynaklanan girişimlerin

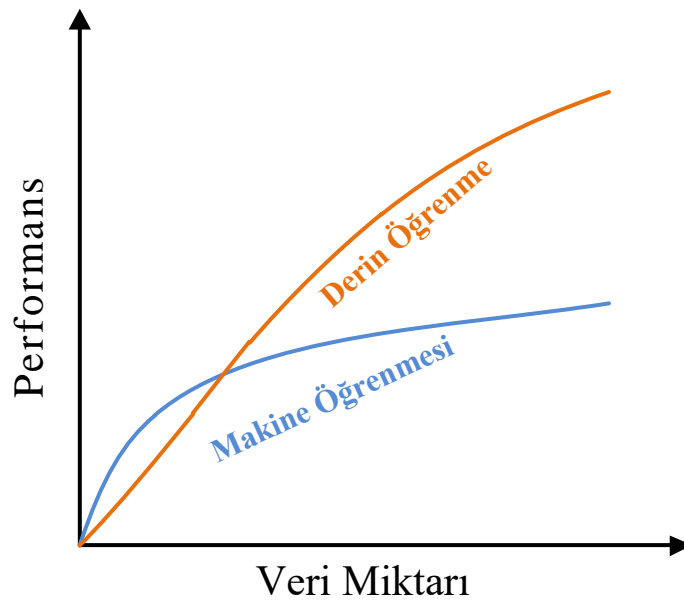
doğrudan bir sonucudur.

Derin öğrenmenin kökenleri 1940'lara kadar izlenebilse de [42], modern çağın karmaşık problemlerini çözmek için kullanımındaki ani artış, üç temel nedenden kaynaklanmaktadır [3]. Bunlardan ilki, büyük miktarda eğitim verisinin mevcudiyetidir. Son zamanlarda bilginin her yerde sayısallaştırılmasıyla birlikte karmaşık hesaplama modellerini eğitmek için çok büyük miktarda veri ortaya çıkmaktadır. Derin öğrenme, temel hesaplama bloklarının birden çok katmanını basitçe istifleyerek karmaşık işlevleri modelleme konusunda kendine özgü bir yeteneğe sahiptir. Bu nedenle, zor problemlerle başa çıkmak için uygun bir seçimdir. Ancak, nispeten daha küçük eğitim veri setlerinin olması, yakın zamana kadar derin öğrenmenin faydasını kısıtlamıştı. İkinci neden güçlü hesaplama kaynaklarının mevcudiyetidir. Büyük miktarda veri üzerinden karmaşık işlevleri öğrenmek, muazzam hesaplama gereksinimlerine ihtiyaç duyar. İlgili araştırma toplulukları bu tür gereksinimleri ancak son zamanlarda yerine getirebilmektedir. Üçüncü neden ise derin öğrenme algoritmalarını uygulayan çeşitli programlama dillerinde (Java, Python, C#, C++ vb.) yazılmış birçok kütüphane dosyasının mevcudiyetidir. Farklı araştırma topluluklarında, kaynak kodlarını kamu platformlarında yayınlamaya yönelik artan bir eğilim vardır. TensorFlow, Lasagne, Keras, MXNet, Caffe, Torch en çok tercih edilen kütüphanelerdir. Bu kütüphaneler, çok katmanlı algılayıcı, tekrarlayan sinir ağı, otomatik kodlayıcı gibi birçok derin öğrenme modelini desteklemektedir. Derin öğrenme algoritma uygulamalarına kolay erişim, bu tekniğin birçok uygulama alanında kullanımını artırmıştır.

Medikal görüntüleme alanı, 1960'lardan beri makine öğrenmesinden yararlanmaktadır [43], [44]. Ancak, modern derin öğrenme teknikleriyle ilgili ilk dikkate değer katkılar, 1990'larda medikal görüntüleme literatüründe ortaya çıkmıştır [45][46][47]. Bu yöntemlerin modern derin öğrenme ile ilişkisi, medikal görüntüleme görevlerini yerine getirmek için YSA'ların kullanılması şeklindedir. Bununla birlikte, eğitim verilerinin miktarı ve hesaplama kaynakları ile sınırlı olan bu çalışmalar, yalnızca iki ila üç katman derinliğinde olan ağları eğitmektedir. Bu modern çağda artık 'derin' olarak kabul edilmemektedir. Günümüz derin öğrenme modellerindeki katman sayısı genellikle bir düzineden yüzün üzerine kadar değişmektedir [48]. 2012 yılına gelindiğinde ise, derin öğrenme, çok zor bir görüntü sınıflandırma görevini dikkate değer bir doğrulukla gerçekleştirerek bilgisayarlı görme alanında büyük bir atılım sağlamıştır [49]. O zamandan beri, Görüntü İşleme topluluğu ana odağını kademeli olarak derin öğrenmeye

kaydırmıştır. Sonuç olarak, medikal görüntüleme literatürü de 2013 yılı civarında derin sinir ağlarından yararlanan yöntemlere tanık olmaya başlamıştır ve şimdiye kadar bu tür yöntemler ile ilgili yapılan birçok çalışma ortaya çıkmıştır [50][3].

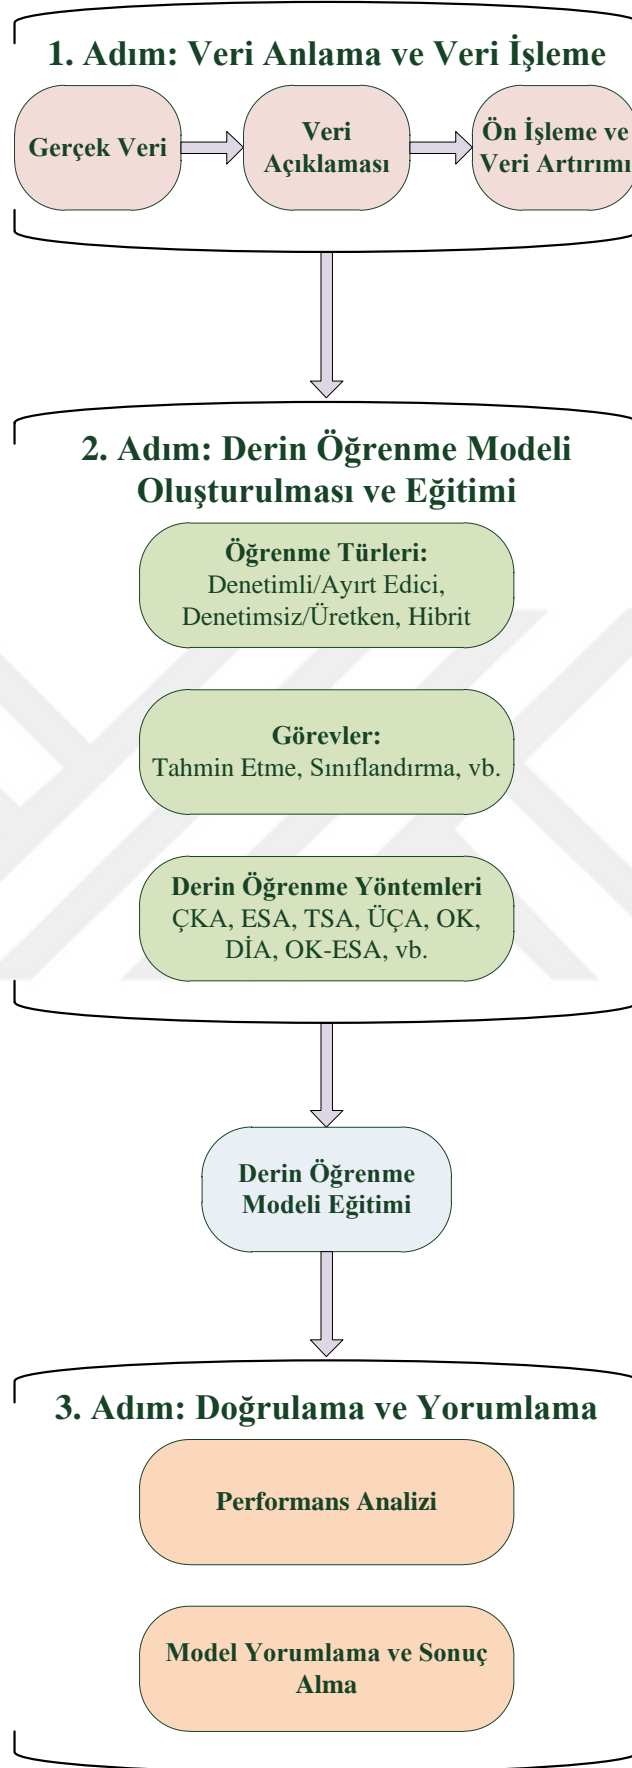
Makine öğrenmesi algoritmaları ile derin öğrenme algoritmaları arasındaki fark, yaklaşımdır. Derin öğrenme, inanılmaz bir hesaplama gücüne sahip olan ancak aynı zamanda iyi sonuçlar vermek için çok fazla veri ve güçlü donanım gerektiren sinir ağlarını kullanır. Derin öğrenme kendi kendine öğrenebilen sinir ağları oluşturmaya dayanırken, makine öğrenmesi algoritmaları, verileri alıp ondan öğrenmeye ve daha fazla uygulamaya çalışan klasik algoritmalar olarak kabul edilir. Derin öğrenme modellerinin ortak amacı, bir eğitim veri seti kullanarak hesaplamalı modelin parametrelerini yinelemeli olarak öğrenmektir, böylece model istenen bir görevi yerine getirirken kademeli olarak daha iyi hale gelir. Hesaplamalı modelin kendisi genellikle çoklu nöron/algılayıcı katmanlarından [9] ve temel hesaplama bloklarından oluşan bir YSA [51] şeklini alırken, farklı katmanlardaki nöronlar arasında ağ ağırlıkları olarak bilinen parametreler bağlantıların gücünü belirtir. Derin öğrenme modelleri, belirli bir görev için eğitildikten sonra, daha önce görülmemiş çeşitli veriler yani test verileri üzerinde aynı görevi doğru bir şekilde gerçekleştirebilir. Derin öğrenmenin bu güçlü genelleme yeteneği, şu anda onu diğer makine öğrenmesi tekniklerinden öne çıkarmaktadır [3]. Şekil 3.2, veri miktarı dikkate alınarak derin öğrenme ve makine öğrenmesi modellerinin genel performans karşılaştırmasını göstermektedir [2].



Şekil 3.2. Derin öğrenme ve makine öğrenmesi veri miktarı-performans karşılaştırması.

Tez çalışmasında derin öğrenme tekniklerinin seçilmesinin sebebi ise, etiketlenmiş görüntü içeren eğitim setlerinde kendiliğinden özellik çıkarma işlemini becerebilen, makine öğrenmesinin aksine çok katmanlı sinir ağlarını bir arada kullanılmasına olanak sağlayan bir sistem olmasından kaynaklanmaktadır. Amaç, görüntü işlemlerde daha hızlı, verimli ve en önemlisi otomatik olarak öznelikler çıkarıp bunu sonuca yansıtmaktır. Geleneksel yöntemlerde ise bu işlev elle girilmektedir. Derin öğrenme modellerinin belki en iyi özelliklerinden bir tanesi de, bir görüntünün sınıflandırılmasında tasarlanan çok sayıda farklı modelle birlikte birçok yöntemin iç içe kullanılabilmesine olanak sağlamasıdır. Bu sayede daha iyi sonuçlar elde edilebilmektedir. Tez çalışmasında hibrit derin öğrenme sistemlerinin uygulanmasının sebebi ise budur. Derin öğrenme modellerini birbiriyle kıyasladığımızda, en önemli dezavantajı ise çok sayıda katman ve parametreden oluşmasıdır. Mimarilerin karmaşıklığı, elde edilen performansı zaman zaman da olumsuz etkileyebilmektedir.

Son yıllarda, görüntü sınıflandırmasında önemli atılımlar yapan derin öğrenme teknikleri günümüzde tıbbi teşhiste sıklıkla kullanılmaktadır. Derin öğrenme algoritmaları, özellikle evrimsel ağlar, tıbbi görüntüleri analiz etmek için hızla tercih edilen bir metodoloji haline geldi. Bu bölümde, hiyerarşik yapıda tipik olarak birkaç bilgi işleme aşaması katmanını dikkate alan çeşitli derin sinir ağı teknikleri incelenecektir. Tipik bir derin sinir ağı, giriş ve çıkış katmanları dahil olmak üzere birden çok gizli katman içerir. Bu bölümde ayrıca, çeşitli problemleri çözmek için nasıl kullanıldıklarına bağlı olarak derin öğrenme tekniklerine ilişkin sınıflandırma sunulmaktadır. Şekil 3.3'te, gerçek dünya sorunlarını çözmek için veri anlama ve ön işleme, derin öğrenme modeli oluşturma ve eğitim ile doğrulama ve yorumlama gibi üç işleme adımından oluşan bir derin öğrenme iş akışı gösterilmektedir. Bu akış, genellikle makine öğrenmesi modellemesiyle aynı işlem aşamalarını takip eder ancak, makine öğrenmesi modellemesinden farklı olarak, derin öğrenme modellerinde özellik çıkarımı otomatiktir [2].



Şekil 3.3. Derin öğrenme iş akışı.

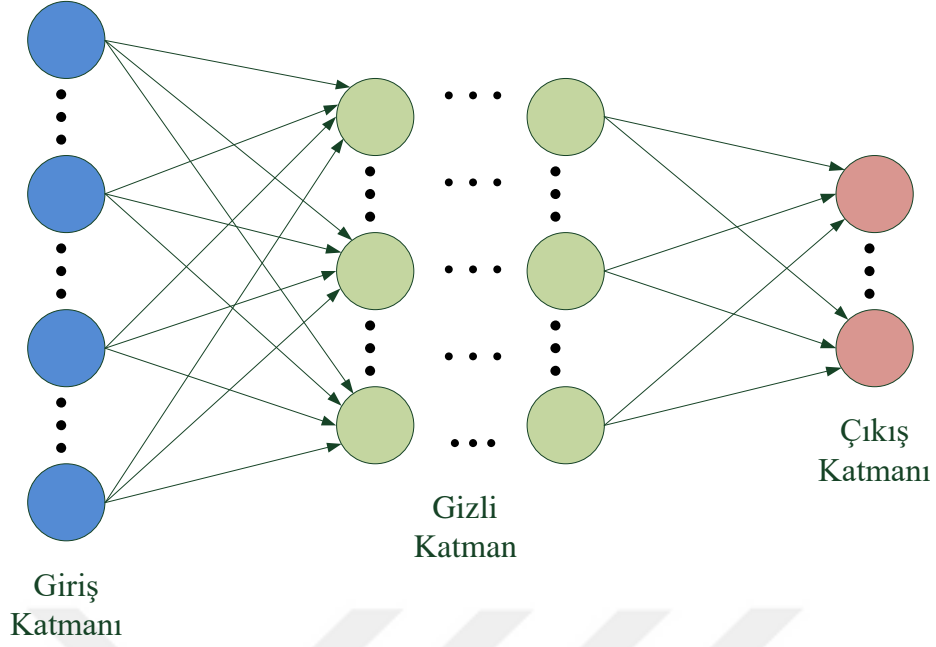
Derin öğrenme tekniklerinin detaylarını incelemeden önce, çeşitli öğrenme görevlerini açıklamak faydalı olacaktır. Bunlardan ilki, etiketli eğitim verilerini kullanan görev odaklı bir yaklaşım olan Denetimli Öğrenme, ikincisi ise etiketlenmemiş veri kümelerini analiz eden veri odaklı bir süreç olan Denetimsiz Öğrenmedir. Bir diğeri, hem denetimli hem de denetimsiz yöntemlerin melezleştirilmesi ile ortaya çıkan Yarı Denetimli Öğrenme ve son olarak ise çevre odaklı bir yaklaşım olan Takviyeli Öğrenmedir. Takviyeli Öğrenme, kendi başına kararlar alabilen bir sistemin, bulunduğu ortamı algılayarak hedefine ulaşabilmesi için doğru kararlar almayı nasıl öğrenebileceğini gösterir. Bunlara bağlı olarak, sınıflandırma yaparken derin öğrenme tekniklerini genel olarak üç ana kategoriye ayırmak mümkündür; (i) denetimli veya ayırt edici öğrenme için derin ağlar, (ii) denetimsiz veya üretken öğrenme için derin ağlar ve (iii) her ikisini ve ilgili diğerlerini birleştiren hibrit öğrenme için derin ağlar [2]. İlerleyen kısımlarda, çeşitli uygulama alanlarında gerçek dünya sorunlarını çözmek için kullanılacak bu tekniklerden, özellikle tıbbi görüntüleri analiz etmek için kullanılan ve bu tez çalışmasında ele alınanlardan her biri detaylı olarak açıklanmaktadır.

3.1. DENETİMLİ/AYIRT EDİCİ ÖĞRENME İÇİN DERİN AĞLAR

Derin Öğrenme tekniklerinin bu kategorisi, sınıflandırma uygulamalarında ayırt edici bir işlev sağlamak için kullanılır. Modellerin eğitilmesinde girdilere ve beklenen çıktılara sahip etiketli veri setleri kullanılır. Yani algoritma bir bilgi hakkında bir karar verdiğinde, verilere dahil edilen etiketleri kullanarak bu kararın doğru olup olmadığını kontrol edebilir. Denetimli veya ayırt edici öğrenme için yaygın olarak kullanılan mimariler, temel olarak Çok Katmanlı Algılayıcı (ÇKA), Evrişimsel Sinir Ağı (ESA), Tekrarlayan Sinir Ağı(TSA) ve bunların varyantlarını içerir.

3.1.1. Çok Katmanlı Algılayıcı (ÇKA)

Denetimli bir öğrenme yaklaşımı olan ÇKA, bir tür ileri beslemeli yapay sinir ağıdır [52], [53]. Derin sinir ağlarının veya derin öğrenmenin temel mimarisi olarak da bilinir. Tipik bir ÇKA, giriş verilerini alan bir giriş katmanından, giriş sinyali hakkında bir karar veya tahminde bulunan bir çıkış katmanından ve bu ikisi arasında ağı hesaplama motoru olarak kabul edilen bir veya daha fazla gizli katmandan oluşan tamamen bağlı bir ağıdır [54]. ÇKA mimarisi Şekil 3.4'te gösterilmektedir.

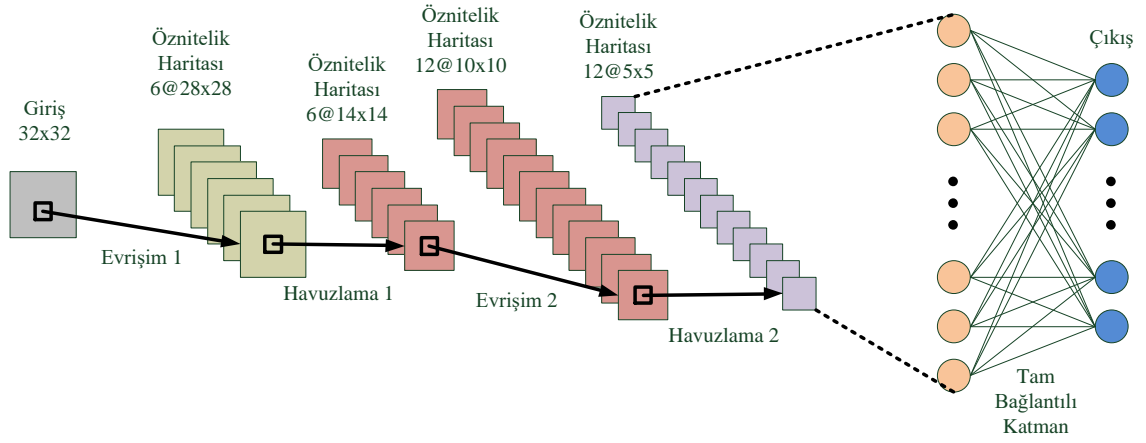


Şekil 3.4. Çok katmanlı algılayıcı (ÇKA) mimarisi.

Bir ÇKA ağının çıktısı, Doğrultucu Doğrusal Birim (Rectifier Linear Unit-ReLU), Tanh, Sigmoid ve Softmax gibi transfer fonksiyonları olarak da bilinen çeşitli aktivasyon fonksiyonları kullanılarak belirlenir. ÇKA'yı eğitmek için, bir sinir ağının en temel yapı taşı olarak da bilinen ve denetimli bir öğrenme tekniği olan, "Geri Yayılm" algoritması kullanılır. Eğitim sürecinde Stokastik Gradyan Düşüşü (SGD), Sınırlı Bellek Broyden-Fletcher-Goldfarb-Shanno (L-BFGS) ve Uyarlamalı Moment Tahmini (Adam) gibi çeşitli optimizasyon yaklaşımları uygulanmaktadır [55]. ÇKA, karmaşık bir modelin çözümünü hesaplama açısından pahalı hale getirebilecek gizli katman sayısı, nöronlar ve yinelemeler gibi çeşitli hiperparametrelerin ayarlanmasını gerektirir. Bununla birlikte, kısmi uyum yoluyla, doğrusal olmayan modelleri gerçek zamanlı veya çevrimiçi öğrenme avantajı sunar.

3.1.2. Evrimsel Sinir Ağı (ESA)

ESA [56], özellik çıkarımında insana ihtiyaç duymadan doğrudan girdiden öğrenen popüler bir ayırt edici derin öğrenme mimarisidir. Şekil 3.5, çoklu evrişim ve havuzlama katmanları içeren bir ESA örneğini göstermektedir. ESA'daki her katman, anlamlı bir çıktı için optimum parametreleri hesaba katmanın yanı sıra model karmaşıklığını azaltır. ESA ayrıca, geleneksel bir ağda meydana gelebilecek aşırı uydurma sorunuyla başa çıkabilen bir bırakma (dropout) kullanır [57]. Evrişim, değişimi ifade eden bir sonuç işlevi vermek için uygulanan, özel doğrusal bir matematiksel işlem olarak ifade edilebilir.



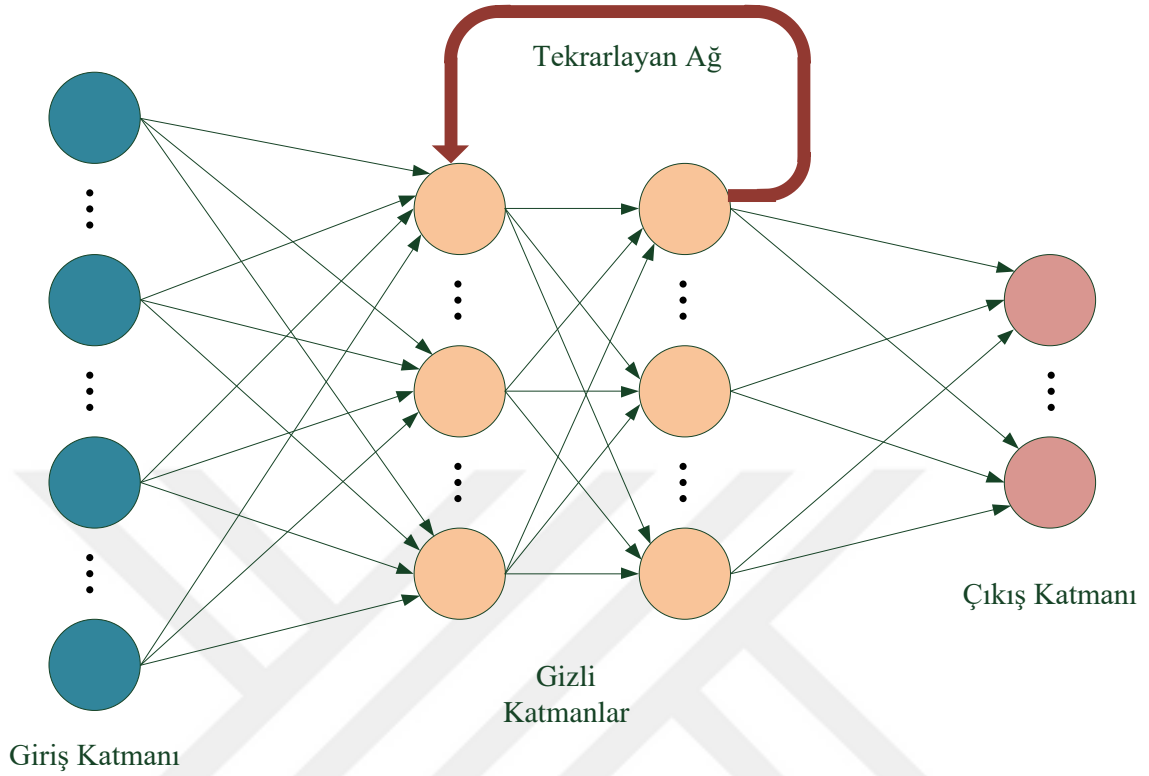
Şekil 3.5. Çoklu evrişim ve havuzlama katmanı içeren bir Evrişimsel Sinir Ağı (ESA) örneği.

ESA'lar özellikle çeşitli 2D şekillerle ilgilenmek için tasarlanmıştır ve bu nedenle görsel tanıma, tıbbi görüntü analizi, görüntü bölümlendirme, doğal dil işleme ve daha birçok alanda yaygın olarak kullanılmaktadır [55]. İnsan müdahalesine gerek kalmadan girdiden temel özellikleri otomatik olarak keşfetme yeteneği, onu geleneksel bir ağdan daha güçlü kılar. ESA'nın öğrenme yeteneklerine göre VGG [58][59], ResNet [48], AlexNet [49], Xception [60], Inception [61] vb. gibi, çeşitli alanlarda kullanılabilen farklı varyantları vardır. Örneğin, AlexNet modeline dayalı ESA, beş konvolüsyonel katman, iki tamamen bağlı katman ve bir softmax çıktı katmanı içerir [49].

