

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI
BİYOMEDİKAL MÜHENDİSLİĞİ DOKTORA PROGRAMI**

**DERİN ÖĞRENME YÖNTEMLERİ İLE AKCİĞER GRAFİLERİNDE
PATOLOJİ SINIFLANDIRILMASI**

HAZIRLAYAN

BURCU OLTU

DOKTORA TEZİ

ANKARA-2025

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI
BİYOMEDİKAL MÜHENDİSLİĞİ DOKTORA PROGRAMI**

**DERİN ÖĞRENME YÖNTEMLERİ İLE AKCİĞER GRAFİLERİNDE
PATOLOJİ SINIFLANDIRILMASI**

HAZIRLAYAN

BURCU OLTU

DOKTORA TEZİ

TEZ DANIŞMANI

PROF. DR. BERNA DENGİZ

ANKARA-2025

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Biyomedikal Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği Doktora Programı çerçevesinde Burcu Oltu tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 18 / 06 / 2025

Tez Adı: Derin Öğrenme Yöntemleri ile Akciğer Grafilerinde Patoloji Sınıflandırılması.

Tez Jüri Üyeleri

İmza

Prof. Dr. Berna Dengiz	Başkent Üniversitesi	
Prof. Dr. Seniha Esen Yüksel Erdem	Hacettepe Üniversitesi	
Prof. Dr. Fikret Arı	Ankara Üniversitesi	
Prof. Dr. Hamit Erdem	Başkent Üniversitesi	
Doç. Dr. Selda Güney	Başkent Üniversitesi	

ONAY

Prof. Dr. Dilek Çökeliler Serdaroğlu

Fen Bilimleri Enstitüsü Müdürü

Tarih : ... / ... /

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 14 / 07 / 2025

Öğrencinin Adı, Soyadı: Burcu Oltu

Öğrencinin Numarası: 21920302

Anabilim Dalı: Biyomedikal Mühendisliği

Programı: Doktora

Danışmanın Unvanı/Adı, Soyadı: Prof. Dr. Berna Dengiz

Tez Başlığı: Derin Öğrenme Yöntemleri ile Akciğer Grafilerinde Patoloji Sınıflandırılması

Yukarıda başlığı belirtilen Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 157 sayfalık kısmına ilişkin, 14 / 07 / 2025 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %1'dir. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: 14/07/2025

Öğrenci Danışmanı:

Prof. Dr. Berna Dengiz

TEŞEKKÜR

Tez sürecim boyunca benden desteğini esirgemeyen, her şeyi yapacağıma inanmamı sağlayan, bana güçlü ve kendine güvenen bir kadın mühendis olmayı öğreten değerli tez danışmanım Prof. Dr. Berna Dengiz’e en derin saygı ve şükranlarımı sunarım.

Doktora sürecim boyunca her zaman yanımda olduğunu hissettiren, ne olursa olsun çaresizliğe kapılmamamı sağlayan, hem bilgi birikimi hem de desteğiyle her zaman yanımda olan Doç. Dr. Selda Güney’e; bana her zaman yeni bakış açıları kazandıran, daha fazla araştırmam ve öğrenmem için beni motive eden Prof. Dr. Seniha Esen Yüksel Erdem’e; doktora sürecim boyunca beni hep destekleyen, önerileri ve yönlendirmeleriyle beni araştırmaya ve üretmeye teşvik eden Prof. Dr. Hamit Erdem’e teze olan katkıları ve destekleri için teşekkür ederim.

Akademik hayata adım atmamda yol gösterici olan, bana her zaman güvenen ve desteğini hiç esirgemeyen Prof. Dr. Faruk Elaldı’ya şükranlarımı sunarım.

Bilgi ve tecrübeleri ile bana her zaman ışık tuttuğu, bana olan inancını hiç kaybetmediği ve beni her zaman desteklediği için Doç. Dr. Aykut Erdamar’a teşekkürlerimi sunarım.

Akademik hayatımın şekillenmesinde çok büyük rolü olan Dr. Öğr. Üyesi Orhan Erdem Haberal’a bana hep güvendiği ve beni her zaman desteklediği için teşekkürlerimi sunarım.

Tez kapsamında verilerin toplanması için bana yardımcı olan tüm Başkent Üniversitesi Hastanesi Personeli’ne ve bu süreçte desteğini esirgemeyen Prof. Dr. Muhteşem Ağıldere’ye en içten teşekkürlerimi sunarım.

Tez sürecimde hep yanımda oldukları ve bu sürecin sorunsuz bir şekilde geçmesine yardımcı oldukları için değerli çalışma arkadaşlarıma ve Fatma Nur Turaman’a en içten sevgi ve teşekkürlerimi sunarım.

Akademik hayatımın en büyük bölümü olan B-301 numaralı odamızın kıdemli üyeleri Dr. Tuğçe Kantar Uğur’a ve Dr. Öğr. Üyesi Tansel Uyar’a lisans hayatımdan bu yana hem bilgi birikimleriyle hem de kendi tecrübeleriyle yol gösterici oldukları ve desteklerini her zaman hissettirdikleri için teşekkür ederim.