3.1.3. Tekrarlayan Sinir Ağı (TSA)

Başka bir popüler sinir ağı olan TSA, sıralı veya zaman serisi verileri kullanır ve önceki adımın çıktısını mevcut aşamaya girdi olarak besler [62]. Tekrarlayan ağlar, ileri beslemeli sinir ağları ve ESA gibi, eğitim girdilerinden öğrenirler; ancak önceki girdilerden gelen bilgileri kullanarak mevcut girdi ve çıktıyı etkilemelerine izin veren hafızaları ile ayırt edilirler [63]. Girişlerin ve çıkışların birbirinden bağımsız olduğunu varsayan tipik derin sinir ağlarının aksine, TSA'nın çıkışı dizi içindeki önceki öğelere bağlıdır. Şekil 3.6'da TSA modeli yer almaktadır. Bir giriş katmanına, iki gizli katmana ve bir çıkış katmanına sahip bu modelde, bu katmanların hepsi bağımsız şekilde çalışmaktadır. Dolayısıyla her katmanın kendine göre bir işlevi vardır ve her katman farklı bir işlevi yerine getirir. TSA'da mevcut girdinin çıktısı geçmiş bir hesaplamaya bağlı olduğundan, doğası gereği tekrarlardır. Çıktı üretildikten sonra kopyalanır ve tekrarlayan ağa geri gönderilir. Tekrarlanan bu aşamalar sonucunda bir önceki giriş durumu depolanır ve yeni elde edilen giriş değeriyle birleştirilir. Bu sayede, yeni elde edilen girişin bir

önceki girişle olan ilişkisi sağlanır. Karar verilirken mevcut girdi ve bir önceki girdiden öğrendiği çıktı dikkate alınır.



Şekil 3.6. Tekrarlayan Sinir Ağı (TSA) modeli.

Bununla birlikte, standart tekrarlayan ağlar, uzun veri dizilerini öğrenmeyi zorlaştıran kaybolan gradyanlar sorununa sahiptir. Aşağıda, sorunları en aza indiren ve birçok gerçek dünya uygulama alanında iyi performans gösteren tekrarlayan ağın birkaç popüler varyantı incelenmektedir.

-Uzun kısa süreli bellek (UKSB)

Yaygın olarak LSTM (Long Short-Term Memory) olarak bilinen, Hochreiter ve diğerleri tarafından tanımlanan bu mimari, kaybolan gradyan problemiyle başa çıkmak için özel birimler kullanan popüler bir TSA mimarisi biçimidir [64]. Bir LSTM birimindeki bir bellek hücresi, verileri uzun süreler boyunca saklayabilir ve hücrenin içine ve dışına bilgi akışı üç kapı tarafından yönetilir. Unutma kapısı önceki durum hücresinden hangi bilgilerin hafızaya alınacağını ve artık yararlı olmayan hangi bilgilerin kaldırılacağını belirlerken, giriş kapısı hangi bilgilerin hücre durumuna girmesi gerektiğini, çıkış kapısı ise çıktıları belirler ve kontrol eder. Tekrarlayan bir ağın eğitilmesi sorunlarını çözdüğü için, LSTM ağı en başarılı TSA'lerden biri olarak kabul edilir.

-Çift yönlü TSA/LSTM

Çift yönlü TSA'lar, zıt yönlerde çalışan iki gizli katmanı tek bir çıktıya bağlayarak hem geçmişten hem de gelecekte veri kabul etmelerini sağlar. Çift yönlü TSA'lar, geleneksel tekrarlayan ağların aksine, aynı anda hem pozitif hem de negatif zaman yönlerini tahmin etmek için eğitilmiştir. Genellikle BiLSTM olarak bilinen Çift Yönlü LSTM, dizi sınıflandırma konularında model performansını artırabilen standart LSTM'nin bir uzantısıdır [65]. İki LSTM'den oluşan bir dizi işleme modelidir: biri girdiyi ileri, diğeri geri alır. Özellikle çift yönlü LSTM, doğal dil işleme görevlerinde popüler bir seçimdir [66].

-Geçitli tekrarlayan birim (GTB)

Cho ve diğerleri tarafından tanıtılan GTB, sinir ağındaki hücreler arasındaki bilgi akışını kontrol etmek ve yönetmek için geçitleme yöntemlerini kullanan tekrarlayan ağı bir başka popüler çeşiddir [67]. GTB bir LSTM gibidir, ancak daha az parametreye sahiptir. Çünkü bir sıfırlama kapısına ve bir de güncelleme kapısına sahip olmasına rağmen çıkış kapısı yoktur. Bu nedenle, GTB ve LSTM arasındaki temel fark, GTB'nin sıfırlama ve güncelleme kapıları olmak üzere iki kapısı, LSTM'nin giriş, çıkış ve unutma kapıları olmak üzere üç kapısı olmasıdır. GTB'nin yapısı, dizinin önceki bölümlerinden gelen bilgileri atmadan, büyük veri dizilerinden bağımlılıkların uyarlanabilir bir şekilde yakalanmasını sağlar. Bu nedenle GTB, genellikle karşılaştırılabilir performans sunan ve hesaplaması önemli ölçüde daha hızlı olan biraz daha modern bir varyanttır [68]. GTB'lerin daha küçük ve daha seyrek belirli veri kümelerinde daha iyi performans sergiledikleri gösterilmiş olsa da [69], TSA'nın her iki varyantı da sonuç üretirken etkinliklerini kanıtlamıştır.

Genel olarak, tekrarlayan bir ağı temel özelliği, aktivasyonların döngüye girmesini sağlayan en az bir geri besleme bağlantısına sahip olmasıdır. Bu geri besleme bağlantısı, ağların dizi tanıma, dizi öğrenme ve yeniden oluşturma, zamansal ilişkilendirme veya tahmin gibi zamansal işleme yapmasına izin verir. Tekrarlayan ağların, tahmin problemleri, makine çevirisi, doğal dil işleme, metin özetleme, konuşma tanıma ve çok daha fazla sayıda popüler uygulama alanı vardır [55].

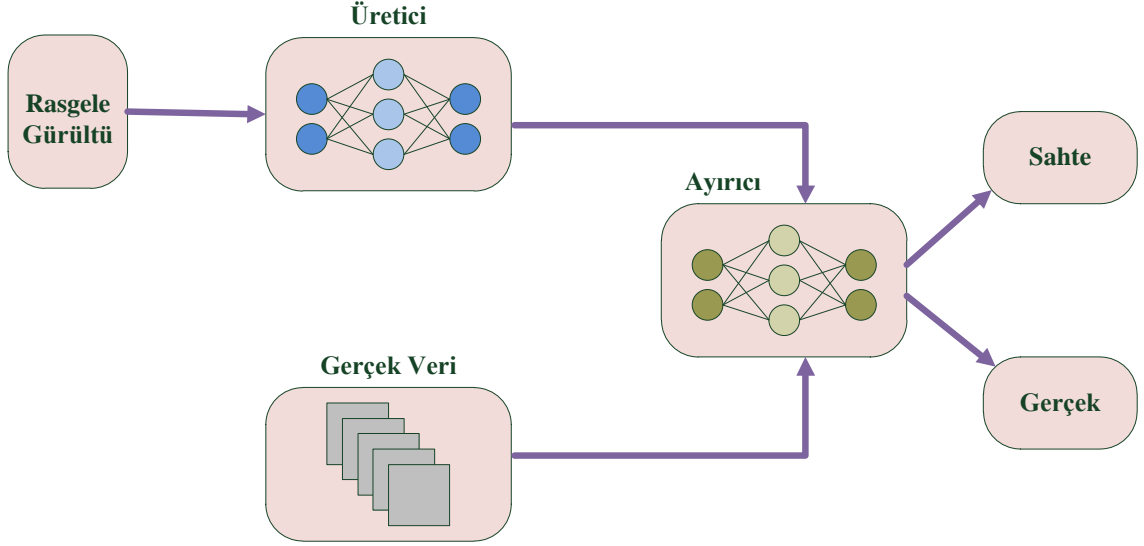
3.2. DENETİMSİZ/ÜRETKEN ÖĞRENME İÇİN DERİN AĞLAR

Derin öğrenme tekniklerinin bu kategorisi tipik olarak, model analizi veya sentezi için

yüksek dereceli korelasyon özelliklerini ve görünür verilerin ve bunlarla ilişkili sınıfların ortak istatistiksel dağılımlarını karakterize etmek için kullanılır [70]. Üretken derin mimarilerde ana fikir, öğrenme süreci sırasında hedef sınıf etiketleri gibi kesin denetim bilgilerinin önemli olmamasıdır. Bu kategori altındaki yöntemler, tipik olarak özellik öğrenme veya veri oluşturma ve temsil etme için kullanılır. Böylece üretici modelleme, denetimli öğrenme görevleri için ön işleme olarak da kullanılabilir ve bu da ayırt edici modelin doğruluğunu sağlar [71]. Denetimsiz veya üretken öğrenme için yaygın olarak kullanılan derin sinir ağı teknikleri, Üretken Çekişmeli Ağ (ÜÇA), Kısıtlı Boltzmann Makinesi (KBM), Kendi Kendini Düzenleyen Harita (KDH), Otomatik Kodlayıcı (OK) ve Derin İnanç Ağı (DİA)'dır.

3.2.1. Üretken Çekişmeli Ağ (ÜÇA)

Ian Goodfellow tarafından tasarlanan ÜÇA, talep üzerine yeni makul örnekler oluşturmak için çalışan bir tür sinir ağı mimarisidir [72]. Modelin orijinal veri kümesinden yeni örnekler üretmek veya çıktı almak için kullanılabilmesi için, girdi verilerindeki düzenlilikleri veya kalıpları otomatik olarak keşfetmesi ve öğrenmesi gerekir. Bu üretken model İngilizce yazılışının baş harfleriyle "GAN" olarak anılmaktadır. Klasik derin ağ mimarilerinden farklı olarak bir üretici (generative, G) ve bir ayırıcı (discriminator, D) olmak üzere iki farklı derin sinir ağından oluşur. Üretici derin ağ, dışardan gelen gürültü sinyalleri gibi rastgele değişkenler ile veri tabanındakilere benzer görüntüler üretmeye çalışmaktadır. Ayırıcı derin ağ ise, yapay olarak üretilen sahte görüntüler ile veri tabanındaki gerçek görüntüleri birbirinden ayırt etmeye çalışmaktadır. G üreticisi orijinal verilere benzer özelliklere sahip yeni veriler oluşturken, D ayırıcısı üretici tarafından sağlanan verilerden ziyade gerçek verilerden alınan sonraki bir örneğin olasılığını tahmin eder. Böylece, ÜÇA modellemede hem üretici hem de ayırıcı birbiriyle rekabet edecek şekilde paralel olarak eğitilir ve bu iki ağın çekişmeli olarak çalışmasıyla öğrenme işlemi gerçekleştirilir [73]. Şekil 3.7'de, temel bir ÜÇA mimarisi gösterilmektedir.




Şekil 3.7. Standart bir Üretken Çekişmeli Ağ (ÜÇA) çalışma yapısı.

ÜÇA genel olarak denetimsiz öğrenme görevleri için tasarlanmıştır, ancak göreve bağlı olarak yarı denetimli ve takviyeli öğrenme için de iyi bir çözüm olduğu kanıtlanmıştır [74]. ÜÇA'lar ayrıca, gizli özellik uzayının hizalanması için son teknoloji transfer öğrenme araştırmalarında da kullanılmaktadır [75]. Çift Yönlü ÜÇA'lar (Bidirectional GAN) [76] gibi ters modeller, Standart ÜÇA modelinin gizli bir alandan veri dağılımına eşlemeyi öğrenmesine benzer şekilde, verilerden gizli bir alana eşlemeyi öğrenebilir. GAN ağlarının sağlık, görüntü analizi, veri artırma, video üretimi, ses üretimi, pandemiler, trafik kontrolü, siber güvenlik ve hızla artan daha birçok potansiyel uygulama alanı vardır. Genel olarak, ÜÇA'lar kendilerini kapsamlı bir bağımsız veri genişletme alanı ve üretken bir çözüm gerektiren sorunlara çözüm olarak kurmuşlardır.

3.2.2. Kısıtlı Boltzmann Makinesi (KBM)

Birçok farklı veri türünün üretken modelleri olarak kullanılan KBM'nin temelleri, Ackley, Hinton ve Sejnowski tarafından ilk defa 1985 yılında yayınlanan "A Learning Algorithm for Boltzmann Machines" adlı makale ile sunulan öğrenme algoritmasının prensiplerine dayandırılmaktadır [77]. KBM aynı zamanda girdileri boyunca bir olasılık dağılımı öğrenebilen üretken bir rastlantısal sinir ağıdır [78]. Boltzmann makineleri tipik olarak görünür ve gizli düğümlerden oluşur ve her düğüm diğer tüm düğümlere bağlıdır, bu da sistemin normal koşullarda nasıl çalıştığını öğrenerek düzensizlikleri anlamamıza yardımcı olur. KBM'ler ise Boltzmann makinelerinin bir alt kümesi olup, görünür ve gizli katmanlar arasındaki bağlantı sayısında bir sınır vardır. Bu kısıtlama, gradyan tabanlı kontrastlı sapma algoritması gibi eğitim algoritmalarının genel olarak Boltzmann

makinelerinden daha verimli olmasına izin verir [79]. Biraz daha detaylı açıklamak gerekirse, KBM yapısındaki düğümler birbirine katmanlar halinde bağlanır, ancak aynı katmandaki iki düğüm birbirine bağlanmaz. Bundan dolayı katman içi iletişim yoktur ve KBM'lerin temel kısıtlaması budur. Her düğüm, girdiyi işleyen ve bu girişi iletilmeyeceği konusunda rastgele kararlar alan bir hesaplama odağıdır. Şekil 3.8'de KBM'nin ağ yapısı gösterilmektedir.



Şekil 3.8. Kısıtlı Boltzmann Makinesi (KBM)'nin ağ yapısı.

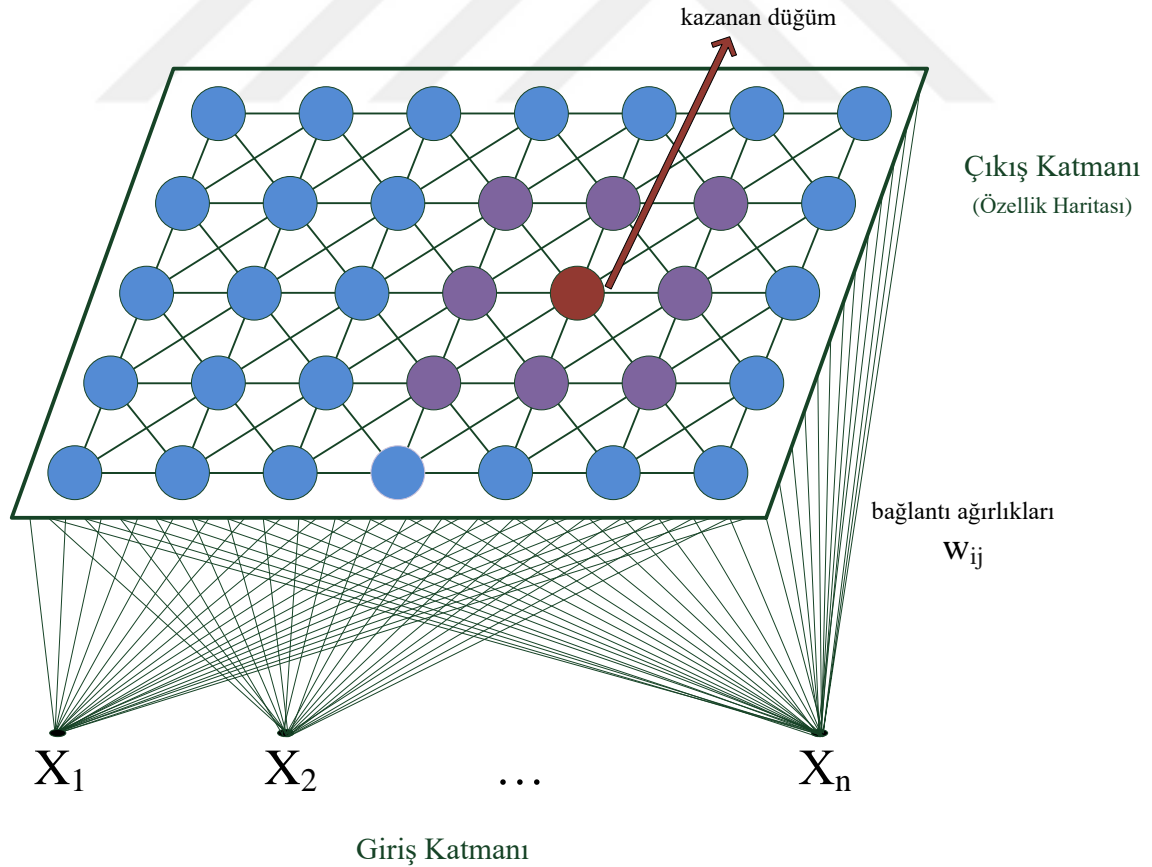
KBM'lerde ikili düğümlerin iki katmanı vardır. Bunlardan ilki görünür düğümlerin olduğu, diğeri ise gizli düğümlerin olduğu katmandır. Bu açıdan, KBM'ler iki parçalı (bipartite) çizge olarak görülebilir [80]. Görünür katman, dışarıdan girdi olarak alınan verileri temsil ederken, gizli katman öğrenme yeteneğini artırmaktadır. KBM'ler, boyut azaltma, sınıflandırma, regresyon, işbirlikçi filtreleme, özellik öğrenme, konu modelleme ve başka pek çok konuda uygulama alanı bulmuştur. Derin öğrenme modellemesi alanında, göreve bağlı olarak denetimli veya denetimsiz olarak eğitilebilirler. Genel olarak, KBM'ler verilerdeki kalıpları otomatik olarak tanıyabilir. Ayrıca, özellik seçimi veya çıkarımının yanı sıra bir derin inanç ağı oluşturmak için kullanılan olasılıksal veya rastlantısal modeller geliştirebilir [2].

3.2.3. Kendi Kendini Düzenleyen Harita (KDH)

KDH tekniği ilk defa 1990 yılında Kohonen tarafından yayınlanan “The Self-Organizing Map” isimli çalışma ile tanınmıştır [81]. Bu nedenle Kohonen Haritası veya İngilizce kısaltmasıyla SOM (The Self-Organizing Map) olarak da bilinen bu teknik, kümeleme için yaygın olarak kullanılan bir sinir ağı tabanlı boyut azaltma algoritmasıdır [82]. Ayrıca, verilerin topolojik yapısını korurken daha yüksek boyutlu bir veri setinin düşük

boyutlu (genellikle iki boyutlu) bir temsilini oluşturmak için kullanılan denetimsiz öğrenme tekniğinin başka bir biçimidir.

KDH yapısı, Şekil 3.9'da görüldüğü gibi, nöronlardan veya düğümlerden oluşan bir kafestir. Izgarada, X ve Y koordinatında, her düğümün belirli bir topolojik konumu vardır ve girdi değişkenleriyle aynı boyutta bir ağırlık vektörü içerir. Girdi eğitim verileri, $X_1, X_2, X_3 \dots X_n$ gibi n boyutlu bir vektör kümesidir ve her düğüm, n boyuttaki karşılık gelen ağırlık vektörü w_{ij} 'den oluşur. Düğümler arasındaki çizgiler, basitçe bitişikliğin bir temsilidir ve diğer sinir ağlarında olduğu gibi herhangi bir bağlantıyı ifade etmez. KDH, bir dizi giriş sinyalini kabul eden ve bunlara yanıt veren nöronların bir kafesi veya ızgarasıdır. Her nöronun bir konumu vardır ve birbirine yakın olanlar benzer özelliklere sahip kümeleri gösterir. Bu nedenle, her nöron, eğitimden öğrenilen bir kümeyi temsil eder. KDH'lerde yanıtlar karşılaştırılır ve kafesten kazanan bir nöron seçilir. Seçilen bu nöron komşu nöronlarla birlikte aktive edilir. KDH'ler, çıkış düğümleri arasında yanıl bağlantıların olmadığı herhangi bir sayıda gösterge için iki boyutlu bir haritayı çıktı olarak döndürür [83].



Şekil 3.9. Kendi Kendini Düzenleyen Harita (KDH) modelinin genel çalışma yapısı.

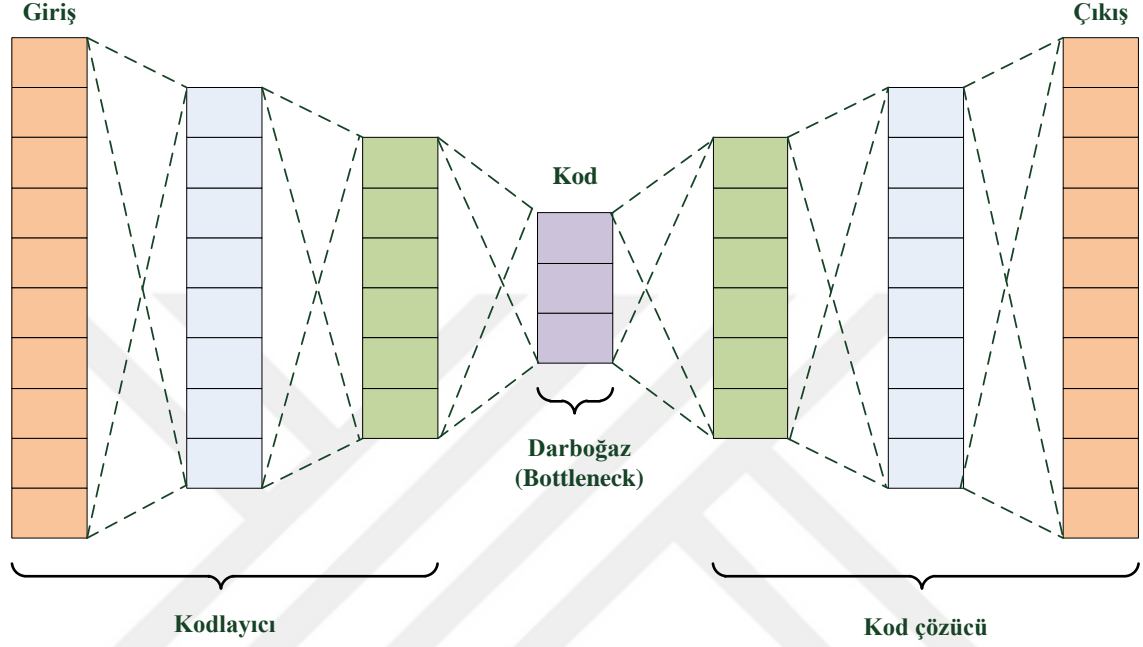
Bir KDH, nöronlarını tekrar tekrar veri noktalarına yaklaştırarak bir veri kümesinin topolojik biçimine uyum sağlar, bu da muazzam veri kümelerini görselleştirmemize ve olası kümeleri bulmamıza olanak tanır. KDH'nın ilk katmanı giriş katmanıdır ve ikinci katman, çıkış katmanı veya özellik haritasıdır. Gradyan inişli geri yayılım gibi hata düzeltme öğrenmesini kullanan diğer sinir ağlarının aksine, KDH'lar girdi uzayının topolojik özelliklerini korumak için bir komşuluk işlevi kullanan rekabetçi öğrenmeyi uygular [2]. Çeşitli çalışmalar incelendiğinde örüntü belirleme, sağlık veya tıbbi teşhis, anormallik tespiti, virüs veya solucan saldırısı tespiti ve uzaktan algılama uygulamaları dahil olmak üzere çeşitli uygulamalarda yaygın olarak kullanıldığı görülmüştür [84]–[86]. Bir KDH kullanmanın birincil yararı, kalıpları anlamak için yüksek boyutlu verileri görselleştirmeyi ve analiz etmeyi kolaylaştırabilmesidir. Bununla birlikte, boyutsallığın ve ızgara kümelemenin azaltılması ile verilerdeki benzerliklerin gözlemlenmesini de kolaylaştırır. Sonuç olarak, KDH'lar, veri özelliklerine bağlı olarak belirli bir problem alanı için veriye dayalı etkili bir model geliştirmede önemli bir rol oynayabilir.

3.2.4. Otomatik Kodlayıcı (OK)

Temsilleri öğrenmek için sinir ağlarının kullanıldığı popüler bir denetimsiz öğrenme tekniği olan OK'lar, öğrenmeyi etkinleştirmek için etiketli girdilere ihtiyaç duymazlar [42]. Şekil 3.10'da bir OK'un genel çalışma yapısı gösterilmektedir. Kodlayıcı, kod ve kod çözücü, bir otomatik kodlayıcının üç temel parçasıdır. Genel olarak kodlayıcı, girişi sıkıştırır ve kod çözücünün daha sonra girişi yeniden yapılandırmak için kullandığı kodu oluşturur. Kod, gizli alan temsili olarak da adlandırılan girdinin kompakt bir özeti veya sıkıştırılmasıdır. Daha detaylı açıklamak gerekirse, kodlayıcı, yüksek boyutlu girdi verilerini, daha düşük boyutlu bir veya daha fazla gizli katmandan oluşan gizli bir değişkenle eşler. Bu darboğaz katmanı, girdi verilerinin sıkıştırılmış bir temsiliyi ifade eder. İkinci kısım, gömme işleminden gelen girdi verilerini yeniden oluşturmaya çalışan kod çözücüdür. Girdinin yeniden yapılandırılmasının ardından, boyutsallık azaltma, modeli daha az değişkenliğe sahip özellikleri bir kenara bırakarak yalnızca yüksek değişkenliğe sahip özellikleri korumaya zorlar.

Otomatik kodlayıcıların arkasındaki temel mantık, çıktı verilerinin girdi verilerine mümkün olduğunca benzer olması gerekliliğidir. OK modelleri girdiler ve çıktılar farklı olduğunda modeli cezalandıran bir maliyet işlevi içerir. Bu modellerin birkaç kullanışlı özelliği vardır. İlk olarak, eğitim etiketleri olmadan denetimsiz bir şekilde kodlamaları

öğrenebilen özellik dedektörleri olarak kullanılırlar. İkinci olarak, kodlamalar genellikle daha düşük bir boyutta bulunduğundan, model boyutsallığını ve karmaşıklığını azaltırlar. Üçüncüsü, çıktıları yeniden yapılandırmak zorunda kalarak, otomatik kodlayıcılar girdi eğitim verilerine benzer yeni veriler üretir. Bu özellikler, etiketli eğitim verilerinin az olduğu medikal görüntü analizinde bir avantajdır [50].



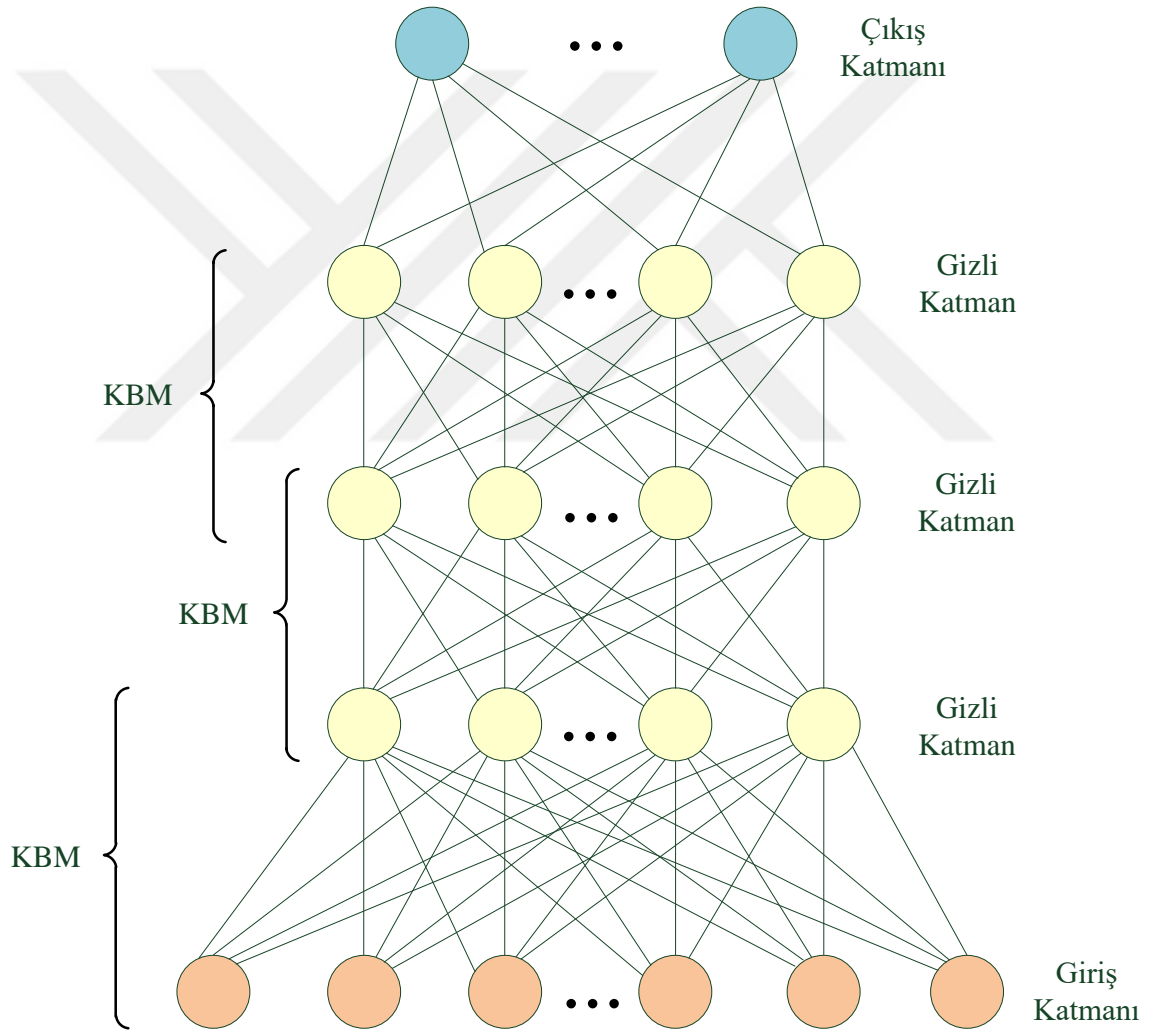
Şekil 3.10. Otomatik Kodlayıcı (OK) modelinin temel yapısı.

Otomatik kodlayıcılar genellikle gürültü giderme prosedürüyle ilişkilendirilir, çünkü önemsiz varyasyonlar otomatik olarak dışarıda bırakılır. Bu kayıp, sıkıştırılmış veri ile yeniden yapılandırılmış veri arasındaki mesafeyi dikkate alan bir kayıp fonksiyonu aracılığıyla modellenir. En sık kullanılan kayıp fonksiyonları, ortalama karesel hata ve Kullback-Leibler sapmasıdır [87].

OK'lar görüntü ve sese gürültü giderme çalışmalarının yanında, son zamanlarda özellikle üretken veri modellerini öğrenmek için de kullanılmıştır [88]. Bununla birlikte, boyutsallık azaltma, özellik çıkarma, verimli kodlama, anormallik veya aykırı değer tespiti vb. gibi denetimsiz birçok öğrenme görevinde yaygın olarak kullanılmaktadır [89]. Kullanım amacına göre; Seyrek Otomatik Kodlayıcı (Sparsity Autoencoder-SAE), Gürültü Giderici Otomatik Kodlayıcı (Denoising Autoencoder-DAE), Büzücü Otomatik Kodlayıcı (Contractive Autoencoder-CAE) ve Varyasyonel Otomatik Kodlayıcı (Variational Autoencoder-VAE) gibi çeşitli varyantları vardır [90].

3.2.5. Derin İnanç Ağı (DİA)

Olasılıksal üretken modellerden bir diğeri olan DİA, OK'lar veya KBM'ler gibi her bir ağı gizli katmanını bir sonraki katman için girdi olarak kullanan, yani sıralı olarak bağlanan, birkaç bağımsız denetimsiz ağı istifleyen çok katmanlı bir grafik modeldir [91]. Bu nedenle bir DİA'yı, (i) yığılmış OK olarak bilinen OK-DİA ve (ii) yığılmış KBM olarak bilinen KBM-DİA olarak iki parça gibi düşünmek mümkündür. Burada OK-DİA otomatik kodlayıcılardan oluşurken, KBM-DİA ise kısıtlı bir Boltzmann makinesi türü olan basit öğrenme modüllerinin bir bileşimi olarak görülebilir. Şekil 3.11'de KBM modüllerinin birleşiminden oluşan temel bir DİA ağ yapısı gösterilmektedir.



Şekil 3.11. Derin İnanç Ağı (DİA)'nın ağ yapısı.

Daha önce açıklanan KBM'lerde nihai hedef, karşılaştırmalı ayrışmaya dayanan her bir alt ağı için daha hızlı denetimsiz bir eğitim tekniği geliştirmektir [79]. DİA, derin yapısına

bağlı olarak girdi verilerinin hiyerarşik bir temsiliyi yakalayabilir. DİA'nın arkasındaki ana fikir, etiketli girdi ile ağda ince ayar yapmadan önce, denetimsiz ileri beslemeli sinir ağlarını etiketlenmemiş verilerle eğitmektir. DİA'nın tipik sığ öğrenme ağlarının aksine en önemli avantajlarından biri, derin örüntülerin tespitine izin vermesidir. Bu da muhakeme yeteneklerine bağlı olarak normal ve hatalı veriler arasındaki derin farkın yakalanmasına izin verir. Genel olarak, DİA modeli, güçlü özellik çıkarma ve sınıflandırma yetenekleri nedeniyle çok çeşitli yüksek boyutlu veri uygulamalarında kilit bir rol oynamakta ve sinir ağları alanındaki önemli konulardan biri haline gelmektedir [2].

3.3. HİBRİT ÖĞRENME İÇİN DERİN AĞLAR

Önceki kısımlarda açıklanan derin öğrenme kategorilerine ek olarak, hibrit ağlar, Derin Transfer Öğrenme (DTL) ve Derin Takviyeli Öğrenme (DRL) gibi diğer birkaç yaklaşım bu bölümde açıklanacaktır.

Ayırt edici modeller, etiketlenmemiş verilerden öğrenemezlerken, üretken modeller, hem etiketlenmiş hem de etiketlenmemiş verilerden öğrenme kapasiteleriyle uyarlanabilirler. Ancak denetimli görevlerde ayırt edici modeller üretken modellerden daha iyi performans gösterirler. Hibrit ağları motive eden her iki modelin avantajlarından yararlanabilme fikri, hem derin üretici hem de ayırt edici modelleri aynı anda eğitmek için bir çerçeve oluşturmuştur.

Hibrit öğrenme modelleri tipik olarak birden çok (iki veya daha fazla) derin temel öğrenme modelinden oluşur. Burada temel model, daha önce tartışılan denetimli/ayırt edici veya denetimsiz/üretken bir derin öğrenme modelidir. Farklı modellerin entegrasyonuna dayalı olarak, aşağıda önerilen ve tez çalışmasında kullanılan üç farklı türde hibrit öğrenme model kategorisi, gerçek dünya sorunlarını çözmek için de faydalı olabilir.

3.3.1. Hibrit Model-1

Hibrit Model-1, daha anlamlı ve sağlam özellikler çıkarmak için farklı türdeki denetimli/ayırt edici veya denetimsiz/üretken öğrenme modellerin kendi aralarında entegrasyonu olarak tanımlanır. Örnek olarak; Evrişimsel Sinir Ağı ve Tekrarlayan Sinir Ağı varyantı olan LSTM'nin birlikte kullanılması (ESA+LSTM) ya da Otomatik

Kodlayıcı ve Üretken Çekişmeli Ağın entegrasyonu (OK+ÜÇA) olabilir. Örnekler uygulanacak sistemin yapısına göre de farklı türdeki denetimli veya denetimsiz öğrenme modellerin kendi aralarında çeşitlendirilmesiyle artırılabilir.

3.3.2. Hibrit Model-2

Hibrit Model-2, denetimsiz/üretken bir modelin entegrasyonunu takiben denetimli/ayırt edici bir modelin kullanılması olarak tanımlanır. Örnek olarak; Otomatik Kodlayıcı ile Evrişimsel Sinir Ağın birleştirilmesi (OK+ESA), Derin İnanç Ağları ile Çok Katmanlı Algılayıcın kombinasyonu (DİA+ÇKA) ve Üretken Çekişmeli Ağlara Evrişimsel Sinir Ağın entegrasyonu (ÜÇA+ESA) olabilir. Örnekler, üretken bir model ve devamında ayırt edici bir model olacak şekilde çeşitlendirilebilir.

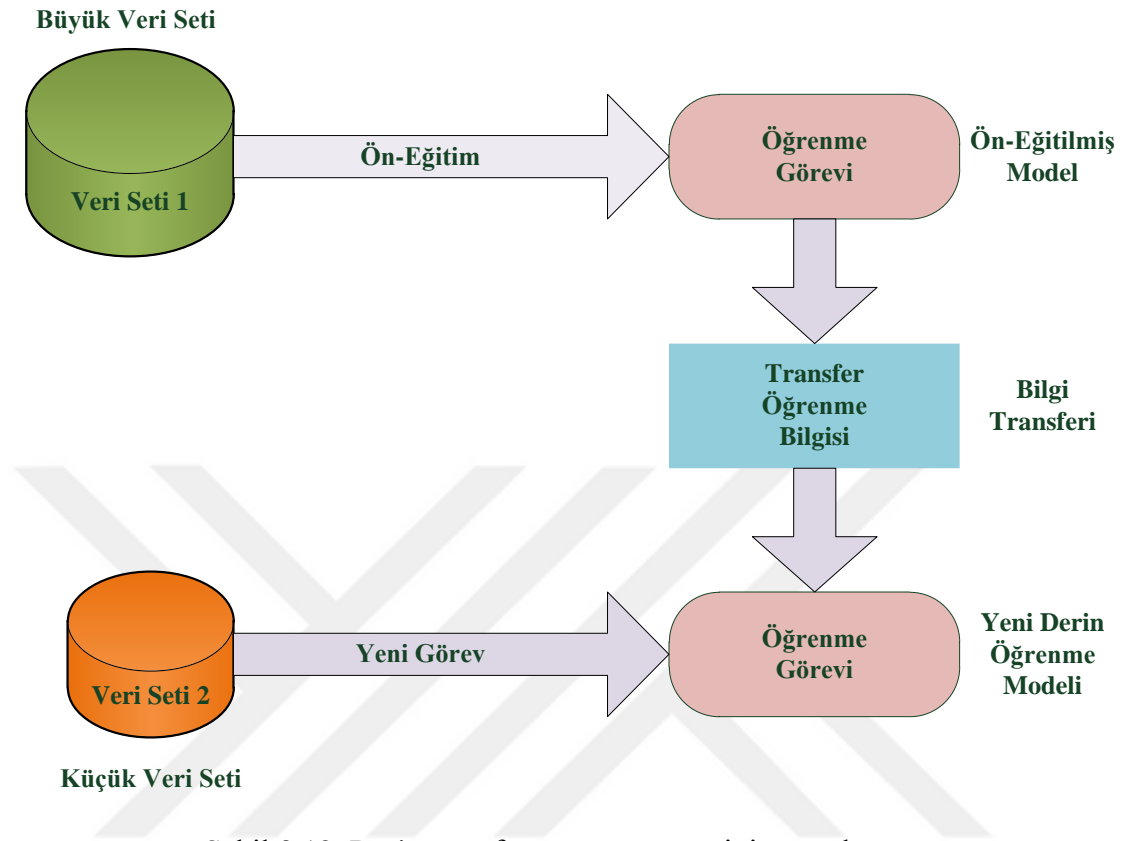
3.3.3. Hibrit Model-3

Denetimli/ayırt edici veya denetimsiz/üretken bir modelin ardından derin olmayan makine öğrenme sınıflandırıcısının entegrasyonu olarak tanımlanır. Örnek olarak; Evrişimsel Sinir Ağının K-En Yakın Komşular (K-Nearest Neighbors-KNN) algoritması (ESA+KNN) ile Otomatik Kodlayıcının Destek Vektör Makineleri (Support Vector Machine-SVM) algoritması (OK+SVM) ile kullanılması olabilir. Örnekler, uygulanacak çalışmanın sistemine göre üretken veya ayırt edici bir model seçiminden sonra bir sınıflandırıcının kullanılması ile farklılaştırılabilir.

3.3.4. Derin Transfer Öğrenimi (DTL)

Transfer Öğrenimi, minimum eğitim veya ince ayar ile yeni bir görevi çözmek için önceden öğrenilen model bilgisini etkili bir şekilde kullanan bir tekniktir. Tipik makine öğrenmesi teknikleriyle karşılaştırıldığında, derin öğrenme büyük miktarda eğitim verisi alır. Sonuç olarak önemli miktarda etiketlenmiş veriye duyulan ihtiyaç, özellikle büyük ölçekli, yüksek kaliteli açıklamalı tıbbi veya sağlık veri kümeleri oluşturmanın zor ve maliyetli olduğu tıp sektöründe, alana özgü bazı temel görevleri ele almanın önünde önemli bir engeldir [35]. Ayrıca standart derin öğrenme modeli, araştırmacılar onu geliştirmek için çok çalışsa da, GPU (Grafik İşlem Birimi) özellikli bir sunucu gibi çok sayıda bilgi işlem kaynağı gerektirir. Sonuç olarak, derin öğrenme tabanlı bir transfer öğrenme yöntemi olan Derin Transfer Öğrenimi (Deep Transfer Learning-DTL), bu sorunu çözmek için yardımcı olabilir. Şekil 3.12, önceden eğitilmiş modelden gelen bilginin yeni bir derin öğrenme modeline aktarıldığı DTL sürecinin genel yapısını

göstermektedir. Derin sinir ağlarını çok az veriyle eğitmeye izin verdiği için şu anda özellikle derin öğrenmede popüler bir yaklaşımdır [92].



Şekil 3.12. Derin transfer öğrenme sürecinin genel yapısı.

Bir derin öğrenme modelinin eğitimi için sunulan iki aşamalı bir yaklaşım olan transfer öğrenimi, bir ön eğitim adımından ve modelin hedef görev üzerinde eğitildiği bir ince ayar adımından oluşur. Derin sinir ağları çeşitli alanlarda popülerlik kazandığında eş zamanlı olarak çok sayıda DTL yöntemi ortaya atılmıştır. Bunların sınıflandırılması ve özetlenmesi çok önemlidir. Literatürde kullanılan tekniklere dayalı olarak, DTL dört kategoride sınıflandırılabilir [93]. Bunlar; (i) kaynak alandaki örnekleri uygun ağırlıkta kullanan örnek tabanlı derin aktarım öğrenimi, (ii) iki etki alanındaki örnekleri daha iyi benzerlikle yeni bir veri alanına eşleyen haritalama tabanlı derin aktarım öğrenimi, (iii) kaynak alanda önceden eğitilmiş ağın bir kısmını yeniden kullanan ağ tabanlı derin aktarım öğrenimi ve (iv) her ikisi de iki alan için uygun olan aktarılabilir özellikleri bulmak için çekişmeli teknolojiyi kullanan çekişme tabanlı derin aktarım öğrenimidir.

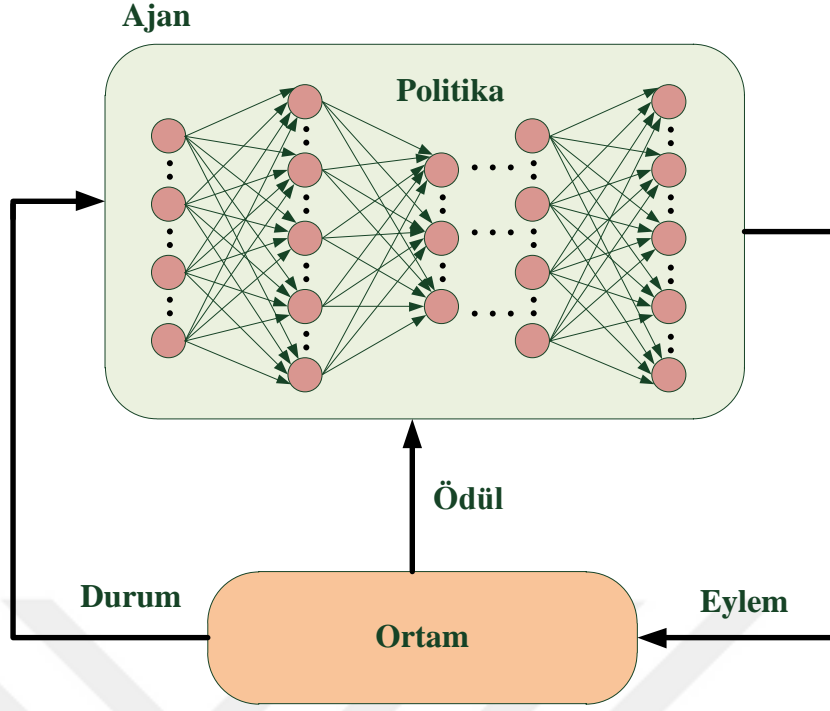
Yüksek etkinliği ve pratikliği nedeniyle, çekişme tabanlı derin transfer öğrenimi son yıllarda oldukça sık kullanılmaktadır [94]. Mevcut araştırmaların çoğu denetimli öğrenmeye odaklanırken, derin sinir ağlarının denetimsiz veya yarı denetimli öğrenmede

bilgiyi nasıl aktarabileceği gelecekte daha fazla ilgi görebilir. DTL teknikleri, doğal dil işleme, duygu sınıflandırması, görsel tanıma, konuşma tanıma, spam filtreleme gibi çeşitli alanlarda kullanışlıdır [95].

3.3.5. Derin Takviyeli Öğrenme (DRL)

Pekiştirmeli Öğrenme olarak da bilinen Takviyeli Öğrenme (Reinforcement Learning-RL), sıralı karar verme problemini çözmek için şimdiye kadar bahsi geçen diğer yöntemlerden farklı bir yaklaşım benimser. Bir ortam ve bir ajan kavramları genellikle ilk olarak pekiştirmeli öğrenmede tanıtılır. Ajan ortamda, her biri ortamın durumu üzerinde etkisi olan ve "iyi" bir durumla sonuçlanan iyi eylem dizileri için "pozitif" ve "kötü" bir durumla sonuçlanan kötü eylem dizileri için "negatif" olan geri bildirimlerle birlikte bir dizi eylem gerçekleştirebilir. RL, en yüksek ödül değerine ulaşmak için ajanın ortamda belirlenen eylemler arasından en uygun olanını seçmesini sağlamak için kullanılan bir makine öğrenmesi yöntemidir. Bu yöntemin politika olarak da adlandırılan amacı, iyi eylem dizilerini öğrenmektir.

Son zamanlarda yapılan araştırmalar, derin öğrenme tekniklerinin, yüksek boyutlu ham veri girişi olan sistemlerde yararlı temsilleri öğrenmek için pekiştirmeli öğrenme yöntemleriyle birleştirilebileceğini göstermiştir. Buradan yola çıkarak, Şekil 3.13'te gösterildiği gibi, Derin Takviyeli Öğrenme (Deep Reinforcement Learning-DRL), ajanların sanal bir ortamda uygun eylemleri öğrenmesine izin vermek için sinir ağlarını bir pekiştirmeli öğrenme mimarisiyle bütünleştirir [96]. DRL yöntemleri derin öğrenme modellerini içerir. Örneğin; ESA, ham ve yüksek boyutlu görsel girdilerden doğrudan öğrenmek için RL ajanlarını bir bileşeni olarak kullanılabilir. Takviyeli öğrenme alanında, Model-tabanlı RL çevre ile doğrudan etkileşime girmeden modellemeyi sağlayan bir geçiş modelini öğrenmeye dayanırken, Modelden-bağımsız RL yöntemleri doğrudan ortam ile etkileşimlerden öğrenir.



Şekil 3.13. Derin takviyeli öğrenmenin şematik yapısı.

Gerçek dünyada DRL tabanlı çözümler robotik, doğal dil işleme, örüntü tanıma, bilgisayar görüşü gibi konularda özellikle akademik topluluklarda büyük ilgi görürken; video oyunları, sesli ve görsel arama motoru gibi konularda da çok çeşitli endüstri ürünlerinde kullanılmıştır [96].

4. HİBRİT DERİN ÖĞRENME SİSTEMLERİ İLE RADYOLOJİ GÖRÜNTÜLERİNDE MEDİKAL KAVRAM TESPİTİ

Günümüzde sağlık alanındaki görüntü işleme ile ilgili çalışmalar popülerliğini son derece artırmıştır. Daha önce görüntü işleme üzerin çalışma yapmış akademisyenler, son yıllarda biyomedikal alanında yapılan görüntü işlemeyle ilgili çalışmalara yoğunlaşmış olup; model olarak da derin öğrenme üzerindeki faaliyetlerini artırmıştır. Yapılan çalışmalarda derin öğrenme, gerek tıbbi görüntüler olsun gerekse diğer alandaki görüntüler, mevcut yöntemlere kıyasla zaman ve performans açısından daha fazla katkıda bulunan modeller arasında olmuştur. Mevcut yöntemler ile tek katmanlı görüntüler üzerinden işlem yapılıyorken, derin öğrenme modeliyle, çok katmanlı görüntüler üzerinden performansı yüksek sonuçlar alınabilmektedir.

Derin öğrenmenin en önemli özelliği, görüntü üzerindeki işlemleri bir seferde işleme tabi tutarak, el ile girilmesi gereken parametreleri kendi kendine keşfedebilmesidir [97]. Önceleri veri kümesi erişimi sınırlı olan biyomedikal alanında veri kümelerinin son zamanlarda hızlı bir şekilde elde edilmesinin; derin öğrenme modelleriyle beraber bu alandaki görüntü işleme çalışmalarına daha da çok katkıda bulunacağı öngörülmektedir. Derin öğrenme modellerine bu denli ilgi gösterilmesinin en önemli bir diğer sebebi ise, yeteri kadar eğitilecek verinin bulunmasının yanında, bu verilerin işlenmesinde gerekli fiziksel alt yapının hazır olmasıdır.

Tıbbi görüntülerden kavram tespiti zorlu bir görev olmaya devam ederken; 2003 yılında diller arası görüntü alımında araştırmayı teşvik etmek için Çapraz Dil Değerlendirme Forumu'nun (Cross Language Evaluation Forum-CLEF) bir parçası olarak ImageCLEF başlatılmıştır [98]. ImageCLEF, hem ticari hem de akademik araştırma topluluklarına hitap edeceği öngörülen, yeni zorluklar öneren ve diller arası bilgi alma, görüntü alma ve kullanıcı etkileşimi ile ilgili çalışan sistemlerin değerlendirilmesi için kıyaslama kaynakları geliştiren bir aksiyondur. ImageCLEF, 2004'ten beri her yıl medikal görevler içermektedir. Bu nedenle, medikal görevlerin her biri belirli bir soruna odaklanmak için birkaç alt göreve bölünmüştür.

ImageCLEF 2019'un [6] medikal görevlerini içeren ImageCLEFmedical eylemlerinin alt görevlerinden birisi olan ImageCLEFmed Caption, her bir görüntüye atanması gereken

medikal kavramları otomatik olarak seçerek tıbbi görüntülerin çok etiketli sınıflandırmasını gerçekleştirmeyi amaçlamaktadır [7]. 2019'da bu görevi gerçekleştirmek için katılan takımların yanı sıra gönderilen çalışmaların sayısı da çok yüksek olmuştur. Katılan takımlar tarafından, derin öğrenme teknikleri de olmak üzere çok çeşitli yaklaşımlar kullanılmıştır.

Tez çalışmasının bu bölümünde, bahsi geçen ImageCLEFmed 2019 Kavram Tespit görevi ele alınmış olup, ImageCLEFmed Caption 2019 veri seti üzerinde üç farklı hibrit derin öğrenme sistemi uygulanmıştır. İlk hibrit sistemde, iki farklı denetimli öğrenme tekniği olan ESA ve TSA beraber uygulanmıştır. İkinci hibrit sistemde, denetimsiz ve denetimli öğrenme tekniğinin birleştirildiği OK-ESA kombinasyonu sunulmuştur. Üçüncü hibrit sistemde, ise denetimli öğrenme tekniği olan ESA'nın dört farklı modeli ile makine öğrenme sınıflandırıcısı olan KNN algoritması birlikte kullanılmıştır. İlerleyen bölümlerde, önce veri seti detaylı olarak ele alınmış, veri seti analizi ve veri filtreleme işlemleri gerçekleştirilmiştir. Hibrit öğrenme için önerilen üç farklı sistem ile veri seti üzerinde eğitim ve test işlemleri yapılmış ve sonuçlar karşılaştırmalı olarak sunulmuştur.

Modeller Python 3.7 'de Tensorflow arka planlı Keras Kütüphanesi kullanılarak oluşturulmuştur. Keras [99], Tensorflow ve Theano [58] üzerinde çalışabilen üst düzey bir programlama arabirimi olarak görülebilir. Bu kütüphane özellikle ortak ağ katmanlarını ve algoritmaları kullanarak ağları hızlı bir şekilde geliştirmek ve test etmek için popülerdir ve kullanıcılar için derin öğrenmeye açılan bir kapı olarak görülür. Derin öğrenmenin yükselişi kısmen, bu alandaki temel teknikleri üst düzey programlama dillerinde uygulayan programlama çerçevelerine araştırmacıların erişimiyle mümkün olmuştur. Şu anda, bu çerçevelerin birçoğu yazılım geliştiriciler tarafından sürekli olarak güncellenmekte ve yeni bulguların çoğu bunlara hızla dahil edilmektedir. Bu modern çerçevelerden tam olarak yararlanmak için uygun GPU mevcudiyeti istenirken, çoğu küçük modelleri eğitmek ve test etmek için CPU desteği de yeterlidir. Çerçeveler, kullanıcıların, katmanlar tarafından gerçekleştirilen işlemleri ve onları eğiten algoritmaları fiilen uygulamaya gerek kalmadan, farklı ağ mimarilerini ve bunların hiperparametre ayarlarını doğrudan test etmelerine olanak tanır. Katmanlar ve ilgili algoritmalar, çerçeve kitaplıklarında önceden tanımlanmış olarak gelir [3].

Yapılan eğitimler ve testler sırasında 16 GB RAM bellek, 2.60 GHz ile çalışan Intel Core i7-6700HQ işlemci ve Nvidia GeForce GTX 950M ekran kartı donanım özelliklerine sahip dizüstü bilgisayar kullanılmıştır.

4.1. VERİ SETİ

Kullanılan ImageCLEFmed Caption 2019 veri seti, ROCO (Radiology Objects in COntext) [100] veri setinin bir alt setidir. Biyomedikal açık erişim literatüründen (PubMed Central), açık erişimli biyomedikal dergi makalelerinden alınan radyolojik görüntüler ile bu görüntülere ait şekil başlıkları ve makale başlıklarını içerir. Bu veri seti, gürültülü etiketleri azaltmak ve çeşitliliği sınırlamak için, alınan biyomedikal görüntüler yerine yalnızca radyoloji görüntüleri üzerine odaklanmıştır. Ayrıca, her yıl düzenli olarak gerçekleştirilen, amacı İTGE modeli ve BES başarımının ölçülmesi olup ImageCLEF dahilinde kullanılan ve hala gelişmekte olan bir veri setidir.


ImageCLEFmed Caption 2019 veri setinde toplam 80.786 görüntü ve bu görüntülere ait metinsel tanımlamalar vardır. Bu küresel set, organizatörler tarafından Çizelge 4.1’de gösterildiği gibi eğitim (56.629 görüntü), doğrulama (14.157 görüntü) ve test (10.000 görüntü) veri setlerine ayrılmıştır.

Çizelge 4.1. Veri seti dağılımı.

Veri Seti	Görüntü Sayısı
Eğitim Veri Seti	56.629
Doğrulama Veri Seti	14.157
Test Veri Seti	10.000
TOPLAM	80.786

Geliştirme verileri, görüntülerden çıkarılan ve toplam sayısı 5.528 olan UMLS kavramlarına sahip, 56.629 eğitim ve 14.157 doğrulama veri seti görüntüsünden ve onlara ait metinsel tanımlamalardan oluşur. Her görüntü, başlığı ile birlikte çıkarılmıştır. Başlık, UMLS kavram benzersiz tanımlayıcılarını (Concept Unique Identifiers-CUI) üretmek için QuickUMLS kullanılarak işlenmiştir. Bir görüntü birden çok CUI ile ilişkilendirilebilir. Her CUI'ye, karşılık gelen UMLS terimi eşlik eder [101]. Şekil 4.1, ImageCLEFmed Caption 2019 veri setinden alınan iki örnek görüntü ve onlara ait metinsel tanımlamaları (başlık, anahtar kelime, CUI ve UMLS kavramları) göstermektedir.

ROCO_00074



Başlık (Caption)

Chest radiography shows a mass on the right lower mediastinum

Anahtar Kelimeler (Keywords)

mas radiography lower
chest right mediastinum

Kavramlar (Concepts)

CUI

C0015726
C0043299
C1962945
C1261259
C0423899
C0025066
C1306645
C0817096

UMLS

Fear (Mental Process)
Diagnostic radiologic examination
Radiographic imaging procedure
Wright stain
Above average intellect
Mediastinum
Plain x-ray
Chest

ROCO_65721



Başlık (Caption)

X-ray of a hip with a failed neck

Anahtar Kelimeler (Keywords)

hip failed xray neck

Kavramlar (Concepts)

CUI

C0027530
C0228391
C0019552

UMLS

Neck
Structure of habenuropeduncular tract
Hip structure

Şekil 4.1. ImageCLEFmed Caption 2019 veri setinden alınan iki örnek görüntü ve onlara ait başlık, anahtar kelime ve kavram bilgileri.

Kullanılan veri setinde kavramlar doğrudan verilmemiş olup görüntülere atanan CUI'ler yer almaktadır. Tezde verilen tüm CUI-UMLS dönüşümü güncel olarak, Ulusal Tıp Kütüphanesi (National Library of Medicine-NIH) UMLS Terminoloji Hizmetleri (UMLS Terminology Services-UTS) ile gerçekleştirilmiştir [102].

4.1.1. Veri Seti Analizi

Bu bölümde, veri kümelerini daha iyi anlamak ve genel veri dağılımını ortaya koymak için detaylı istatistiksel analizlere yer verilmiştir. ImageCLEFmed Caption 2019 veri setinde, önceki yıllarda çok daha yüksek olan UMLS kavram sayısı 5.528'e düşürülmüştür. Eğitim görüntülerinde bulunan toplam farklı UMLS kavram sayısı 5.216'dır, yani 312 kavram herhangi bir eğitim görüntüsüne atanmamıştır. Doğrulama veri seti ise, toplam 3.233 benzersiz kavrama sahiptir. Eğitim veri kümesinde yer almayan kavramlardan bazıları CUI'leri ile birlikte Çizelge 4.2'de gösterilmektedir. Bu durum modelin ilgili kavramları öğrenmesini ve doğrudan görüntülerden tahmin yapmasını engeller. Eğitim setindeki 1.530 kavram yalnızca bir görüntüye atanmıştır ki bu durum da, ilgili bu kavramların sınıflandırılmasını zorlaştırmaktadır. 4.239 görüntü ise tek bir kavram ile tanımlanmıştır.

Çizelge 4.2. Eğitim veri setinde yer almayan bazı CUI'ler ve onlara ait kavramlar.

CUI-Kavram	CUI-Kavram
C0949214: advertisements	C1578434: spouse
C1552850: start	C0332148: probable diagnosis
C0007306: cartoons	C1507394: clinical trial protocol document
C3813540: pineapple extract	C0016538: projections and predictions
C1096774: letter	C1552852: prev
C0871472: t-test	C0969625: methodology aspects
C0034975: registries	C3244316: medication
C0332219: easy	C1561610: signed
C0560453: does jump	C1550473: confidentiality - business
C0038435: stress	C4049977: emotionally satisfied with extremity
C1561611: improved	C1550655: patient
C0549649: misuse	C0016538: projections and predictions
C0552371: citations	C1552856: copyright

Eğitim veri setinde görüntü başına düşen ortalama kavram sayısı 6'dır. Bir görüntüdeki en fazla kavram sayısı 72, en azı ise 1'dir. Çizelge 4.3'te eğitim görüntülerine atanan kavram sayıları yüksekten düşüğe doğru CUI'leri ile birlikte gösterilmektedir.

Çizelge 4.3. Eğitim görüntülerine atanan kavram sayısı sıralaması ve karşılık gelen CUI'ler.

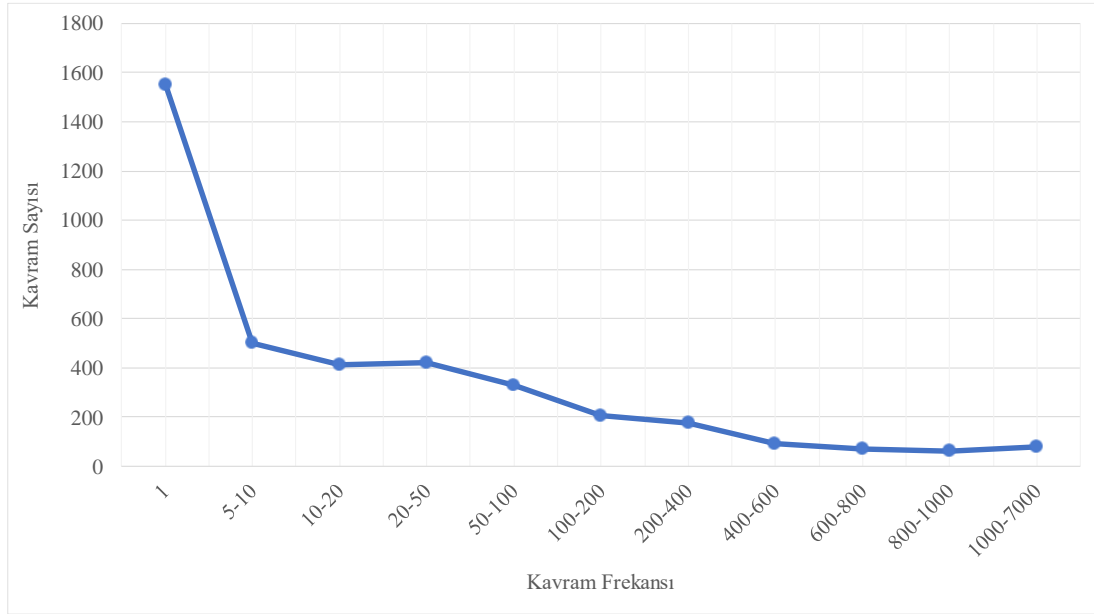
	Görüntü	Kavram Sayısı	Kavramlar (CUI)
0	ROCO_69357	72	C0544724;C0183191;C0729274;C0565342;C...
1	ROCO_46672	70	C0544724;C0183191;C0729274;C0565342;C...
2	ROCO_44813	69	C0922671;C0227991;C0506734;C0582818;C...
3	ROCO_03622	64	C0150312;C0027121;C2242558;C0038774;C...
4	ROCO_15228	56	C0746922;C0497156;C3854058;C1514241;C...
...
56624	ROCO_48497	1	C3282905
56625	ROCO_70524	1	C0018494
56626	ROCO_52410	1	C0000726
56627	ROCO_26633	1	C2700258
56628	ROCO_60832	1	C0202165

Çizelge 4.4. Eğitim seti ve tüm veri seti için en çok kullanılan 10 CUI, karşılık gelen UMLS kavramları ve bu kavramların atandıkları görüntü sayıları.

CUI	Kavram	Eğitim Setindeki Görüntü Sayısı	Veri Setindeki Görüntü Sayısı
C0441633	scanning	6.733	8.452
C0043299	diagnostic radiologic examination	6.321	7.906
C1962945	radiographic imaging procedure	6.318	7.902
C0040395	tomography	6.235	7.697
C0034579	panoramic radiography	6.127	7.564
C0817096	chest	5.981	7.470
C0040405	x-ray computed tomography	5.801	7.164
C1548003	radiograph	5.159	6.428
C0221198	lesion	4.513	5.679
C0772294	epinastine hydrochloride	4.512	5.677


Çizelge 4.4'te ise, hem eğitim seti hem de tüm veri seti için en sık kullanılan 10 CUI, karşılık gelen UMLS kavramı ve bunların kaç tane görüntüye atandığı gösterilmektedir [7], [103]. En sık ortaya çıkan 10 kavramın, daha çok görüntüleme çalışmasının türüne atıfta bulunduğu görülmektedir.

Şekil 4.2'de, eğitim setinin kavram sayısı ve kavram frekans dağılımı gösterilmektedir. Örneğin, frekansı yani görülme sıklığı 10 ile 20 aralığında ortaya çıkan 416 kavram görülmektedir.



Şekil 4.2. Eğitim seti kavram frekansı-kavram sayısı dağılımı.

Şekil 4.3'te hem eğitim hem doğrulama seti dikkate alınarak gerçekleştirilen analiz sonucu incelendiğinde; dörtten az görüntüde ortaya çıkan 2.655 kavram vardır. 5.528 kavramdan 5.441 kavram, veri setinde 1000 defaya eşit veya daha az görülürken, 87 kavram 1000'den fazla görüntüde ortaya çıkmıştır. Frekansı 3.000'den fazla olan sadece 15 kavram vardır.



Şekil 4.3. Geliştirme veri seti kavram sayısı-kavram frekansı dağılımı.

Bir derin öğrenme modelinin başarılı bir şekilde performans göstermesi için sınıf başına çok sayıda örneğe ihtiyaç duyduğu göz önüne alındığında, geliştirme veri setindeki kavramların dağılımı böyle bir veri kümesinde bulunan nadir kavramların eğitilmesinin zorluğunu göstermektedir.

4.1.2. Veri Filtreleme

ImageCLEFmed Caption 2019 veri seti, önceki versiyonlarına göre daha küçük boyutta olmasına ve yalnızca radyoloji görüntülerine odaklanmasına rağmen, veri analizi sonucunda, eğitim setindeki radyolojik görüntülerde bulunan ve herhangi bir görsel veriye karşılık gelmeyen birçok kavramın olduğunu görülmüştür. Benzer şekilde, çok düşük frekansa sahip kavramlar hem öğrenilmeyecek, aynı zamanda modele bir yanlılık getirecektir. Bu şekilde nadir olan kavramları filtreleyerek daha iyi sonuçlar elde edilmesi hedeflenmiştir.

İlk olarak, eğitim setinde sadece bir kez oluşan tüm kavramlar seçilmiştir ve karşılık gelen görüntüleri alınmıştır. Daha sonra, her bir görüntü üzerindeki ilgili kavramlar kontrol edilir, eğer ilgili tüm kavramların frekansları bir ise görüntü veri kümesinden çıkarılır. Filtrelenmiş veri kümesi, 163 kavram ve 98 görüntü çıkarılmış olarak Vs,1 olarak gösterilir. Benzer şekilde incelendiğinde; üçten az frekansa sahip olan kavramlar yani bir ya da iki kez atanmış kavramlar ve karşılık gelen görüntüleri kontrol edilerek gerçekleştirilen filtreleme sonucunda Vs,3 tanımlı veri kümesi oluşturulmuştur. Veri

kaybı olmaması için daha fazla filtreleme işlemi yapılmamıştır.

Tezin ilerleyen bölümlerinde, ImageCLEFmed Caption 2019 veri seti (Vs), filtrelenmiş veri setlerinden Vs,1 ve Vs,3 üzerinde eğitim ve test işlemlerini gerçekleştirebilmek için önerilen üç farklı hibrit derin öğrenme sistemi detayları ile birlikte sunulmaktadır. İlk hibrit sistemde, iki farklı denetimli öğrenme tekniğini olan ESA ve TSA beraber uygulanmıştır. İkinci hibrit sistemde, denetimsiz ve denetimli öğrenme tekniğinin birleştirildiği OK-ESA kombinasyonu sunulmuştur. Üçüncü hibrit sistemde ise, denetimli öğrenme tekniği olan ESA'nın dört farklı modeli ile makine öğrenme sınıflandırıcısı olan KNN algoritması birlikte kullanılmıştır.

4.2. SİSTEM 1: ESA - TSA

Bu sistem, Jing ve arkadaşlarının medikal görüntülerden raporlar oluşturmak için sunduğu bir kodlayıcı-kod çözücü modeline dayanmaktadır [104]. Kavram belirleme görevinin de benzer şekilde karşılık gelen radyoloji görüntülerinden metin bilgisi üretmek olduğu göz önüne alınarak, ESA-TSA model çerçevesi ele alınmıştır. Görüntü özelliği çıkarıcı için, temel bir ESA'nın kullanıldığı ve bir bellek hücresi aracılığıyla uzun vadeli bağımlılıkları öğrenme yeteneği ile kavramlar oluşturmak amacıyla bir LSTM'nin kullanıldığı kodlayıcı-kod çözücü ağı tasarlanmıştır. Bununla birlikte, insan görsel dikkat mekanizmasını taklit etmek için dikkat modülü uygulanmıştır. Spesifik olarak transfer öğreniminde, tamamen bağlantılı çeşitli katmanlardan derin özellik çıkarımı benimsenmiştir.

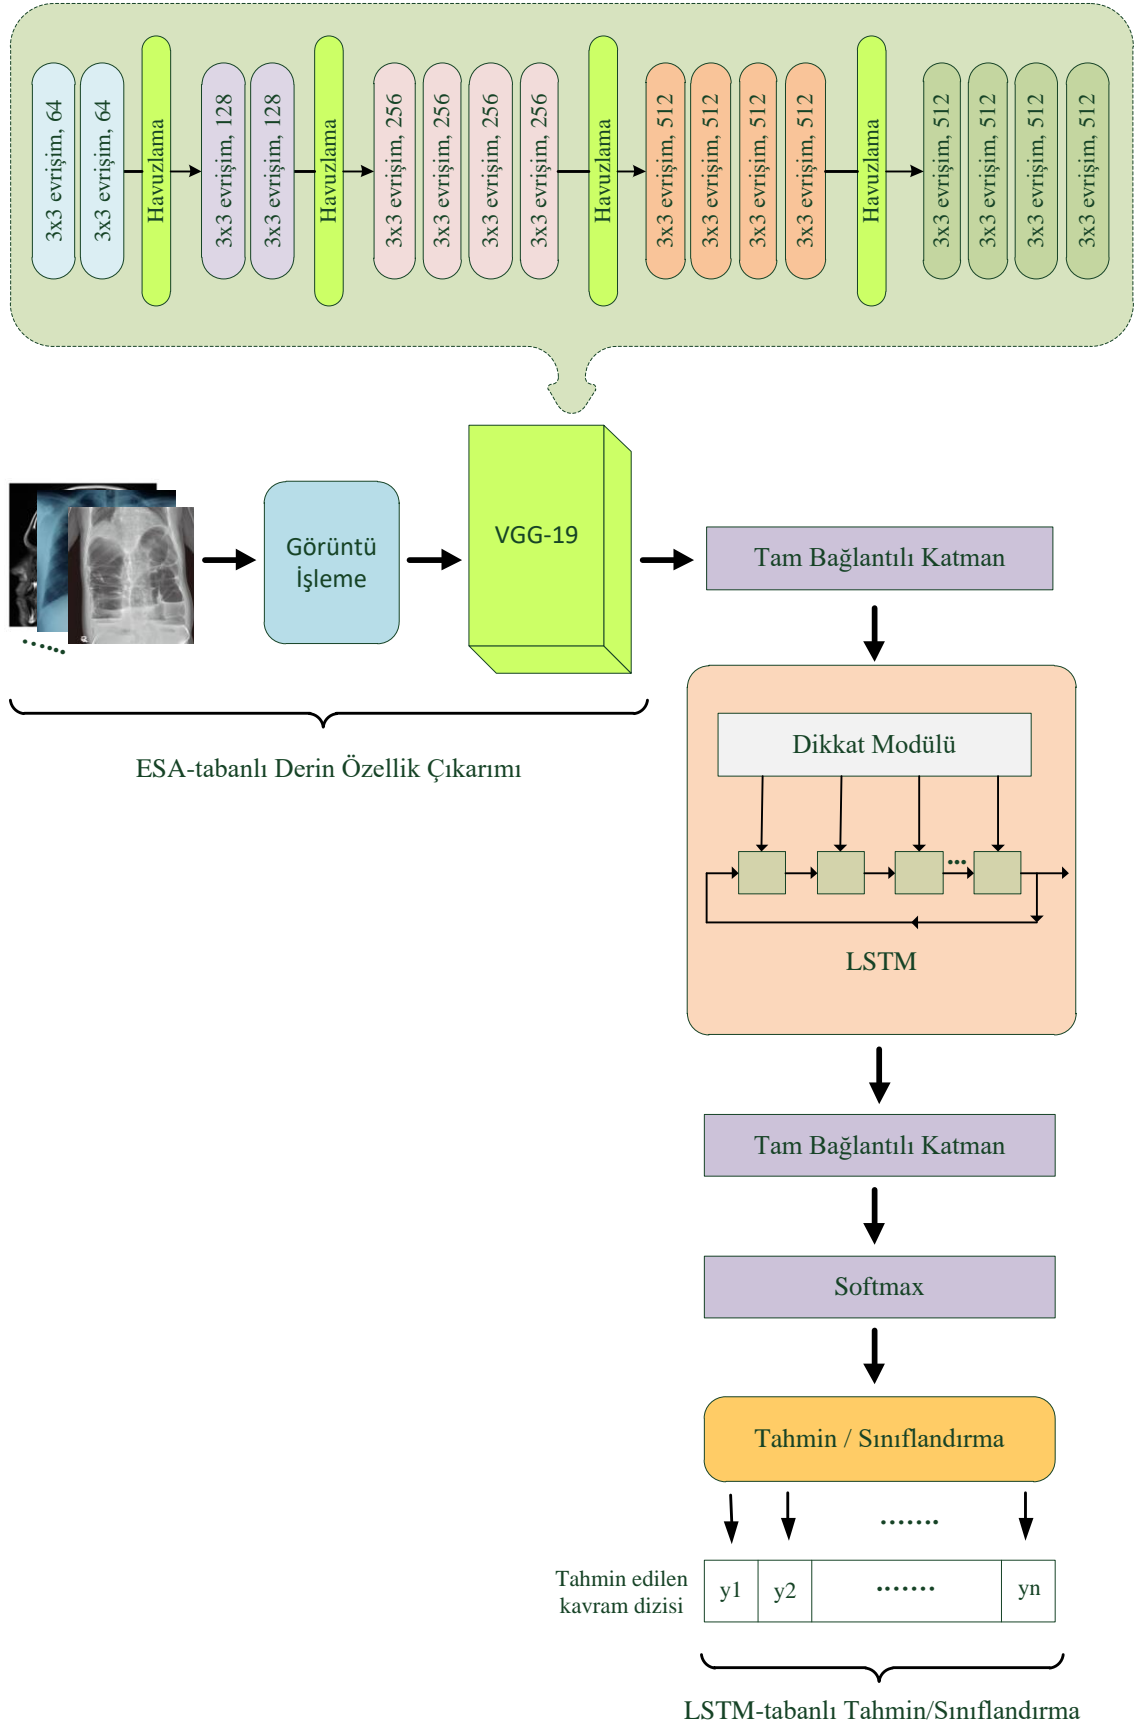
Yaklaşımımızda, ImageCLEFmed Caption 2019 görüntüleri, ImageNet'in ortalama ve standart sapması ile normalleştirilerek, 224×224 olarak yeniden ölçeklendirilmiştir. Giriş görüntüleri, görsel özellikleri çıkarmak için ImageNet üzerinde önceden eğitilmiş, 19 katmana sahip ve 3×3 boyutunda küçük çekirdekler kullanan VGG-19 ESA modeline beslenmiştir [105]. Her görüntüyü bölgelere ayıran ve her bölgeyi ayrı ayrı kodlayan Jing ve arkadaşlarının aksine, önerilen sistemde tüm görüntüler VGG-19 ESA'ya beslenmiştir.

ESA'da çıkarılan derin özellikler, daha sonra medikal kavram tespiti için sağlam bir hibrit model oluşturmak üzere LSTM katmanına iletilir. LSTM, uzun süreli bağımlılık sorununu ortadan kaldırmak için tasarlanmıştır ve zincir tipi bir yapıdadır. LSTM, hücre durumuna bilgi ekleme ve ortadan kaldırma kapasitesine sahiptir. LSTM, unutma kapısı kullanarak hangi bilgilerin hücre dışına atılacağına karar verir. Dil modeli, önceki

kelimelere dayalı olarak yeni kelimeyi tahmin etmeye çalışır. Bir sonraki adımda, hangi bilgilerin hücrede saklanması gerektiğine karar verilmesi gerekir. Giriş kapısı katmanı, hangi değerın güncellenmesi gerektiğine karar verir. Hücrede daha fazla ihtiyaç duyulmayan bilgiler, unutmakapısı kullanılarak kaldırılır ve yararlı bilgiler, çıkış kapısı yardımıyla mevcut hücreden çıkarılır. LSTM kod çözücü için ilk gizli durumu (g) ve hücre durumunu (h) oluşturmak için kodlanmış görüntü dönüştürülür. Her kod çözme adımında, kodlanmış görüntü ve önceki gizli durum, dikkat ağındaki her piksel için ağırlıklar oluşturmada kullanılır. Son olarak, bir önceki oluşturulan kavram ve kodlanmış görüntünün ağırlıklı ortalaması, en yüksek puana sahip bir sonraki kavramı oluşturmak için LSTM kod çözücüye beslenir.

Şekil 4.4'te, önerilen ESA - TSA sistem modeli gösterilmektedir. Önceden eğitilmiş VGG-19 modelinin tam bağlantılı katmanındaki derin özellikler, bir LSTM katmanını beslemek için kullanılır. Dikkat mekanizması, her zaman adımında bir sonraki altyazı terimini oluştururken, LSTM kod çözücünün görüntünün belirli bölümlerine dinamik olarak odaklanması için rehberlik edebilir. Bu nedenle, modelin görüntünün belirgin bölgelerine dikkat etmesini sağlayan görüntü özelliği, temsili olarak VGG ağıının nispeten daha düşük evrişim katmanından seçilmiştir. Spesifik olarak, 14 x 14 x 512 özellik haritasını sağlayan conv5_3 katmanından özellikler çıkarılmış ve düzleştirilmiş 196 x 512 kodlama ile sonraki LSTM kod çözücüye iletilmiştir.

LSTM katmanından sonra, tamamen bağı bir katman, bir softmax katmanı ve giriş görüntülerinin kavram etiketlerini tespit etmek için bir tahmin/sınıflandırma katmanı kullanılır. LSTM katmanının eğitim parametrelerinin en iyi seçimini belirlemek için otomatik bir şema kullanılmıştır.



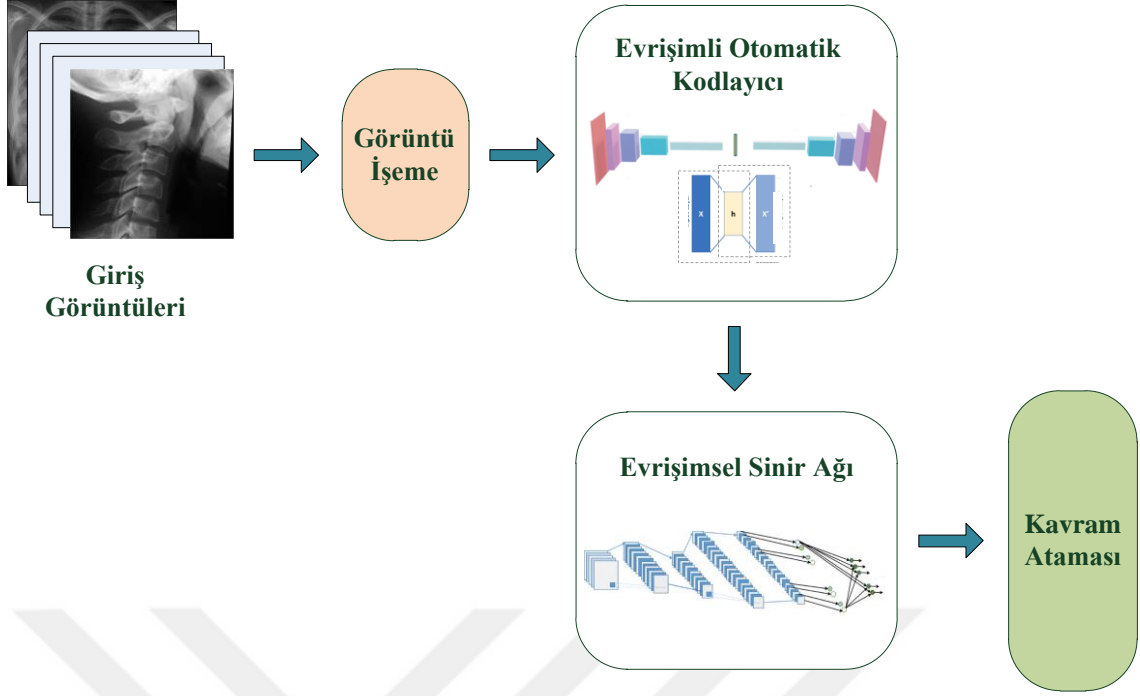
Şekil 4.4. Sistem 1: ESA(VGG-19) – TSA (LSTM) hibrit modeli.

Sunulan hibrit derin öğrenme modeli, 0,001 öğrenme katsayısı ve 16 (yığın) batch boyutu ile kayıp fonksiyonu için kategorik çapraz entropi fonksiyonuna sahip Adam optimizasyon algoritması kullanılarak eğitilmiştir. Adam, derin sinir ağların eğitiminde her bir parametre için öğrenme oranlarını keşfeden ve uyarlanabilir öğrenme oranı yaklaşımlarından yararlanan gradyan iniş algoritmalarından biridir. Kategorik çapraz entropi ise, iki veya daha fazla kodlanmış etiket sınıfı olduğunda tercih edilen kayıp fonksiyonlarından biridir. Bu algoritma, daha düşük yineleme sayısına göre daha yüksek doğruluk elde etmede diğer optimizasyon yöntemlerine göre üstündür. Daha az yinelemenin yanı sıra yüksek doğruluk avantajı, Adam'ı çok sayıda önbelleğe alınmış veriye ve daha az veri noktasına sahip derin sinir ağları eğitmek için en güçlü araç yapmaktadır [106]. Adam, Softmax aktivasyon fonksiyonu ile çok sınıflı sınıflandırma modellerini optimize eder.

Eğitim iterasyonlarının sayısı (epoch), erken durdurma (early stopping) tekniği kullanılarak otomatik olarak optimize edilmiş ve model eğitim sürecine göre belirlenmiştir. Erken durdurma, Tensorflow ile desteklenen ve doğrulama hatasını izleyerek model eğitiminin ne zaman durdurulacağını belirleyen bir metottur. Bu şekilde, iterasyon sayılarını ayarlayarak parametrelerin güçlü bir şekilde aşırı öğrenme problemine takılmasını engellemeye yardımcı olur. Doğrulama veri seti, eğitim sürecindeki yakınsamayı izler, böylece bu yakınsamadaki değişikliğe göre modelin eğitimi erken iptal edilebilir. ESA ve LSTM yöntemleri ayrı ayrı başarılı sonuçlara sahip olsa da; bazı çalışmalarda bu modellerin ayrı ayrı kullanılmalarına göre uygun şekilde birleştirildiklerinde daha güçlü ve etkili hale geldikleri gösterilmiştir [107], [108], [109].

4.3. SİSTEM 2: OK - ESA

Sistem 2'de, ESA'nın özellik çıkarımı ile OK'un denetimsiz özelliklerini OK-ESA bloğu olacak şekilde birleştiren ve bu mimariyi derin öğrenmeye dayalı olarak oluşturan bir yöntem sunulmuştur. Sistem blok şeması Şekil 4.5'te gösterilmiştir. Sisteme gelen görüntüler görüntü işleme bloğuna tabi tutulur. Burada uygun şekilde görüntü işleme adımlarından geçen görüntü daha sonra OK'a aktarılır. Yeniden oluşturulan görüntüler, sınıflandırma için ESA mimarisine beslenir.



Şekil 4.5. Sistem 2:OK – ESA hibrit model blok şeması.

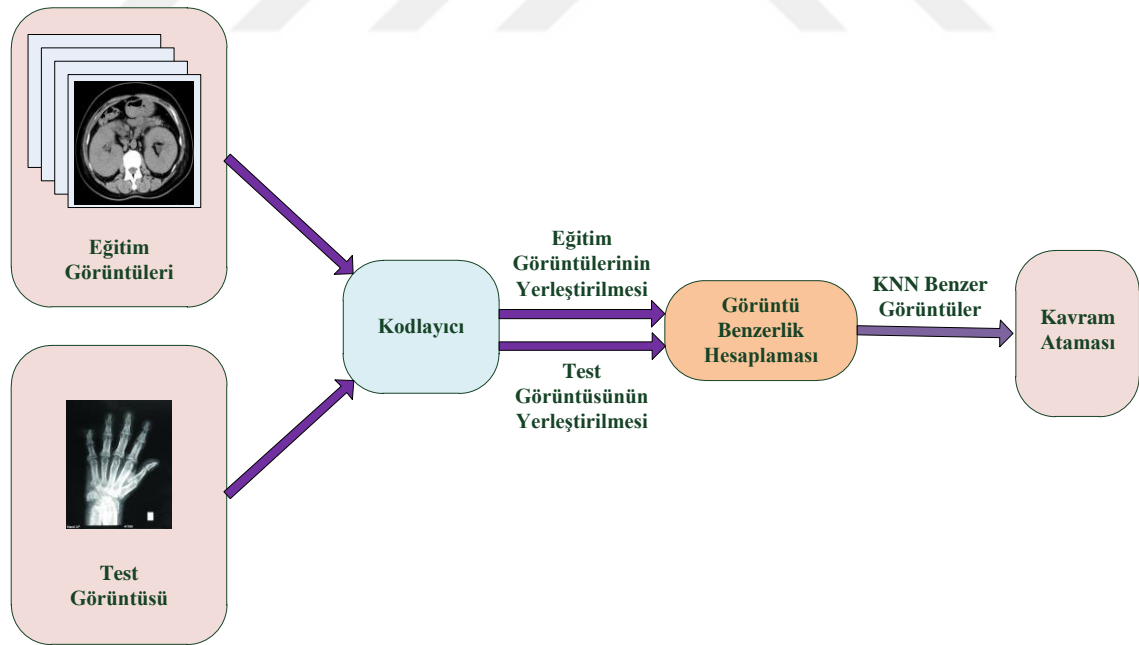
Çalışmada görüntülerle çalışıldığı için derin evrişimli otomatik kodlayıcı seçilmiştir. Tasarlanan evrişimli otomatik kodlayıcı modeli, bir kodlayıcı kısım ve bir de kod çözücü kısım içermektedir ve modelin birden çok katmanı vardır. Kodlayıcının giriş katmanı için görüntüler görüntü işleme bloğunda 192×192 olarak ölçeklendirilmiştir. Bundan sonra evrişim katmanı kullanılır. Önerilen üç evrişim katmanı vardır. Her evrişim katmanının aktivasyon fonksiyonu, bir doğrultucu doğrusal birimdir (ReLU). Her evrişim katmanından sonra havuzlama katmanı kullanılır ve pencereleme işlemi uygulanır. Kod çözme işlemi sırasında kod çözücü, kodlayıcının evrişimli katmanlarıyla aynı sayıda olan üç evrişimli devrik katman kullanır. Her evrişimsel devrik katmanda bir doğrultucu doğrusal birim (ReLU) aktivasyon fonksiyonu mevcuttur. Her evrişim devrik katmanını bir üst örnekleme katmanı takip eder. Otomatik kodlayıcı modeli, güçlü özellikleri çıkararak ağı eğitmek için kullanılır ve ardından eğitilen kodlayıcı kısım ESA ağı ile birleştirilir.

Kullanılan ESA modeli, üç evrişimli katman ve bir tam bağlantılı katman olmak üzere ağırlıklı dört katman içermektedir. İlk evrişimli katman, farklı türde özellikler elde etmek için giriş görüntüsünde 5×5 boyutunda 8 farklı çekirdeği evriştirir. Maksimum havuzlama boyutu 2×2 olarak ayarlanmıştır. İkinci evrişim katmanı ve alt örnekleme katmanının parametreleri birinci katman ile aynıdır. Üçüncü katman da 8 farklı çekirdeği benimser ancak çekirdek boyutu 3×3 'tür ve maksimum havuzlama yoktur. Üç evrişim katmanı ve

iki alt örnekleme katmanından sonra, gelen çıktı bir vektöre düzleştirilir ve tamamen bağlı katmana beslenir. Aktivasyon fonksiyonu olarak ReLU benimsenmiştir. Hiperparametre seçimleri, kapsamlı deneysel sonuçlara bağlıdır.

4.4. SİSTEM 3: ESA - KNN

Sistem 3, medikal kavramların çok etiketli sınıflandırma görevi için ESA tabanlı, önceden eğitilmiş ve tam ölçekli derin öğrenme eğitim modellerini uygulamaktadır. Bilinen kavramlara sahip benzer eğitim görüntülerini almak için sınıflandırılan görüntünün kodlamasını kullanan bir K-En Yakın Komşular (KNN) bileşeninden oluşur. Bunlar daha sonra yeni görüntüye kavramlar atamak için kullanılabilir. Çalışmada kullanılan Uyarlanabilir KNN algoritması, bir test veri noktası için en uygun k değerini seçmeye odaklanan bir varyanttır. Eğitim veri setinin her veri noktası için en uygun k değerini belirlemek için ayrı bir algoritma uygulayarak çalışır. Ana algoritma daha sonra eğitim veri setinden en yakın komşuyu bulur ve verilen bir test veri noktası için k değerini devralır. Uyarlanabilir KNN algoritması, bu kalıtsal k değerini kullanarak çıktıyı tahmin etmek için klasik KNN algoritması olarak işlev görmeye devam eder.



Şekil 4.6. Sistem 3:ESA – KNN yönteminin genel işleyişi.

Şekil 4.6, bu sistemin genel işleyişini göstermektedir. Bir ESA kodlayıcı, tüm eğitim görüntülerini görüntü yerleştirme adı verilen yoğun vektör kodlamalarını elde etmek için kullanır. Benzer şekilde, bir test görüntüsü verildiğinde, ESA kodlayıcı ile her görüntü

yoğun bir vektörle eşlenerek görüntü yerleştirme yapılır. Daha sonra, en benzer eğitim görüntüsünün kavramları döndürülerek test görüntüsüne kavram atama işlemi gerçekleştirilir. Bu sistemde; görüntü tanımının kalitesini ve doğruluğunu, önceden eğitilmiş ağı ve oluşturduğu özellik vektörünün sistemin kesinliği üzerindeki etkisini tanımak ve sonuçları karşılaştırmak, için DenseNet-121, ResNet-101, Xception ve Efficient-B7 olmak üzere 4 farklı önceden eğitilmiş ESA kodlayıcı model kullanılmıştır. Tüm modeller için veri kümelerindeki görüntülerin her bir piksel değeri önce 255'e bölünerek normalleştirilmiştir. Daha sonra görüntüler, her model tarafından kabul edilen varsayılan boyuta göre yeniden boyutlandırılmıştır. Buna göre görüntüler DenseNet-121 ve ResNet-101 için 224×224 piksel, Xception için 299×299 piksel olarak ayarlanmıştır. Deneysel çalışmalarda, donanım sınırlamaları nedeniyle en fazla parametre sayısına sahip olan EfficientNet-B7 modelinin eğitimi için donanım kaynaklarımızın izin verdiği en uygun giriş boyutunun 132×132 olduğu görülmüştür. Önceden eğitilmiş ESA modellerinin parametreleri, çok etiketli sınıflandırma modelinin başlangıç parametreleri olarak aktarılmıştır. ImageCLEFmed Caption 2019 için, KNN benzer görüntüleri alınarak bunların kavramları kullanılmıştır.

Eğitim sürecinde geri yayılım sırasında ağırlıkları güncellemek için kullanılan verilerin boyutunu ifade eden batch (yığın) değeri, toplam veri seti boyutundan daha küçük seçilir ve genellikle veri setindeki toplam örnek sayısını bölebilen bir değer tercih edilir. Bu değer, ağı yakınsama oranını ve doğru tahmini dengeleyerek öğrenme süreçlerine katkıda bulunur [110]. Bu çalışmada, tüm modellerde donanım kaynaklarının izin verdiği maksimum değer olan boyut 16 olarak ayarlanmıştır.

4.4.1. DenseNet-121

DenseNet-121 görüntü kodlayıcısı, tüm katmanların doğrudan birbirine bağlandığı, bilgi akışını iyileştiren ve kaybolan gradyanlardan kaçınan 121 katmanlı bir ESA'dır [111]. ImageNet üzerinde önceden eğitilmiş DenseNet-121 ile ImageCLEFmed Caption 2019 eğitim görüntülerinde ince ayar (fine-tuned) yapılmıştır. İnce ayar yapılmadığında, önceden eğitilmiş kodlayıcının performansının daha kötü olduğu görülmüştür. ImageCLEFmed Caption 2019 görüntüleri, 224×224 'e yeniden ölçeklendirilmiştir ve DenseNet-121'in gereksinimlerine uymasına için ImageNet'in ortalama ve standart sapması ile normalleştirilmiştir. DenseNet121'in ince ayarı yapıldıktan sonra, tüm eğitim görüntülerinin yoğun vektör kodlamalarını elde etmek için kullanılmıştır. Görüntülerin

vektör kodlamaları, DenseNet-121'in son ortalama havuzlama katmanından çıkarılmıştır. Daha sonra görüntü yerleştirmeleri, etiket başına bir olasılık üretmek için 5.528 çıktı ve sigmoid aktivasyonları olan yoğun bir katmandan geçirilir. Model, ikili çapraz entropi kaybını en aza indirerek eğitilmiştir. Varsayılan hiper parametreleri ile Adam algoritması kullanılmıştır. Bir test görüntüsü verildiğinde, görüntünün yoğun vektör kodlamalarını elde etmek için tekrar ince ayarlanmış DenseNet-121 kullanılır. Daha sonra görüntü vektör kodlamalarından hesaplanan, test görüntüsüne en yüksek kosinüs benzerliğine sahip k eğitim görüntüsü alınır ve k görüntünün kavramları arasında en sık görülen r kavramları döndürülür. Alınan belirli k görüntünün en sık görülen r kavram sayısı, görüntü başına düşen ortalama kavram sayısı olarak ayarlanmıştır.

Test zamanında, eğitilmiş model tarafından tahmin edilen olasılıkları kullanarak her test görüntüsü için ilgili kavramlar belirlenir. Her kavram için karşılık gelen tahmini olasılık, bir eşik t 'yi aşarsa bu kavram test görüntüsüne atanır. Veri setindeki 5.528 kavramın tümü için aynı t değeri kullanılmıştır ve bu değer 0,3 olarak ayarlanmıştır.

4.4.2. ResNet-101

ResNet, ağ derinliğini artırmaktan kaynaklanan yok olan gradyan problemini çözmek için artık bir blok (a residual block) sunar [112]. Bu ağ yapısında kullanılan kısayol bağlantıları, bir veya daha fazla katmanı atlayabilirler. Artık bloklarla girdiler, katmanlar arasında kalan bağlantılar üzerinden daha hızlı yayılabilir. ResNet-101, ImageNet veri tabanından bir milyondan fazla görüntü üzerinde eğitilmiş 101 katman derinliğinde bir ESA'dır. ResNet-101 üzerine kurulu kodlayıcıda, bir görüntü ilk olarak ağın girişine uyum sağlamak için ön işleme tabi tutulur. Tekdüzelik için ortalama ve standart sapma ile normalize edilen ImageCLEFmed Caption 2019 girdi görüntüleri 224×224 olarak yeniden boyutlandırılır ve çıktı özellik vektörlerini elde etmek için ağa ileri beslenir. Daha sonra her sınıfın olasılığını hesaplamak için sigmoid aktivasyon fonksiyonu ile tam bir bağlantı katmanından geçilir. Olasılık 0,3'ten büyükse, girdi görüntüsünün o sınıfa ait olduğu düşünülür. Son olarak, orijinal kavramlara geri yansıtılabilen, tahmin edilen etiketler elde edilir.

4.4.3. Xception

Evrişimsel Sinir Ağlarının özellik haritalarındaki kanallar arası korelasyonların ve uzamsal korelasyonların haritalanmasının tamamen ayrıştırılabileceği hipotezi ile ortaya çıkan bu mimariye, Inception mimarisinin altında yatan hipotezden daha güçlü bir

versiyon olduğundan, "Extreme Inception" anlamına gelen Xception adı verilmiştir [60]. Modelin ana motivasyonu, derinlemesine ayrılabilir evrişimlere ve artık bağlantılara dayanmaktadır. Derinlemesine evrişim, (1×1) evrişimin (noktasal evrişim) ardından kanal bazında uzamsal evrişimin (n×n) geldiği anlamına gelir. Başlangıçtaki modüllerin derinlemesine ayrılabilir konvolüsyonlarla değiştirildiği, hesaplama karmaşıklığını azaltmak için orijinal başlangıç bloğunu daha geniş hale getirildiği Xception, 14 modül halinde yapılandırılmış 36 evrişim katmanından ve giriş akışı, orta akış ve çıkış akışı olarak bilinen üç ana akıştan oluşur.

ImageCLEFmed Caption 2019 görüntüleri, 299×299'a yeniden ölçeklendirilir ve eğitim setindeki görüntüler, önce özellik haritalarını oluşturan giriş akışına iletilir. Özellik haritaları ayrıca orta akışa beslenir ve bu işlem sekiz kez tekrarlanır. Son olarak, çıkış akışındaki özellik haritaları 2048 boyutlu vektörler oluşturur. Ayrılabilir konvolüsyonları toplu normalleştirmeler takip eder [113]. Bu mimarinin uygulanması Keras'ta gerçekleştirilmiştir. Modelle ilgili ince ayar için, transfer öğreniminden yararlanılmıştır ve ImageNet üzerinde önceden eğitilmiş ağırlıklar kullanılmıştır. ImageNet'te önceden öğrenilen ağırlıklarla transfer öğrenmenin, tıbbi görüntüler gibi farklı bir görüntü kümesi üzerinde kullanışlı olduğunu gösterir. Ayrıca son katmanda maksimum havuzlamanın eklenmesi ve güven eşiğinin optimize edilmesi, Xception modelin performansını artırmıştır.

4.4.4. EfficientNet-B7

EfficientNet, en güçlü ESA mimarilerinden biridir ve diğer modellere göre daha az hesaplama kaynağı gerektirirken çeşitli veri kümelerinde son derece yüksek performans elde eder. Bu mimari, tıbbi görüntüler ile geleneksel görüntüler arasında önemli bir fark olmasına rağmen, önemli tıbbi görüntü sınıflandırma potansiyelleri sağlayabilen uygun bir modeldir. Ancak henüz EfficientNet'in tıbbi görüntülerdeki yetenekleri üzerinden çok fazla çalışılmamış olması, bu çalışmada modelin kullanılması için bizi motive etmiştir.

EfficientNet, modeli küçültürken derinliği, genişliği ve çözünürlüğü eşit şekilde ölçeklendirerek daha verimli sonuçlar elde eder. Bileşik ölçekleme yöntemindeki ilk adım, sabit bir kaynak kısıtlaması altında temel ağın farklı ölçeklendirme boyutları arasındaki ilişkiyi bulmak için bir ızgara aramaktır. Bu sayede derinlik, genişlik ve çözünürlük boyutları için uygun bir ölçekleme faktörü belirlenir. Bu katsayılar daha sonra temel ağı istenen hedef ağı ölçeklendirmek için uygulanır. Diğer ESA modellerinden

farklı olarak EfficientNet, ReLU aktivasyon fonksiyonu yerine Swish adlı yeni bir aktivasyon fonksiyonu kullanır [114]. EfficientNet grubu B0 ile B7 arasında 8 modelden oluşmaktadır ve model numarası büyüdükçe hesaplanan parametre sayısı çok fazla artmazken doğruluk gözle görülür şekilde artar [115].

Bu çalışmada, Efficientnet-B7 ile transfer öğrenmeyi kullanan kodlayıcı-kod çözücü yaklaşımına dayalı model önerilmiştir. EfficientNet-B7, modeli geliştirmek için basitleştirilmiş ve etkili bir bileşik katsayı kullanarak derinlik, genişlik ve çözünürlükleri eşit şekilde ölçeklendirir. EfficientNet-B7 modeli 7 blok içerir. Bu bloklar ayrıca, EfficientNetB0'dan EfficientNetB7'ye geçtikçe sayıları artan değişen sayıda alt bloğa sahiptir. EfficientNet-B70'nin toplam katmanı 813'tür ve bu katmanlar 5 modülden oluşur. Bu modüllerin işlevleri kısaca şöyledir [116]:

Modül 1 – Bu modül, alt bloklar için bir başlangıç noktası olarak kullanılır.

Modül 2 – Bu modül, 1. blok hariç tüm 7 ana bloğun ilk alt bloğu için bir başlangıç noktası olarak kullanılır.

Modül 3 – Bu modül, tüm alt bloklara bir atlama bağlantısı olarak bağlanır.

Modül 4 – Bu modül, atlama bağlantısını ilk alt bloklarda birleştirmek için kullanılır.

Modül 5 – Her alt blok bir önceki alt bloğa bir atlama bağlantısıyla bağlanır ve bu modül kullanılarak birleştirilir.

4.5. SİSTEMLERİN DEĞERLENDİRİLMESİ

Tez çalışmasında sunulan sistemler ImageCLEFmed Caption 2019'da geliştirme ve test veri setleri için F1 puanları hesaplanarak değerlendirilmiştir. F1 puanı, kavram belirleme görevini gerçekleştirmek için kullanılan tekniklerin performansını değerlendirmek için sıklıkla kullanılır ve bu puan kesinlik (precision) ve duyarlılık (recall) değerinin harmonik ortalaması olarak hesaplanmaktadır. Bu bölümdeki değerlendirme için kesinlik değeri, ilişkili tüm kavramlarıyla birlikte doğru tahmin edilen görüntü sayısının, kavramları tahmin edilen toplam görüntü sayısına oranıdır. Duyarlılık değeri ise, ilişkili tüm kavramlarıyla birlikte doğru tahmin edilen görüntü sayısı ile kavramlarıyla ilişkilendirilmiş toplam görüntü sayısı arasındaki orandır. Belirtilen F1 puanı değerlendirme ölçütü Denklem (4.1) ile ifade edilirken, kesinlik ve duyarlılık ölçütleri sırasıyla Denklem (4.2) ve Denklem (4.3)'te verilmiştir. [117][118].

$$F1 \text{ puanı} = \frac{2 \times \text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (4.1)$$

$$\text{kesinlik} = \frac{\text{ilişkili tüm kavramlarıyla birlikte doğru tahmin edilen görüntü sayısı}}{\text{kavramları tahmin edilen toplam görüntü sayısı}} \quad (4.2)$$

$$\text{duyarlılık} = \frac{\text{ilişkili tüm kavramlarıyla birlikte doğru tahmin edilen görüntü sayısı}}{\text{kavramlarıyla ilişkilendirilmiş toplam görüntü sayısı}} \quad (4.3)$$

F1 puanının normal bir ortalama yerine harmonik ortalama olmasının nedeni uç durumları da hesaba katmamız gerektiğindedir. Eğer basit bir ortalama hesaplaması olsaydı, kesinlik değeri 1 ve duyarlılık değeri 0 olan bir modelin F1 puanı 0,5 olarak hesaplanacaktır ve bu durum yanıltıcı olabilir. F1 puanının kullanılmasının en temel sebebi, eşit dağılmayan veri kümelerinde hatalı bir model seçimi yapmamaktır. Ayrıca tüm hata maliyetlerini de içerecek bir ölçme metriğine ihtiyaç olduğu zamanlarda F1 puanı önemlidir.

Bu çalışma için F1 puanı, model tarafından öngörülen kısmi doğru kavramları hesaba katmadığından, model tarafından tahmin edilen kısmi doğru kavramların dikkate alınabilmesi için daha sağlam değerlendirme metriklerine ihtiyaç duyulduğu açıktır. Ancak sonuçların başka çalışmalarla karşılaştırılabilir ve objektif şekilde değerlendirilebilir olması açısından F1 metriğinin bu şekilde hesaplanması tercih edilmiştir.

Tez çalışmasında kullanılan üç farklı hibrit derin öğrenme sistemine ait geliştirme ve test verileri üzerindeki değerlendirme sonuçları Çizelge 4.5'te verilmiştir. İlk hibrit sistemde iki farklı denetimli öğrenme tekniği olan ESA ve TSA beraber uygulanmıştır. İkinci hibrit sistemde denetimsiz ve denetimli öğrenme tekniğinin birleştirildiği OK-ESA kombinasyonu sunulmuştur. Üçüncü hibrit sistemde ise denetimli öğrenme tekniği olan ESA'nın dört farklı modeli ile makine öğrenme sınıflandırıcısı olan KNN algoritması birlikte kullanılmıştır. ImageCLEFmed Caption 2019 veri seti (Vs), filtrelenmiş veri setleri Vs,1 ve Vs,3 üzerindeki geliştirme ve değerlendirme test sonuçları ayrı ayrı gösterilmektedir. Sistem 3:ESA-KNN için verilen F1 puanları, kullanılan dört farklı ESA ön tanımlı model arasından en yüksek F1 puanın elde edildiği Xception modeline ait puanlardır.


Değerlendirme, sistem tarafından tahmin edilen ve kesin doğruluk kavramları arasındaki F1 puanları açısından gerçekleştirilmiş olup sonuçlarda görüntü başına hesaplanan ve

daha sonra tüm test görüntülerinin ortalaması alınarak elde edilen F1 puanları sunulmuştur.

Çizelge 4.5. Hibrit sistemler için geliştirme ve test sonuçları.

Sistem Tanımı	Geliştirme F1 puanı			Test F1 puanı		
	Vs	Vs,1	Vs,3	Vs	Vs,1	Vs,3
Sistem 1: ESA-TSA	0,2642	0,2978	0,2812	0,2719	0,3067	0,2860
Sistem 2: OK-ESA	0,2086	0,2237	0,2174	0,2193	0,2294	0,2181
Sistem 3: ESA-KNN	0,2456	0,2836	0,2427	0,2575	0,2912	0,2669

Çalışmada test edilen üç farklı hibrit derin öğrenme sistemi için; Vs, Vs,1 ve Vs,3 veri setlerine ait test F1 puanı sonuçlarının grafiksel gösterimi Şekil 4.7’de sunulmuştur. Hem orijinal veri seti ve hem de diğer iki filtrelenmiş veri seti üzerindeki sonuçlarda incelendiğinde Sistem 1:ESA-TSA için F1 puanlarının diğer iki hibrit sistemden daha yüksek olduğu görülmektedir. En yüksek F1 puanı ise 0,3067 değeri ile Vs,1 veri seti üzerinden elde edilmiştir.

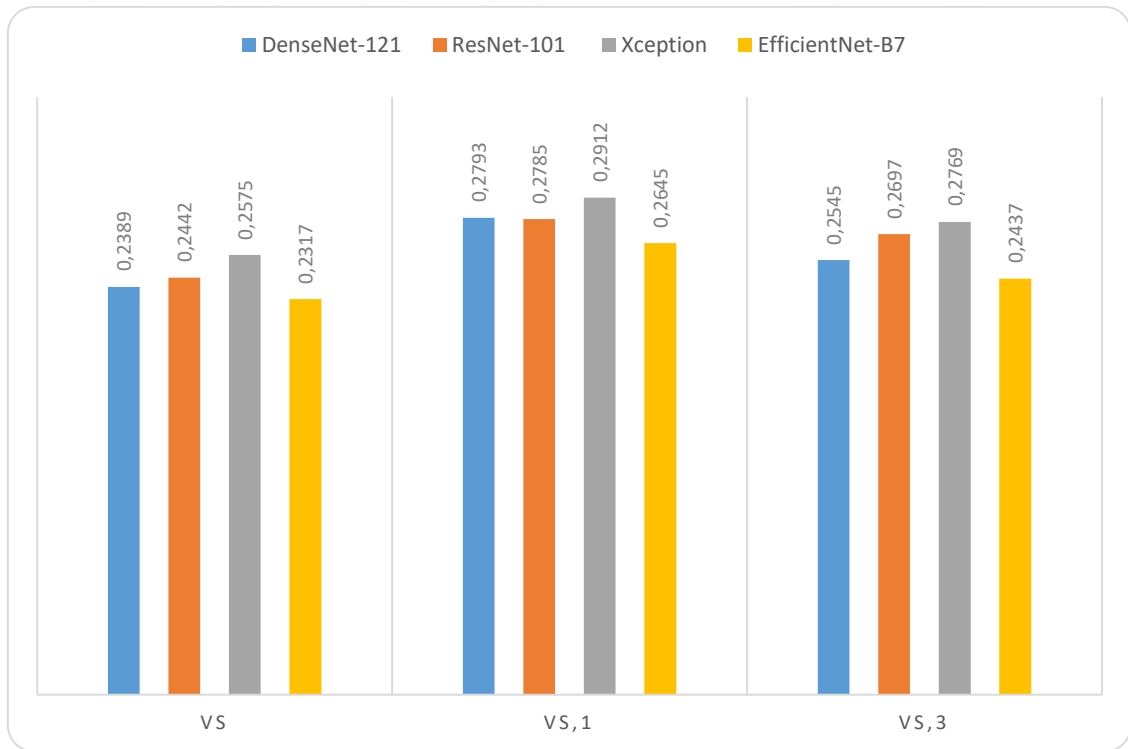


Şekil 4.7. Hibrit derin öğrenme sistemlerinin Vs, Vs,1 ve Vs,3 veri setleri üzerinde test F1 puanları için grafiksel sonuçlar.

ESA'nın dört farklı modeli DenseNet-121, ResNet-101, Xception ve EfficientNet-B7 ile KNN algoritmasının birlikte kullanıldığı Sistem 3'e ait geliştirme ve test sonuçları Çizelge 4.6'da verilmiştir. Genel sistem değerlendirmesine benzer şekilde Vs, Vs,1 ve Vs,3 üzerindeki sonuçlar ayrı ayrı sunulmuştur. Sonuçlar değerlendirildiğinde, ESA-KNN mimarisinde en iyi performansın Xception modeli ile elde edildiği görülmektedir. Çalışmada test edilen dört farklı önceden eğitilmiş ESA modeli için; Vs, Vs,1 ve Vs,3 veri setlerine ait test F1 puanlarının grafiksel gösterimi ise Şekil 4.8'de sunulmuştur.

Çizelge 4.6. Sistem 3 için dört farklı ESA kodlayıcı modelinin geliştirme ve test sonuçları.

ESA Kodlayıcı Modelleri	Geliştirme F1 puanı			Test F1 puanı		
	Vs	Vs,1	Vs,3	Vs	Vs,1	Vs,3
DenseNet-121	0,2307	0,2723	0,2338	0,2389	0,2793	0,2545
ResNet-101	0,2369	0,2697	0,2465	0,2442	0,2785	0,2697
Xception	0,2456	0,2836	0,2427	0,2575	0,2912	0,2769
EfficientNet-B7	0,2284	0,2517	0,2396	0,2317	0,2645	0,2437



Şekil 4.8. Önceden eğitilmiş dört farklı ESA modeline ait Vs, Vs,1 ve Vs,3 veri setleri üzerinde test F1 puanları için grafiksel sonuçlar.

Veri setleri ele alınarak sonuçlara detaylı olarak bakıldığında, filtrelenmiş veri seti Vs,1 için en yüksek sonuçların elde edildiği görülmektedir. Vs,3 sonuçları, Vs,1 kadar iyi olmasa da hiç filtreleme işlemi yapılmamış orijinal veri seti üzerindeki sonuçlardan daha iyidir. Bu durum bize veri setinde filtreleme işleminin gerekli olduğunu ancak yapılacak yüksek frekansta filtreleme işleminin veri kaybına neden olabileceğinden, F1 puanını düşüreceğini göstermektedir. Çünkü test veri setinde filtreleme işlemi sonucunda eğitim veri setinden silinmiş kavramlar ile karşılaşılabilir ve bu durum model üzerinde sonuçların hatalı olarak hesaplanmasına sebep olabilir.

ImageCLEF aksiyonun bir parçası olarak 2019 yılında ortaya atılan ImageCLEFmed Caption görevi için literatürde yapılan çalışmalar incelenmiş ve bu çalışmalardan en yüksek F1 puanlarını elde eden ilk 10 tanesi Çizelge 4.7’de sunulmuştur [119].

Çizelge 4.7. 2019 ImageCLEFmed Caption görevi için F1 puanı değerlendirilmesi.

Takım Adı	F1 puanı
Bayrakdar, ESA-TSA Hibrit Model	0,3067
AUEB NLP Group	0,2823094
damo	0,2655099
GuaJing	0,2265250
ImageSem	0,2235690
UA.PT_Bioinformatics	0,2058640
richard_ycli	0,1952310
Sam Maksoud	0,1749349
AI600	0,1656261
MacUni-CSIRO	0,1435435
pri2si17	0,0496821

Bu tez çalışmasında; görüntü özelliği çıkarıcı için, temel bir ESA'nın kullanıldığı ve bir bellek hücresi aracılığıyla uzun vadeli bağımlılıkları öğrenme yeteneğinin kavramları oluşturmak için kullanıldığı LSTM'nin olduğu kodlayıcı-kod çözücü ağı olarak tasarlanan Sistem 1'in; Vs,1 veri seti üzerindeki test F1 puanı 0,3067 olarak hesaplanmıştır. Bu değer hala iyileştirmeye açık olmakla birlikte; Çizelge 4.7’de görüldüğü üzere daha önce sunulan çalışmalardan daha yüksektir.

5. RADYOLOJİK SOSYAL AĞDA GÖRÜNTÜ VE METİN TABANLI MEDİKAL KAVRAM TAHMİNİ

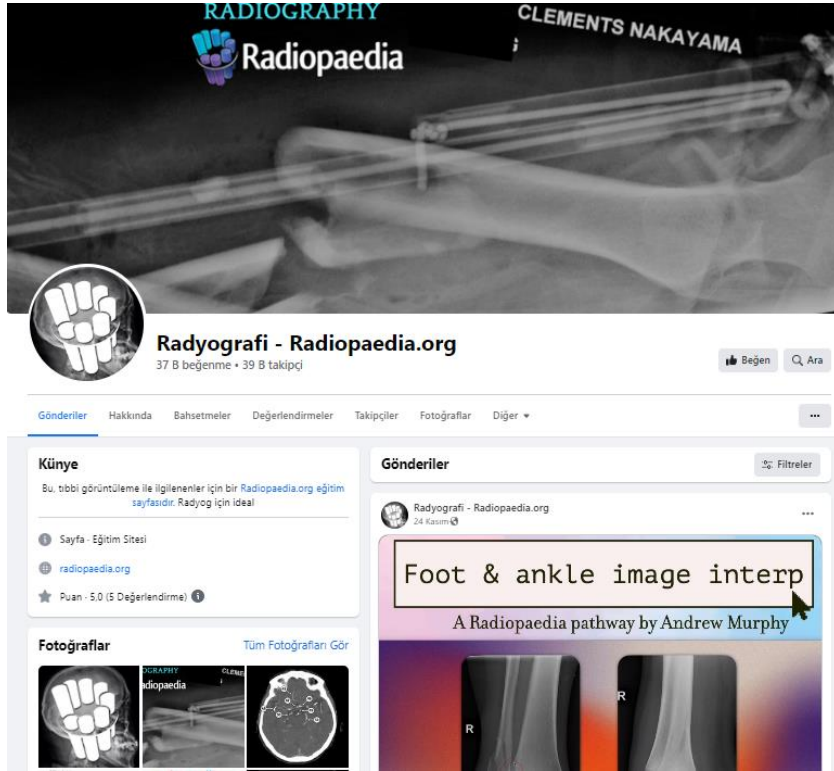
Radyolojik tanı, radyologlar için çoğu zaman zorlu ve zaman alıcı olmakla birlikte, birçok tıbbi deneyim ve yüksek düzeyde konsantrasyon gerektirir. Günümüzde patoloji ve radyoloji görüntüleri gibi medikal görüntüler, hastanelerde tedavi amacıyla yaygın olarak kullanılmaktadır. Medikal görüntülerin okunması ve özetlenmesi genellikle uzman sağlık çalışanları tarafından yönetilmektedir [120] . Radyolojik görüntülerden bilgi elde etmek ise zaman alıcı ve zahmetli bir iştir. Ancak, araştırma ve öğretim için kritik derecede önemlidir. Büyük radyolojik görüntü veri tabanlarının otomatik indekslenmesini ve alınmasını kolaylaştırmak için, hem görüntüler hem de ilgili metinler, UMLS sözlüğünden medikal kavramlar kullanılarak indekslenir.

Medikal kavram çıkarımının amacı, tıbbi belgelerden problemler, tedaviler ve testler gibi ilgili medikal kavramlara atıfta bulunan ifadeleri belirlemektir. Bu tez çalışmasında, dördüncü bölümde açıklanan üç farklı hibrit derin öğrenme sistemi ile medikal kavram tahmini gerçekleştirilmiş ve daha sonra bu sistemler karşılaştırılmıştır. Bu bölümde geliştirilen hibrit derin öğrenme yaklaşımları, radyolojik bir sosyal ağ üzerinden oluşturulmuş veri setinde test edilmiştir.

Kullanılan radyolojik ağ, Şekil 5.1 ve Şekil 5.2’de sırasıyla gösterilen, Facebook sosyal ağı üzerinde Radiopaedia.org ve Radiography-Radiopaedia.org adları ile oluşturulmuş eğitim sayfalarıdır. Tıbbi görüntüleme ile ilgilenenler için, ücretsiz çevrimiçi işbirlikçi radyoloji kaynağı olarak kendisini tanımlayan bu sosyal ağ sayfaları, amacını da en kapsamlı çevrimiçi radyoloji birlikteliği oluşturma olarak belirtmiştir. Bu sosyal ağ sitelerinde paylaşılan radyolojik görüntülerin altına kullanıcılar tarafından görüntüye ilişkin teşhiş/tanı/sorun vb. ile ilgili yorumlar yapılmaktadır.



Şekil 5.1. Facebook Radiopaedia.org radyolojik sosyal ağı.



Şekil 5.2. Facebook Radiography-Radiopaedia.org radyolojik sosyal ağı.

Facebook sosyal ağı üzerinde Radiography-Radiopaedia.org sayfasında paylaşılan örnek bir görüntü ve görüntü ile ilgili yapılan yorumlar Şekil 5.3'te sunulmuştur. Görüntüye ait ilgili kavram ise cevap olarak yine ilgili sosyal ağ sitesi üzerinde link verilerek paylaşılmıştır.



Şekil 5.3. Facebook Radiography-Radiopaedia radyolojik sosyal ağ sayfasından örnek bir görüntü ve görüntüye ait bazı yorumlar.

Şekil 5.3'te gösterilen örnek görüntü için <https://radiopaedia.org/> sitesi üzerinde paylaşılan başlık ve görüntünün altında yer alan görüntü başlığı bilgisi Şekil 5.4'te (Dr. Bahman Rasuli izniyle, Radiopaedia.org, rID 66751) gösterilmektedir. Gerçek kavramların belirlenmesinde bu metinsel bilgilerden yararlanılmıştır.

Mandibular ramus fracture

Case contributed by Bahman Rasuli

Diagnosis certain

+ Citation, DOI & case data

Share

Add to

Settings

Presentation

Left jaw trauma.

Patient Data

Age: 30 years

Gender: Male



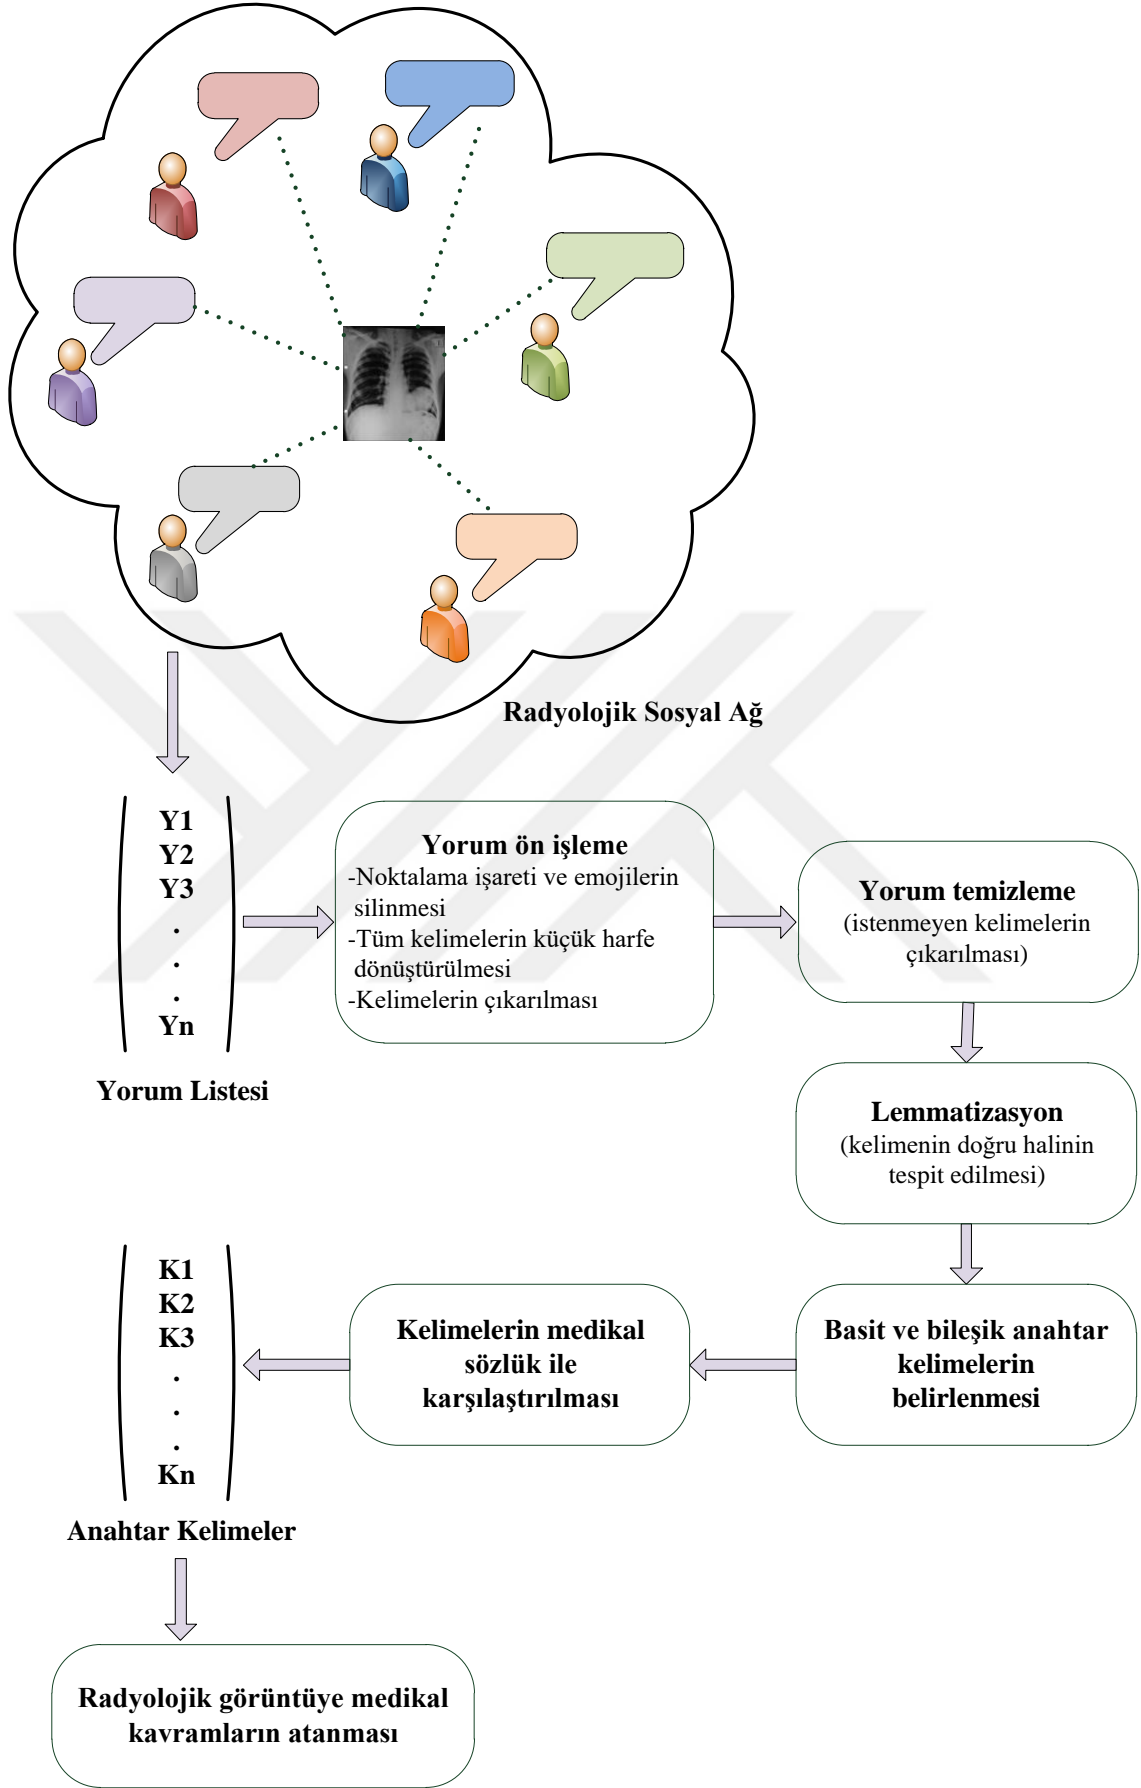
Şekil 5.4. Radiopaedia.org sitesi üzerinden ilgili görüntü için paylaşılan medikal kavram ve başlık bilgisi.

Bu tez çalışmasında ilgili radyolojik sosyal ağ sayfaları Radiopaedia.org ve Radiography-Radiopaedia.org üzerinden medikal kavram tespiti için 200 görüntü ve görüntülere ait yorumlar toplanarak Radiopaedia Test Veri seti (Rdpd_Test_Vs) hazırlanmıştır. Hazırlanan veri setine ait sayısal bilgiler Çizelge 5.1’de verilmiştir.

Çizelge 5.1. Oluşturulan Radiopaedia veri setine (Rdpd_Test_Vs) ait sayısal bilgiler.

Radiopaedia veri seti (Rdpd_Test_Vs)	Toplam Görüntü Sayısı	Toplam Yorum Sayısı	Yorumlardan Elde Edilen Anahtar Kelime Sayısı
Radiopaedia.org radyolojik sosyal ağı	78	643	765
Radiography-Radiopaedia.org radyolojik sosyal ağı	122	791	827


ImageCLEF 2019 veri setinde olduğu gibi, görüntü başlıkları görüntülerle ilişkili olacak şekilde “captions.txt” olarak kayıt altına alınmıştır. Yine ilişkili yorumlar ImageCLEF 2019 veri setinde olduğu gibi “comments.txt” olarak kaydedilmiştir. Yorumların çok büyük bir çoğunluğu İngilizce olarak yazıldığından sadece İngilizce yazılan yorumlar kayıt altına alınmıştır. Yorum yapan kişinin kullanıcı kimliği dışında yazdığı tüm ifadeler (kelimeler, kısaltmalar, noktalama işaretleri, boşluk, emoji vb.) alınmış ve birleştirilmiştir. Daha sonra metin madenciliği yapılarak ilgili medikal anahtar kelimeler çıkarılmıştır. Çıkarılan anahtar kelimeler, ilgili görüntülerle ilişkili olacak şekilde “keywords.txt” şeklinde kayıt altına alınmıştır. Bu süreç, Şekil 5.5’te detaylı olarak gösterilmektedir. Metin madenciliği, yapılandırılmamış metinden yararlı bilgileri bulmak için kullanılan yöntemleri kapsamaktadır ve medikal alanında da önemli bir görevdir. Bilgi çıkarma ve doğal dil işleme için kullanılan metin madenciliğindeki geleneksel yaklaşımlar, genellikle anahtar kelime tabanlı benzerliğe dayanır.



Şekil 5.5. Radyolojik görüntü yorumlarından medikal anahtar kelimelerin belirlenmesi.

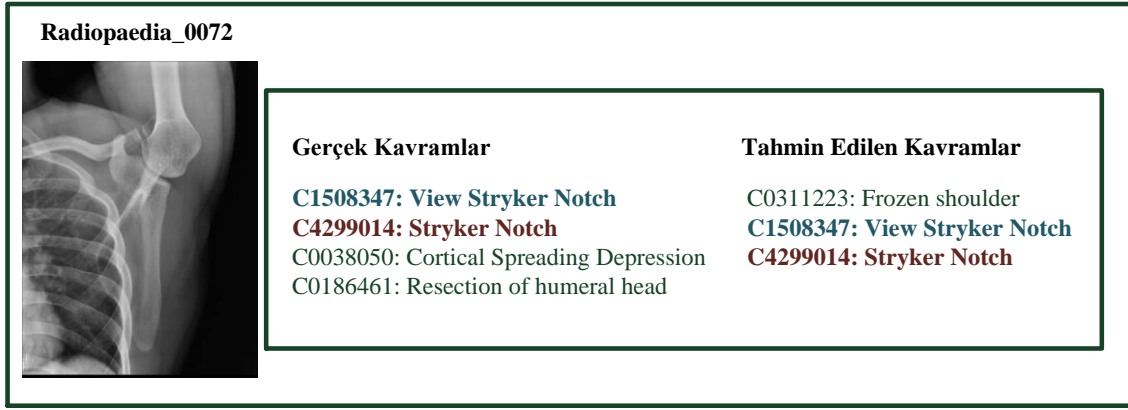
Bir radyoloji görüntüsü için toplanan yorumlar, ilk olarak ön işleme tabi tutulmuştur. Yorum listesinin ön işlenmesi, metin materyalinden anahtar kelime verilerini tanımlamanın ön adımıdır. Burada noktalama işaretleri ve emoji sembollerinin kaldırılması, cümlelere ait tüm kelimelerin küçük harfe dönüştürülmesi ve kelimelerin elde edilmesi işlemleri sırasıyla gerçekleştirilmiştir. Temizleme adımı, etkisiz kelimeleri kaldırmaya çalışır. Bu görevi başarmak için, medikal alanda ilgisiz görünen, istenmeyen kelimeleri içeren bir anti-sözlük kullanılır. Anti-sözlük; edatlar, zamirler, bazı zarflar ve sıfatlar vb. gibi indeks olarak kullanılmayacak sözcükleri içeren standart bir listedir. Bu yüzden, onları indekslemenin veya bir bilgi alma sürecinde kullanmanın bir anlamı yoktur. Lemmatizasyon ise kelimenin sözlükteki “doğru” halinin tespit edilmesi işlemidir. Yorumların yazılması, insan doğasına bağlı olarak, yanlış yazılmış kelimeler içerebilir. Bu durum da indeksleme modelini olumsuz etkileyebilir. Bazen de dil bilgisel sebeplerden dolayı yorumlar çeşitli kelimelerin farklı biçimlerini içerebilir. Kelimelerin standart biçimini arayan lemmatizasyon, bir kelimenin farklı çekimli biçimlerini tek bir öge olarak analiz edilebilmeleri için gruplandırma aşamasıdır. Lemmaları yani kelimelerin standart halini bulmak için, kök veya ön eki arayan bir stemmer algoritması (Porter algoritması) uygulanmıştır [121][122].

Aday anahtar kelimelere katılan basit ve bileşik terimler çıkarıldıktan sonra, kontrollü bir kelime dağarcığından (sözlük, eş anlamlılar veya terimler listesi vb.) seçilen kavramların çıkarılması adımına geçilir. Kelimelerin medikal bir sözlük ile karşılaştırılması, harici bir anlamsal kaynak ile gelen doğrulama adımıdır. Kelimelerin medikal sözlüğe ait olup olmadığı kontrol edilerek bir filtreleme işlemi yapılır. Çalışmada, U.S. National Library of Medicine tarafından sağlanan UMLS kullanılmıştır. Daha sonra UMLS-CUI dönüşümü yapılmıştır. Şekil 5.6’da Rdpd_Test_Vs’de yer alan örnek bir radyoloji görüntüsü (Dr. Andrew Murphi zniyle, Radiopaedia.org, rID 45881), onunla ilişkili başlık ve görüntü başlığı bilgileri, CUI’leri ile birlikte kavramlar, görüntüye ait yorum listesi ve yorumlardan elde edilen anahtar kelimeler gösterilmektedir.

Radiopaedia_0000	Kavramlar														
<p>Başlık: Posteromedial tubercle fracture of the talus</p>	<table border="1"> <thead> <tr> <th>CUI</th> <th>UMLS</th> </tr> </thead> <tbody> <tr> <td>C1179848</td> <td>Posteromedial</td> </tr> <tr> <td>C0825537</td> <td>Medial tubercle of talus</td> </tr> <tr> <td>C0347813</td> <td>Fracture of talus</td> </tr> <tr> <td>C0039277</td> <td>Talus</td> </tr> <tr> <td>C3507537</td> <td>avulsion fracture of talus</td> </tr> <tr> <td>C3507541</td> <td>displaced avulsion fracture of talus</td> </tr> </tbody> </table>	CUI	UMLS	C1179848	Posteromedial	C0825537	Medial tubercle of talus	C0347813	Fracture of talus	C0039277	Talus	C3507537	avulsion fracture of talus	C3507541	displaced avulsion fracture of talus
CUI	UMLS														
C1179848	Posteromedial														
C0825537	Medial tubercle of talus														
C0347813	Fracture of talus														
C0039277	Talus														
C3507537	avulsion fracture of talus														
C3507541	displaced avulsion fracture of talus														
	<p>Yorum Listesi</p> <p>deltoid injury Avulsion# talus An avulsion fracture of posteromedial talus.. What's the ovoid shaped opacity in the lower tibia ? It was a awesome case..... Avulsion # posteeior talus Avulsion fracture of medial talus shoulder avulsion fracture of talus Avulsion fracture of medial process of tallus Is that your ankle Looks like it Talus-fracture medial</p> <p>Anahtar Kelimeler</p> <p>deltoid injury avulsion fracture of posteromedial talus ovoid shape lower tibia posteeior talus avulsion fracture of medial talus shoulder avulsion fracture of talus avulsion fracture of medial process of talus talus-fracture medial</p>														
<p>Görüntü Başlığı: Avulsion fracture of the posteromedial tubercle of the talus with minimal displacement.</p>															

Şekil 5.6. Rdpd_Test_Vs'de yer alan örnek bir görüntü ve görüntü ile ilişkili bilgiler.

Bu çalışmada oluşturulan Rdpd_Test_Vs üzerinde, dördüncü bölümde önerilen üç farklı hibrit derin öğrenme modeli ile eğitilen sistemler test edilmiştir. Test setiyle ilgili kavram tahminleri, her satırın görüntü kimliğine ve ardından hibrit derin öğrenme modelleri aracılığıyla o görüntünün tahmin edilen medikal kavramlarına karşılık gelen bir txt dosyasına kaydedilir. Şekil 5.7, Rdpd_Test_Vs koleksiyonunun bir kavram tahmin etme örneğini göstermektedir.



Şekil 5.7. Rdpd_Test_Vs'de yer alan örnek bir görüntü için gerçek kavramlar ve ESA-TSA sisteminde tahmin edilen kavramlar.

Tez çalışmasının bu bölümünde kullanılan yaklaşımların performansı, dördüncü bölüme benzer olarak bilgi erişim sistemlerinin değerlendirilmesinde sıklıkla kullanılan kesinlik (precision), duyarlılık (recall) ve F1 puanı ölçütleri ile gerçekleştirilmiştir. Ancak bu bölümdeki değerlendirmede ölçütlerinin hesaplanmasında model tarafından öngörülen kısmi doğru kavramlar da dikkate alınmıştır. Buna göre bu bölümde hesaplanan kesinlik değeri bir görüntü için doğru tahmin edilen kavram sayısının, çıkarılan toplam kavram sayısına oranıdır. Duyarlılık değeri ise, bir görüntü için doğru tahmin edilen kavram sayısı ile tahmin edilmesi gereken doğru kavram sayısı arasındaki orandır. Bu değerlendirme ölçütleri sırasıyla Denklem (5.1) ve Denklem (5.2)'de verilmiştir [26]. F1 puanı ise, Denklem (5.3)'te görüldüğü gibi kesinlik ve duyarlılık değerinin harmonik ortalaması olarak hesaplanmaktadır.

$$kesinlik = \frac{\text{doğru tahmin edilen kavram sayısı}}{\text{çıkarılan toplam kavram sayısı}} \quad (5.1)$$

$$duyarlılık = \frac{\text{doğru tahmin edilen kavram sayısı}}{\text{doğru tahmin edilmesi gereken toplam kavram sayısı}} \quad (5.2)$$

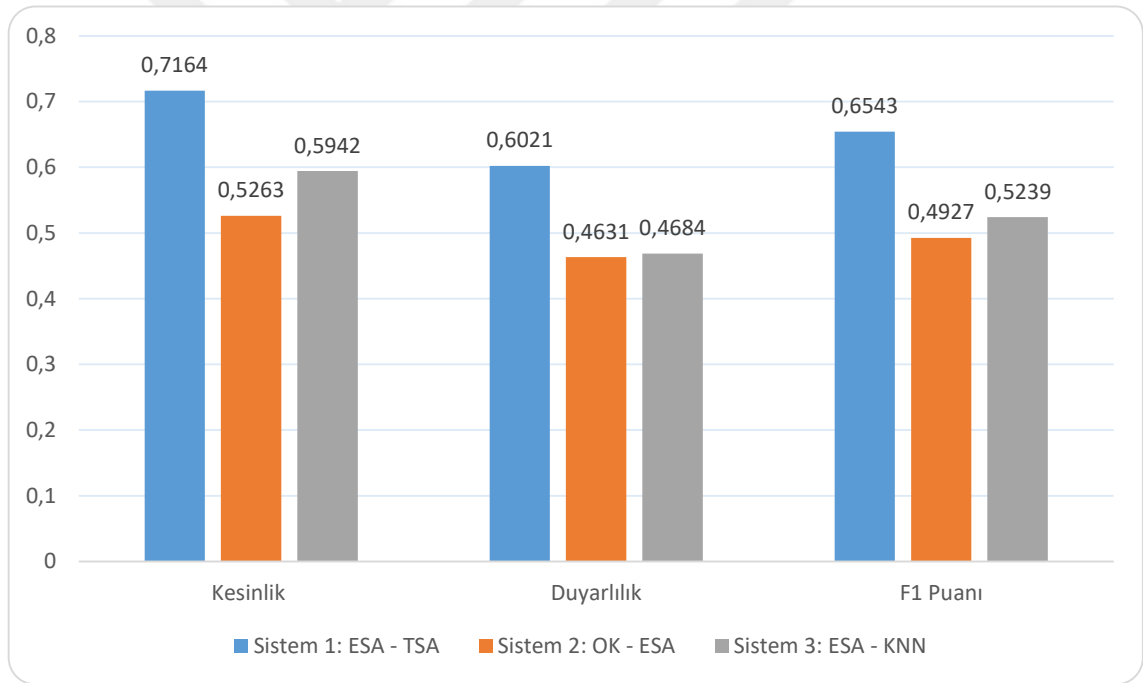
$$F1 \text{ puanı} = \frac{2 \times \text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (5.3)$$

Çalışmada Rdpd_Test_Vs üzerinde test edilen üç farklı derin öğrenme hibrit sistem için hesaplanan kesinlik, duyarlılık ve F1 puanı değerleri Çizelge 5.2'de sunulmuştur. Sunulan sonuçlarda görüntü başına hesaplanan ve daha sonra tüm test görüntülerinin ortalaması alınarak elde edilen değerler görülmektedir.

Çizelge 5.2. Rdpd_Test_Vs üzerinde test edilen hibrit derin öğrenme sistemlerine ait sonuçlar.

Model Tanımı	Kesinlik	Duyarlılık	F1 puanı
Sistem 1: ESA - TSA	0,7164	0,6021	0,6543
Sistem 2: OK - ESA	0,5263	0,4631	0,4927
Sistem 3: ESA - KNN	0,5942	0,4684	0,5239

Sonuçlar incelendiğinde, kesinlik değerlendirme ölçütünün duyarlılık sonuçlarından daha yüksek olduğu görülmektedir. Bu durum, bir görüntü için yorumlardan tahmin edilen kavramların % 70 civarında doğru olarak tahmin edildiğini göstermektedir. Test sonuçlarına ait grafiksel gösterim Şekil 5.8’de sunulmaktadır.



Şekil 5.8. Rdpd_Test_Vs üzerinde test edilen hibrit derin öğrenme sistemlerine ait grafiksel sonuçlar.

Sonuçlar F1 puanı açısından değerlendirildiğinde ise, en yüksek başarımın 0,6543 puan ile Sistem 1:ESA-TSA hibrit modelinden elde edildiği görülmektedir. Xception ön-eğitilmiş modelin kullanıldığı Sistem 3:ESA-KNN hibrit modeli ise 0,5239 F1 puanı ile ikinci sıradadır. Son olarak Sistem 3:OK-ESA hibrit modeli ile 0,4927 F1 puanı elde edilmiştir.

6. SONUÇLAR VE ÖNERİLER

Medikal görüntülerden kavram tespiti ve görüntü sınıflandırma, verimli ve sağlam medikal görüntü erişim sistemleri için iki önemli görevdir. Ayrıca, bu görevler bilgi keşfi, medikal rapor oluşturma, tıbbi soru yanıtlama ve klinik karar verme gibi alt görevlere yardımcı olur. Günlük çok sayıda görüntüyü inceleyen klinisyenlere yardımcı olmak için biyomedikal görüntüleri otomatik olarak yorumlamada derin öğrenme yöntemleri geliştirilmektedir. Bununla birlikte son zamanlarda sağlık konulu sosyal ağların giderek arttığı görülmektedir.

Sağlık konulu medikal sosyal ağ platformları, farklı sağlık hizmeti katılımcıları arasındaki etkileşimi sağlayan sanal alanlar oluşturur. Paylaşımın bir parçası olarak bu alanlar, üyelerin bir analiz veya yorumlama önerisi için farklı tıbbi vakaları açıklayan tıbbi görüntüler yüklemesine olanak tanır. Günlük olarak yüklenen bu büyük miktarda veri, özellikle radyoloji görüntüleri karşısında, görüntülerin arama işlevi sürecini geliştirmek ve bu durumla etkili bir şekilde başa çıkmak için yeni mekanizmaları devreye sokmak gerekmektedir. Bu sorunun üstesinden gelmek için, içerik tabanlı bir tıbbi görüntü alma şemasına dayalı görsel aramanın kurulması bir çözüm yolu olarak görülmektedir. Daha açık bir şekilde, bu tür bir mekanizma sosyal ağ üyelerine görsel olarak benzer depolanmış görüntüleri bulma konusunda yardımcı olacak ve onları motive edecektir.

Bu tez çalışmasında, bir sosyal ağ üzerinde paylaşılan radyolojik görüntülere atanması gereken medikal kavramları otomatik olarak seçerek, görüntülerin çok etiketli sınıflandırmasını gerçekleştirmek amaçlanmıştır. Tez çalışmasında, özellikle birden fazla derin öğrenme tekniği birleştirilerek hibrit sistemler oluşturulmuştur. Çünkü bu teknikler, etiketlenmiş imge içeren eğitim setlerinde kendiliğinden özellik çıkarma işlemi yapabilecek, makine öğrenmesinin aksine çok katmanlı sinir ağların bir arada kullanılmasına olanak sağlayan sistemlerdir. Bu sebeple, ImageCLEFmed 2019 Kavram Tespit görevi ele alınmış olup, ImageCLEFmed Caption 2019 veri seti üzerinde hibrit makine öğrenmesi yöntemleri uygulanmıştır. İlk hibrit sistemde, iki farklı denetimli öğrenme tekniğini olan ESA ve TSA beraber uygulanmıştır. İkinci hibrit sistemde, denetimsiz ve denetimli öğrenme tekniğinin birleştirildiği OK-ESA kombinasyonu

sunulmuştur. Üçüncü hibrit sistemde ise, denetimli öğrenme tekniği olan ESA'nın dört farklı modeli ile makine öğrenme sınıflandırıcısı olan KNN algoritması birlikte kullanılmıştır. Değerlendirme, ImageCLEFmed 2019 Kavram Tespit görevinde belirtildiği gibi, sistem tarafından tahmin edilen ve kesin doğruluk kavramları arasındaki F1 puanları açısından gerçekleştirilmiştir. F1 puanları, her görüntü için hesaplandıktan sonra tüm test görüntülerinin ortalaması alınarak elde edilir.

ESA'nın dört farklı modeli DenseNet-121, ResNet-101, Xception ve EfficientNet-B7 ile KNN algoritmasının birlikte kullanıldığı üçüncü hibrit sisteme ait sonuçlar incelendiğinde Xception modelinin en iyi performans gösterdiği görülmüştür. Tüm sistemler açısından bakıldığında ise en iyi sonuçların ESA-TSA mimarisinde elde edildiği görülmektedir. ImageCLEFmed 2019 Kavram Tespit görevi için yapılan çalışmalara ait sonuçlar arasında, ESA-TSA hibrit derin öğrenme modeli ile en iyi test sonucu elde etmemize rağmen, veri setindeki görüntülerde modalite, anatomi ve kontrast açısından çok büyük bir çeşitlilik olmasından, veri setinin çok sayıda medikal kavram içermesinden ve özellikle de bazı kavramların eğitim veri kümesinde yer almıyor olmasında dolayı daha yüksek başarımlar elde edilememiştir. Yapılan detaylı veri seti analizi ile veri setinde bulunan 5.528 farklı UMLS kavramından 5.216 tanesinin eğitim setinde yer aldığı, yani 312 kavramın herhangi bir eğitim görüntüsüne atanmadığı görülmüştür. Bununla birlikte, eğitim setindeki 1.530 kavram yalnızca bir görüntüye atanmıştır ki bu durum da, ilgili bu kavramların sınıflandırılmasını oldukça zorlaştırmaktadır. Bu amaçla, eğitim veri setinde çok fazla veri kaybına neden olmayacak şekilde ilk olarak eğitim setinde sadece bir kez oluşan tüm kavramları, daha sonra da üçten az frekansta oluşan kavramları filtreleyerek $V_{s,1}$ ve $V_{s,3}$ veri kümeleri oluşturulmuştur. Filtreleme işlemi yapılırken örneğin, bir kez oluşan tüm kavramlar seçilmiştir ve karşılık gelen görüntüleri alınmıştır. Daha sonra her bir görüntü üzerindeki ilgili kavramlar kontrol edilmiş, eğer ilgili tüm kavramların frekansları birer kez ise görüntü veri kümesinden çıkarılmıştır. Aksi durumda, ilgili görüntüyü tanımlayan diğer kavramlar da silineceğinden bu kontrol işlemi önem kazanmıştır. Son olarak, mevcut değerlendirme metriği olan F1 puanı model tarafından öngörülen kısmi doğru kavramlar hesaba katmadığından, model tarafından tahmin edilen kısmi doğru kavramların dikkate alınabilmesi için daha sağlam bir değerlendirme metriğine ihtiyaç duyulmuştur. Ancak sonuçların başka çalışmalarla karşılaştırılabilir ve objektif olarak değerlendirilebilir olması açısından F1 metriği tercih edilmiştir.

En yüksek başarımın elde edildiği ESA-TSA hibrit derin öğrenme yaklaşımı ile birlikte

önerilen diğer iki hibrit yaklaşım, ImageCLEFmed Caption 2019 veri setine benzer şekilde oluşturulmuş daha küçük çaplı bir veri seti üzerinde test edilmiştir. Bu veri seti (Rdpd_Test_Vs) Facebook sosyal ağı üzerinde Radiopaedia.org ve Radiography-Radiopaedia.org adları ile oluşturulmuş eğitim sayfalarından toplanmış radyolojik görüntüler ve bu görüntülere ait başlık bilgileri ile görüntüler için gelen yorumlardan oluşturulmuştur. Buradaki sonuçlar değerlendirildiğinde, yine en yüksek başarımlı ESA-TSA modeli ile elde edilmiş olup, tüm F1 değerleri, ImageCLEFmed Caption 2019 test veri setindeki F1 değerlerinden daha yüksek çıkmıştır. Bu da hazırlanan veri setindeki radyolojik görüntülere ait yorumlardan çıkarılan kavramların görüntüyü oldukça iyi şekilde tanımladığını göstermektedir. Çıkarılan bu kavramlar daha sonra sosyal ağ sitesi üzerinden aramaları kolaylaştırmak için kullanılabilir.

Medikal görüntüler ve yorumlar, özellikle hastalar ve doktorlar arasındaki etkileşimi amaçlayan temel alanları sunar. Uzmanların analizlerini ve incelemelerini ifade eden çok sayıda yorum nedeniyle, sosyal ağ sitesi aracılığıyla paylaşılan medikal görüntü içeriğini belirleme girişimi önemli bir görevdir. Bu nedenle, tez çalışmasında yorumlarda var olanlara genel bir bakış sağlamak için yorumlardan anahtar kavramlar çıkaran bir analiz yaklaşımı kullanılmıştır.

Radyolojik tanı, günümüzde radyologlar için çoğu zaman zorlu ve zaman alıcı olmakla birlikte, medikal sosyal ağlarda gerek eğitim gerekse bu işlemin makineler tarafından gerçek dünya ortamında konuşlandırılması için gereken performanstan hala uzak olmakla birlikte, yeni yöntem ve çalışmalara açık bir alandır. Derin öğrenme inanılmaz bir hesaplama gücüne sahip olan ancak aynı zamanda iyi sonuçlar vermek için çok fazla doğru veri ve güçlü donanım gerektiren sinir ağlarını kullandığı için, gelişen teknoloji ve donanım kaynakları da bu sistemlerde önemli rol oynayacaktır.

7. KAYNAKLAR

- [1] N. Jokar, A. R. Honarvar, K. Esfandiari, ve S. Aghamirzadeh, “The review of social networks analysis tools”, *Bulletin de la Société Royale des Sciences de Liège*, c. 85, ss. 329–339, 2016.
- [2] I. H. Sarker, “Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions”, *SN Computer Science*, c. 2, sayı 6, ss. 1–20, 2021.
- [3] F. Altaf, S. M. S. Islam, N. Akhtar, ve N. K. Janjua, “Going deep in medical image analysis: Concepts, methods, challenges, and future directions”, *IEEE Access*, c. 7, ss. 99540–99572, 2019.
- [4] A. Mondai, E. Cambria, A. Feraco, Di. Das, ve S. Bandyopadhyay, “Auto-categorization of medical concepts and contexts”, *2017 IEEE Symposium Series on Computational Intelligence, Proceedings*, c. 2018, ss. 1–7, 2018.
- [5] O. Bodenreider, “The Unified Medical Language System (UMLS): integrating biomedical terminology”, *Nucleic Acids Research*, c. 32, sayı D267, 2004.
- [6] B. Ionescu *vd.*, “ImageCLEF 2019: Multimedia Retrieval in Medicine, Lifelogging, Security and Nature”, *Lecture Notes in Computer Science*, c. 11696, ss. 358–386, 2019.
- [7] O. Pelka, C. M. Friedrich, A. G. Seco De Herrera, ve H. Müller, “Overview of the ImageclefMed 2019 concept detection task”, *CEUR Workshop Proceedings*, c. 2380, 2019.
- [8] D. Maynard, I. Roberts, M. A. Greenwood, D. Rout, ve K. Bontcheva, “A framework for real-time semantic social media analysis”, *Web Semantics: Science, Services and Agents on the World Wide Web*, c. 44, ss. 75–88, 2017.
- [9] “Biggest social media platforms 2022 | Statista”.
<https://www.statista.com/statistics/272014/global-social-networks-ranked-by-number-of-users/> (erişim 03 Aralık 2022).
- [10] “Twitter: number of users worldwide 2024 | Statista”.
<https://www.statista.com/statistics/303681/twitter-users-worldwide/> (erişim 03 Aralık 2022).
- [11] “Weibo Corporation: DAUs 2022 | Statista”.
<https://www.statista.com/statistics/1058070/china-sina-weibo-dau/> (erişim 03 Aralık 2022).
- [12] The Statistics Portal, “Instagram - Statistics; Facts | Statista”, *Statista*, 2019.
<https://www.statista.com/topics/1882/instagram/> (erişim 07 Mart 2019).
- [13] “Turkey: number of Instagram users 2022 | Statista”.
<https://www.statista.com/statistics/1024714/instagram-users-turkey/> (erişim 03 Aralık 2022).
- [14] The Statistics Portal, “Social network penetration worldwide 2021 | Statistic”,

- Statista*, 2019. <https://www.statista.com/statistics/260811/social-network-penetration-worldwide/> (erişim 07 Mart 2019).
- [15] Najeeb Elahi; Randi Karlsen; Waqas Younas, “Semantic image annotation with social context”, *International Conference for nternet Technology and Secured Transactions (ICITST)*, 2010.
- [16] “Clinician’s Network & Healthcare Directory for Doctors, NPs, PAs & RNs”. <https://www.doximity.com/> (erişim 01 Ocak 2023).
- [17] “Sermo: Social Network Platform for Physicians”. <https://www.sermo.com/> (erişim 01 Ocak 2023).
- [18] “The Student Doctor Network - A Nonprofit Organization”. <https://www.studentdoctor.net/> (erişim 01 Ocak 2023).
- [19] “Live better, together! | PatientsLikeMe”. <https://www.patientslikeme.com/> (erişim 01 Ocak 2023).
- [20] “Medical Education with Real Medical Cases | Figure 1”. <https://www.figure1.com/> (erişim 01 Ocak 2023).
- [21] “Home - MomMD”. <https://mommd.com/> (erişim 01 Ocak 2023).
- [22] “Radiopaedia.org | Facebook”. <https://www.facebook.com/Radiopaedia.org> (erişim 01 Ocak 2023).
- [23] “Radiography - Radiopaedia.org | Facebook”. <https://www.facebook.com/RadRadiopaedia> (erişim 01 Ocak 2023).
- [24] “LearningRadiology | Facebook”. <https://www.facebook.com/profile.php?id=100064418484956> (erişim 01 Ocak 2023).
- [25] “The Radiologist | Facebook”. <https://www.facebook.com/profile.php?id=100027318501038&sk=photos> (erişim 01 Ocak 2023).
- [26] M. G. Ayadi, R. Bouslimi, ve J. Akaichi, “A Model for Multilingual Terminology Extraction via a Medical Social Network”, *Procedia Computer Science*, c. 112, ss. 21–30, 2017.
- [27] A. M. AL-Abad vd., “A Semantic Social Network Service for Educating Saudi Breast Cancer Patients”, *2009 Ninth IEEE International Conference on Advanced Learning Technologies*, 2009, ss. 81–82.
- [28] W. U. Wickramaarachchi ve R. K. A. R. Kariapper, “An approach to get overall emotion from comment text towards a certain image uploaded to social network using Latent Semantic Analysis”, *2017 2nd International Conference on Image, Vision and Computing (ICIVC)*, Haz. 2017, ss. 788–792.
- [29] Y. Wang, S. Wang, J. Tang, H. Liu, ve B. Li, “Unsupervised sentiment analysis for social media images”. *International Joint Conferences on Artificial Intelligence*, 2015.
- [30] M. Krishnamurthy, K. Mahmood, ve P. Marcinek, “A hybrid statistical and semantic model for identification of mental health and behavioral disorders using social network analysis”, *2016 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*,. 2016, ss. 1019–1026.

- [31] M. Merler, L. Cao, ve J. R. Smith, “You are what you tweet...pic! gender prediction based on semantic analysis of social media images”, içinde *Proceedings - IEEE International Conference on Multimedia and Expo*, Haz. 2015, c. 2015-Augus, ss. 1–6.
- [32] M. G. Ayadi, R. Bouslimi, ve J. Akaichi, “A medical image retrieval scheme through a medical social network”, *Network Modeling Analysis in Health Informatics and Bioinformatics*, c. 5, sayı 1, s. 23, 2016.
- [33] M. S. Demirci ve S. Sagiroglu, “Sosyal Ağ Verilerinin Kullanım Alanları Üzerine Kapsamlı Bir İnceleme”, *Gazi University Journal of Science*, c. 5, sayı 2, ss. 1–21, 2017.,
- [34] I. H. Sarker, M. H. Furhad, ve R. Nowrozy, “AI-Driven Cybersecurity: An Overview, Security Intelligence Modeling and Research Directions”, *SN Computer Science*, c. 2, sayı 3, ss. 1–18, 2021.
- [35] I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions”, *SN Computer Science*, c. 2, sayı 3, ss. 1–21, 2021.
- [36] N. Akhtar ve A. Mian, “Threat of Adversarial Attacks on Deep Learning in Computer Vision: A Survey”, *IEEE Access*, c. 6, ss. 14410–14430, Şub. 2018.
- [37] I. Sutskever, O. Vinyals, ve Q. V. Le, “Sequence to Sequence Learning with Neural Networks”, *Advances in Neural Information Processing Systems*, c. 4, sayı January, ss. 3104–3112, 2014.
- [38] H. Y. Xiong vd., “The human splicing code reveals new insights into the genetic determinants of disease”, *Science*, c. 347, sayı 6218, 2015.
- [39] T. Ciodaro, D. Deva, J. M. De Seixas, ve D. Damazio, “Online particle detection with Neural Networks based on topological calorimetry information”, *Journal of Physics: Conference Series*, c. 368, sayı 1, 2012.
- [40] J. Ma, R. P. Sheridan, A. Liaw, G. E. Dahl, ve V. Svetnik, “Deep neural nets as a method for quantitative structure-activity relationships”, *Journal of Chemical Information and Modeling*, c. 55, sayı 2, ss. 263–274, 2015.
- [41] M. Helmstaedter, K. L. Briggman, S. C. Turaga, V. Jain, H. S. Seung, ve W. Denk, “Connectomic reconstruction of the inner plexiform layer in the mouse retina”, *Nature* 2013 500:7461, c. 500, sayı 7461, ss. 168–174, 2013.
- [42] I. Goodfellow, Y. Bengio, ve A. Courville, *Deep Learning*. London, England: The MIT Press, 2016.
- [43] H. C. Becker, W. J. Nettleton, J. W. Sweeney, P. H. Meyers, ve C. M. Nice, “Digital Computer Determination of a Medical Diagnostic Index Directly from Chest X-Ray Images”, *IEEE Transactions on Biomedical Engineering*, c. BME-11, sayı 3, ss. 67–72, 1964.
- [44] G. S. Lodwick, T. E. Keats, ve J. P. Dorst, “The Coding of Roentgen Images for Computer Analysis as Applied to Lung Cancer¹”, *Radiology*, c. 81, ss. 185–200, 1963.
- [45] Y. Wu, M. L. Giger, K. Doi, C. J. Vyborny, R. A. Schmidt, ve C. E. Metz, “Artificial neural networks in mammography: application to decision making in the diagnosis of breast cancer”, *Radiology*, c. 187, sayı 1, ss. 81–87, 1993.
- [46] S. C. B. Lo, S. L. A. Lou, M. V Chien, ve S. K. Mun, “Artificial Convolution

- Neural Network Techniques and Applications for Lung Nodule Detection”, *IEEE Transactions on Medical Imaging*, c. 14, sayı 4, ss. 711–718, 1995.
- [47] W. Zhang, K. Doi, M. L. Giger, R. M. Nishikawa, ve R. A. Schmidt, “An improved shift-invariant artificial neural network for computerized detection of clustered microcalcifications in digital mammograms”, *Medical Physics*, c. 23, sayı 4, ss. 595–601, Nis. 1996.
- [48] K. He, X. Zhang, S. Ren, ve J. Sun, “Deep Residual Learning for Image Recognition”, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, c. 2016-December, ss. 770–778, 2015.
- [49] A. Krizhevsky, I. Sutskever, ve G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, Erişim: 02 Aralık 2022. [Çevrimiçi]. Available at: <http://code.google.com/p/cuda-convnet/>
- [50] J. Ker, L. Wang, J. Rao, ve T. Lim, “Deep Learning Applications in Medical Image Analysis”, *IEEE Access*, c. 6, ss. 9375–9379, 2017.
- [51] R. J. Schalkoff, *Artificial neural networks*, c. 1. New York, USA: McGraw-Hill, New York, 1997.
- [52] A. Khotanzad ve C. Chung, “Application of multi-layer perceptron neural networks to vision problems”, *Neural Computing & Applications 1998*, c. 7, sayı 3, ss. 249–259, 1998.
- [53] T. Bikku, “Multi-layered deep learning perceptron approach for health risk prediction”, *Journal of Big Data*, c. 7, sayı 1, ss. 1–14, 2020.
- [54] J. Han, J. Pei, ve H. Tong, *Data Mining: Concepts and Techniques*, Morgan Kaufmann., c. 4. 2022.
- [55] I. H. Sarker, “Deep Cybersecurity: A Comprehensive Overview from Neural Network and Deep Learning Perspective”, *SN Computer Science*, c. 2, sayı 3, ss. 1–16, 2021.
- [56] Y. LeCun, L. Bottou, Y. Bengio, ve P. Haffner, “Gradient-based learning applied to document recognition”, *Proceedings of the IEEE*, c. 86, sayı 11, ss. 2278–2323, 1998.
- [57] A. Géron, *Hands-on machine learning with Scikit-Learn, Keras and TensorFlow: concepts, tools, and techniques to build intelligent systems*, O’Reilly Media, Inc. 2019.
- [58] H. Qassim, A. Verma, ve D. Feinzimer, “Compressed residual-VGG16 CNN model for big data places image recognition”, *2018 IEEE 8th Annual Computing and Communication Workshop and Conference, CCWC 2018*, c. 2018-January, ss. 169–175, 2018.
- [59] A. Bagaskara ve M. Suryanegara, “Evaluation of VGG-16 and VGG-19 Deep Learning Architecture for Classifying Dementia People”, *Proceedings - 2021 4th International Conference on Computer and Informatics Engineering: IT-Based Digital Industrial Innovation for the Welfare of Society, IC2IE 2021*, ss. 1–4, 2021.
- [60] F. Chollet, “Xception: Deep Learning with Depthwise Separable Convolutions”, *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, c. 2017-January, ss. 1800–1807, 2016.
- [61] C. Szegedy vd., “Going Deeper with Convolutions”, *Proceedings of the IEEE*

Computer Society Conference on Computer Vision and Pattern Recognition, c. 07-12-June-2015, ss. 1–9, 2014.

- [62] D. Mandic ve J. Chambers, *Recurrent neural networks for prediction: learning algorithms, architectures and stability*. Wiley, 2001.
- [63] A. Sherstinsky, “Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network”, *Physica D: Nonlinear Phenomena*, c. 404, s. 132306, Mar. 2020.
- [64] S. Hochreiter ve J. Schmidhuber, “Long Short-Term Memory”, *Neural Computation*, c. 9, sayı 8, ss. 1735–1780, 1997.
- [65] S. Siami-Namini, N. Tavakoli, ve A. S. Namin, “The Performance of LSTM and BiLSTM in Forecasting Time Series”, *Proceedings - 2019 IEEE International Conference on Big Data, Big Data 2019*, ss. 3285–3292, Ara. 2019.
- [66] A. Aziz Sharfuddin, M. Nafis Tihami, ve M. Saiful Islam, “A Deep Recurrent Neural Network with BiLSTM model for Sentiment Classification”, *2018 International Conference on Bangla Speech and Language Processing, ICBSLP 2018*, 2018.
- [67] K. Cho vd., “Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation”, *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, ss. 1724–1734, Haz. 2014, doi: 10.48550/arxiv.1406.1078.
- [68] J. Chung, C. Gulcehre, K. Cho, ve Y. Bengio, “Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling”, içinde *NIPS 2014 Workshop on Deep Learning*, 2014.
- [69] N. Gruber ve A. Jockisch, “Are GRU Cells More Specific and LSTM Cells More Sensitive in Motive Classification of Text?”, *Frontiers in Artificial Intelligence*, c. 3, s. 40, Haz. 2020.
- [70] L. Deng, “A tutorial survey of architectures, algorithms, and applications for deep learning”, *APSIPA Transactions on Signal and Information Processing*, c. 3, s. e2, Ara. 2014.
- [71] A. Da’u, N. Salim, A. Da’, A. Da’u, ve N. Salim, “Recommendation system based on deep learning methods: a systematic review and new directions”, *Artificial Intelligence Review 2019 53:4*, c. 53, sayı 4, ss. 2709–2748, 2019.
- [72] I. J. Goodfellow vd., “Generative Adversarial Nets”, içinde *Advances in Neural Information Processing Systems 27*, 2014, c. 27.
- [73] G. Çelik ve Talu Muhammed Fatih, “Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi”, *Araştırma Makalesi BAUN Fen Bil. Enst. Dergisi*, c. 22, sayı 1, ss. 181–192, 2020.
- [74] A. Aggarwal, M. Mittal, ve G. Battineni, “Generative adversarial network: An overview of theory and applications”, *International Journal of Information Management Data Insights*, c. 1, sayı 1, s. 100004, 2021.
- [75] B. Li, V. François-Lavet, T. Doan, ve J. Pineau, “Domain Adversarial Reinforcement Learning”, *arXiv:2102.07097v1*, Şub. 2021, Erişim: 05 Aralık 2022. [Çevrimiçi]. Available at: <http://arxiv.org/abs/2102.07097>
- [76] J. Donahue, P. Krähenbühl, ve T. Darrell, “Adversarial Feature Learning”,

International Conference on Learning Representations, 2017.

- [77] D. H. Ackley, G. E. Hinton, ve T. J. Sejnowski, “A Learning Algorithm for Boltzmann Machines”, *Cognitive Science*, c. 9, ss. 147–169, 1985.
- [78] B. M. Marlin, K. Swersky, B. Chen, ve N. De Freitas, “Inductive Principles for Restricted Boltzmann Machine Learning”, *Proceedings of the 13th International Conference on Artificial Intelligence and Statistics (AISTATS)*, 2010, ss. 509–516.
- [79] G. E. Hinton, S. Osindero, ve Y. W. Teh, “A fast learning algorithm for deep belief nets”, *Neural Computation*, c. 18, sayı 7, ss. 1527–1554, 2006.
- [80] A. Decelle, C. Furtlehner, A. Decelle, ve C. Furtlehner, “Restricted Boltzmann machine: Recent advances and mean-field theory”, *Chinese Physics B*, c. 30, sayı 4, 2021.
- [81] T. Kohonen, “The Self-Organizing Map”, *Proceedings of the IEEE*, c. 78, sayı 9, ss. 1464–1480, 1990.
- [82] J. Vesanto ve E. Alhoniemi, “Clustering of the self-organizing map”, *IEEE Transactions on Neural Networks*, c. 11, sayı 3, ss. 586–600, 2000.
- [83] D. Miljkovic, “Brief review of self-organizing maps”, *40th International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2017*, 2017, ss. 1061–1066.
- [84] T. Kohonen, “Essentials of the self-organizing map”, *Neural Networks*, c. 37, ss. 52–65, 2013.
- [85] X. Qu vd., “A Survey on the Development of Self-Organizing Maps for Unsupervised Intrusion Detection”, *Mobile Networks and Applications*, c. 26, sayı 2, ss. 808–829, 2021.
- [86] A. Filippi, I. Dobрева, A. G., ve J. R., “Self-Organizing Map-based Applications in Remote Sensing”, *Self-Organizing Maps*, 2010, doi: 10.5772/9163.
- [87] D. Pratella, S. A. E. M. Saadi, S. Bannwarth, V. Paquis-fluckinger, ve S. Bottini, “A Survey of Autoencoder Algorithms to Pave the Diagnosis of Rare Diseases”, *International Journal of Molecular Sciences*, c. 22, sayı 19, 2021.
- [88] W. Liu, Z. Wang, X. Liu, N. Zeng, Y. Liu, ve F. E. Alsaadi, “A survey of deep neural network architectures and their applications”, *Neurocomputing*, c. 234, ss. 11–26, Nis. 2017.
- [89] G. Zhang, Y. Liu, ve X. Jin, “A survey of autoencoder-based recommender systems”, *Frontiers of Computer Science*, c. 14, sayı 2, ss. 430–450, Ağu. 2019.
- [90] J. Zhai, S. Zhang, J. Chen, ve Q. He, “Autoencoder and Its Various Variants”, *Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018*, ss. 415–419, 2019.
- [91] G. E. Hinton, “Deep belief networks”, *Scholarpedia*, c. 4, sayı 5, s. 5947, 2009.
- [92] K. Weiss, T. M. Khoshgoftaar, ve D. D. Wang, “A survey of transfer learning”, *Journal of Big Data*, c. 3, sayı 1, ss. 1–40, 2016.
- [93] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, ve C. Liu, “A Survey on Deep Transfer Learning”, içinde *The 27th International Conference on Artificial Neural Networks (ICANN)*, Ağu. 2018, c. 11141 LNCS, ss. 270–279.

- [94] S. J. Pan ve Q. Yang, “A survey on transfer learning”, *IEEE Transactions on Knowledge and Data Engineering*, c. 22, sayı 10, ss. 1345–1359, 2009.
- [95] B. Maschler ve M. Weyrich, “Deep Transfer Learning for Industrial Automation: A Review and Discussion of New Techniques for Data-Driven Machine Learning”, *IEEE Industrial Electronics Magazine*, c. 15, sayı 2, ss. 65–75, 2021.
- [96] S. S. Mousavi, M. Schukat, ve E. Howley, “Deep Reinforcement Learning: An Overview”, *Lecture Notes in Networks and Systems*, c. 16, ss. 426–440, 2018.
- [97] M. Toğaçar ve B. Ergen, “Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması”, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, c. 31, sayı 1, ss. 109–121, 2019.
- [98] P. Clough, M. Sanderson, ve N. Reid, “The Eurovision St Andrews collection of photographs”, Association for Computing Machinery (ACM), UK, 2003. doi: 10.1145/1147197.1147199.
- [99] “Keras: the Python deep learning API”. <https://keras.io/> (erişim 17 Ocak 2023).
- [100] O. Pelka, S. Koitka, J. Rückert, F. Nensa, ve C. M. Friedrich, “Radiology objects in COntext (ROCO): A multimodal image dataset”, *Lecture Notes in Computer Science (LNCS)*, c. 11043, ss. 180–189, 2018.
- [101] V. Kougia, J. Pavlopoulos, ve I. Androutsopoulos, “AUEB NLP Group at ImageCLEFmed Caption 2019”, içinde *In: CLEF2019 Working Notes. CEUR Workshop Proceed-ings, (CEUR-WS.org)*, 2019.
- [102] National Library of Medicine, “UMLS Metathesaurus Browser”. <https://uts.nlm.nih.gov/uts/umls/home> (erişim 15 Aralık 2022).
- [103] J. Xu vd., “Concept detection based on multi-label classification and image captioning approach-DAMO at ImageCLEF 2019”, *In: CLEF2019 Working Notes. CEUR Workshop Proceed-ings, (CEUR-WS.org)*, 2019.
- [104] B. Jing, P. Xie, ve E. P. Xing, “On the Automatic Generation of Medical Imaging Reports”, *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL)*, c. 1, ss. 2577–2586, 2018.
- [105] “TensorFlow v2.11.0,Keras,VGG19”. https://www.tensorflow.org/api_docs/python/tf/keras/applications/vgg19/VGG19 (erişim 20 Aralık 2022).
- [106] D. P. Kingma ve J. L. Ba, “Adam: A Method for Stochastic Optimization”, *International Conference on Learning Representations (ICLR)*, Ara. 2015. doi: 10.48550/arxiv.1412.6980.
- [107] M. Abdallah, N. An Le Khac, H. Jahromi, ve A. Delia Jurcut, “A Hybrid CNN-LSTM Based Approach for Anomaly Detection Systems in SDNs”, *The 16th International Conference on Availability, Reliability and Security*, 2021. doi: 10.1145/3465481.3469190.
- [108] H. Almutairi, G. M. Hassan, ve A. Datta, “Detection of obstructive sleep apnoea by ECG signals using deep learning architectures”, içinde *28th European Signal Processing Conference (EUSIPCO)*, 2021, c. 2021-January, ss. 1382–1386.
- [109] S. L. Oh, E. Y. K. Ng, R. S. Tan, ve U. R. Acharya, “Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats”, *Computers in Biology and Medicine*, c. 102, ss. 278–287, 2018.

- [110] M. Li, T. Zhang, Y. Chen, ve A. J. Smola, “Efficient mini-batch training for stochastic optimization”, *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, c. New York, USA, ss. 661–670, 2014.
- [111] G. Huang, Z. Liu, L. Van Der Maaten, ve K. Q. Weinberger, “Densely Connected Convolutional Networks”, *EEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, ss. 2261–2269.
- [112] A. Aljuaid ve M. Anwar, “Survey of Supervised Learning for Medical Image Processing”, *SN Computer Science*, c. 3, sayı 4, ss. 1–22, 2022.
- [113] S. Roopashree ve J. Anitha, “DeepHerb: A Vision Based System for Medicinal Plants Using Xception Features”, *IEEE Access*, c. 9, ss. 135927–135941, 2021.
- [114] M. Tan ve Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks”, *36th International Conference on Machine Learning (ICML)*, ss. 10691–10700, 2019.
- [115] Ü. Atila, M. Uçar, K. Akyol, ve E. Uçar, “Plant leaf disease classification using EfficientNet deep learning model”, *Ecological Informatics*, c. 61, sayı 101182, 2021.
- [116] T. B. T. Nguyen, M. V. Ngo, ve V. P. Nguyen, “Histopathological Imaging Classification of Breast Tissue for Cancer Diagnosis Support Using Deep Learning Models”, *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, c. 444, ss. 152–164, 2022.
- [117] S. Godbole ve S. Sarawagi, “Discriminative methods for multi-labeled classification”, *Lecture Notes in Computer Science*, c. 3056, ss. 22–30, 2004.
- [118] D. Miranda, V. Thenkanidiyoor, ve D. A. Dinesh, “Review on approaches to concept detection in medical images”, *Biocybernetics and Biomedical Engineering*, c. 42, sayı 2, ss. 453–462, 2022.
- [119] “ImageCLEFmed Caption | ImageCLEF / LifeCLEF - Multimedia Retrieval in CLEF”. <https://www.imageclef.org/2019/medical/caption> (erişim 31 Aralık 2022).
- [120] V. Chhatbar, M. Gondhalekar, S. Pimple, ve R. Pawar, “Machine Interpretation of Medical Images Using Deep Learning”, *2nd Global Conference for Advancement in Technology (GCAT)*, Eki. 2021.
- [121] M. F. Porter, “Lovins Revisited”, *Charting a New Course: Natural Language Processing and Information Retrieval*, ss. 39–68, 2005.
- [122] “Stemming algorithms for various European languages”. <http://snowball.tartarus.org/texts/stemmersoverview.html> (erişim 06 Şubat 2023).

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Sümeyye BAYRAKDAR

Yabancı Dili : İngilizce

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Doktora	Elektrik-Elektronik ve Bilgisayar Mühendisliği	Düzce Üniversitesi	2023
Y. Lisans	Bilgisayar Mühendisliği	Düzce Üniversitesi	2016
Lisans	Bilgisayar Mühendisliği	Düzce Üniversitesi	2016
Lisans	Bilgisayar Öğretmenliği	Kocaeli Üniversitesi	2013
Lise		Biga Atatürk Anadolu Lisesi	2009

YAYINLAR

- Sumeyye Bayrakdar, Ibrahim Yucedag, Exploiting 5G Enabled Cognitive Radio Technology for Semantic Analysis in Social Networks, (Submitted).
- Sumeyye Bayrakdar, Ibrahim Yucedag, Mehmet Simsek, Ibrahim Alper Dogru, Semantic analysis on social networks: A survey, *International Journal of Communication Systems*, 33 (11), e4424, 2020.
- Sümeyye Bayrakdar, İbrahim Yücedağ, Sosyal Ağlarda Yorum İçerik Tahmini için Bulanık Mantık tabanlı Metinsel Anlam Çıkarım Yaklaşımının Analizi, *Politeknik Dergisi*, 23 (3), 707-711, 2020.
- Sümeyye Bayrakdar, İbrahim Yücedağ, Sosyal Ağlarda Metin ve Görüntü tabanlı Anlamsal Çıkarım Yöntemlerinin İncelenmesi, *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 28 (3), 283-288, 2020.

5. Koksak Gundogdu, Sumeyye Bayrakdar, Ibrahim Yucedag, Developing and modeling of voice control system for prosthetic robot arm in medical systems, *Journal of King Saud University-Computer and Information Sciences*, 30 (2), 198-205, 2018.
6. Gülçin Ersöz, İbrahim Yücedağ, Sümeyye Bayrakdar, Şemsettin Altındal, Ahmet Gümüş, Investigation of photo-induced effect on electrical properties of Au/PPy/n-Si (MPS) type schottky barrier diodes, *Journal of Materials Science: Materials in Electronics*, 28 (9), 6413-6420, 2017.
7. Sümeyye Bayrakdar, Devrim Akgün, İbrahim Yücedağ, Video dosyaları üzerinde yüz ifade analizi için hızlandırılmış bir yaklaşım, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 23 (5), 602-613, 2017.
8. Sümeyye Bayrakdar, Hamit Saruhan, Ibrahim Yucedag, Optimization of Production Plants with Pollution Control in Water Resources: A Case Study, *Sigma Journal of Engineering and Natural Sciences*, 8 (2), 99-105, 2017.
9. Sümeyye Bayrakdar, Mehmet Şimşek, İbrahim Yücedağ, Muhammed Enes Bayrakdar, Direksiyon Eğitimi Sınavı için Nesnelerin İnterneti Tabanlı Akıllı Sürüş Değerlendirme Sistemi, *International Engineering Research Symposium*, 315-321, 11-13 September 2017, Duzce, Turkey.
10. Sümeyye Bayrakdar, Devrim Akgün, İbrahim Yücedağ, Yüz İfadelerinin Otomatik Analizi üzerine Bir Literatür Çalışması, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 20 (2), 383-398, 2016.
11. Sumeyye Bayrakdar, Ibrahim Yucedag, Devrim Akgun, A multicore accelerated implementation for statistical analysis of facial expressions in video, *IEEE XIth International Scientific and Technical Conference Computer Sciences and Information Technologies (CSIT 2016)*, 62-65, 06-10 September 2016, Lviv, Ukraine.
12. Sümeyye Bayrakdar, Hamit Saruhan, İbrahim Yücedağ, Su Kaynaklarında Kirlilik Kontrolü ile Üretim Tesislerinin Maksimum Kar Optimizasyonu Örnek Bir Problemin İncelenmesi, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu (ASYU 2016)*, 149-153, 29 Eylül-1 Ekim 2016, Düzce, Türkiye.

13. Derya Başol, Muhammed Mustafa Ertay, Sümeyye Bayrakdar, İbrahim Yücedağ, Güneş Pili ve Modelleri Web Arayüzü, *1st International Mediterranean Science and Engineering Congress (IMSEC 2016)*, 3006-3010, 26-28 October 2016, Adana, Turkey.
14. Ahmet Gümüş, Gülçin Ersöz, İbrahim Yücedağ, Sümeyye Bayrakdar, Şemsettin Altındal, Comparative Study of the Temperature-Dependent Dielectric Properties of Au/PPy/n-Si (MPS)-Type Schottky Barrier Diodes, *Journal of the Korean Physical Society*, 67 (5), 889-895, 2015.
15. Muhammed Enes Bayrakdar, Sümeyye Bayrakdar, İbrahim Yücedağ, Ali Çalhan, Bilişsel Radyo Kullanıcıları için Bulanık Mantık Yardımıyla Kanal Kullanım Olasılığı Hesabında Farklı bir Yaklaşım, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 3 (1), 88-99, 2015.
16. Sümeyye Bayrakdar, Bekir Çomak, Derya Başol, İbrahim Yücedağ, Determination of Type and Quality of Hazelnut using Image Processing Techniques, *IEEE 23th Signal Processing and Communications Applications Conference (SIU 2015)*, 616-619, 16-19 May 2015, Malatya, Turkey.
17. Muhammed Enes Bayrakdar, Sümeyye Bayrakdar, A Cooperative Communication Approach for Voluntary Secondary Users in Cognitive Radio Networks, *IEEE 23th Signal Processing and Communications Applications Conference (SIU 2015)*, 604-607, 16-19 May 2015, Malatya, Turkey.