Lisans hayatımdan beri hep yan yana olduğum değerli yol arkadaşım Dr. B. Kübra Karaca Aydemir’e attığım her adımda yanımda olduğu ve desteğini hiç eksik etmediği için en içten şükranlarımı sunarım.

Lise yıllarımdan bugüne kadar her zaman yanımda olan, her kararına koşulsuz destek veren, bana benden daha çok inanan çok değerli dostlarım Berra Zeynep Özdemir’e, Bengisu Eğilmez Erdener’e ve Çağrı Erdener’e her anımda yanımda oldukları için teşekkür ederim. Üniversite yıllarımdan bu yana ne olursa olsun yüzümü güldürmeyi başaran, desteğini ve sevgisini hep hissettiren biricik dostum Irmak Karaark’a bana benden çok güvendiği ve hep yanımda olduğu için teşekkürlerimi sunarım.

Her başarıyı kendi başarısı gibi sahiplenen ve benimle hep gurur duyan dostlarım Utku Ünalın’a, Seda Mısırlıoğlu’na ve Aykut Özturan’a, yanımda oldukları ve bana inandıkları için teşekkür ederim.

Bu süreçte benimle birlikte yorulan, tüm nazımı çeken, her zorlukta sabırla yanımda duran, beni her düştüğümde kaldıran, attığım her adımda desteğini hissettiren Hasan Safa Yılmaz’a en derin sevgi ve teşekkürlerimi sunarım.

Çok sevgili Zeugma ailemin tüm üyelerine ve Prof. Dr. Nuray Bayrakçı’ya, benimle her zaman gurur duydukları, başaracağıma benden çok inandıkları ve beni her zaman yüreklendirdikleri için en içten sevgi ve teşekkürlerimi sunarım.

Doğduğum günden beri attığım her adımda, aldığım her kararda yanımda olan, maddi ve manevi desteklerini asla esirgemeyen, her düştüğümde daha güçlü ayağa kalkmamı sağlayan, sevgi ve inançlarıyla beni ayakta tutan, benimle sonsuz gurur duyan, hayatımın en büyük şansı çok kıymetli aileme; annem Ülkü Oltu’ya, babam Mehmet Haşim Oltu’ya, kardeşim Tolga Oltu’ya, anneannem İkbâl Tunçer’e, dedem Güngör Tunçer’e, halam Füsün Oltu Ersoy’a, Gürsel Ersoy’a ve attığım her adımda beni izlediklerini ve benimle gurur duyduklarını bildiğim, kalbimde yaşayan canım dayım Hasan Tunçer’e, babaannem Güzin Oltu’ya ve dedem Mükerrrem Oltu’ya bu süreçte de hayatımın her döneminde olduğu gibi beni ne olursa olsun destekledikleri, yanımda oldukları ve bana güvendikleri için, en derin sevgi, saygı ve teşekkürlerimi sunarım.

ÖZET

Burcu OLTU

DERİN ÖĞRENME YÖNTEMLERİ İLE AKCİĞER GRAFİLERİNDE PATOLOJİ SINIFLANDIRILMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

2025

Akciğerler, solunum sisteminin temel organları olup yapısal bozukluklar, enfeksiyonlar veya çevresel etkenler nedeniyle işlev kaybına uğrayabilmektedir. COVID-19, tüberküloz, pnömoni, pulmoner fibröz, atelektazi, kardiyomegali ve pnömotoraks gibi akciğer hastalıkları erken evrede teşhis edilmediğinde ölümcül sonuçlara yol açabilmektedir. Bu nedenle akciğer hastalıklarının erken ve doğru şekilde teşhis edilmesi büyük önem taşımaktadır. Akciğer grafileri, düşük maliyet ve hızlı uygulanabilirlik gibi avantajlarıyla bu amaçla yaygın olarak kullanılmaktadır. Ancak örtüşen anatomik yapılar, sınırlı uzman sayısı ve yüksek görüntü hacmi gibi etkenler, bu görüntülerin yorumlanmasını zorlaştırmakta, günlük yaklaşık %3-5 oranında hata yapılmasına yol açmaktadır. Bu doğrultuda akciğer grafilerinin yorumlanabilmesi için radyologlara yardımcı olacak otomatik ve güvenilir teşhis sistemlerine duyulan ihtiyaç gün geçtikçe artmaktadır.

Bu tez çalışmasında akciğer grafilerinin yüksek performansla sınıflandırılması amacıyla uçtan uca bir derin öğrenme modeli geliştirilmiş ve bu modelin başarısını artıracak özgün kayıp fonksiyonlarını önerilmiştir. Modelin omurgası olarak önceden eğitilmiş DenseNet201 mimarisi kullanılmıştır. DenseNet201'den çıkarılan öznitelik haritalarından daha zengin uzamsal bilgiler elde etmek amacıyla evrimsel uzun kısa süreli bellek (Convolutional Long Short-Term Memory (ConvLSTM)) katmanı, kanal bazında özniteliklerin vurgulanması için sıkma-bırakma bloğu (Squeeze and Excitation (SE)) ve uzun menzilli bağımlılıkları yakalayan görü dönüştürücüler (Vision Transformer (ViT)) modele entegre edilmiştir. Ayrıca, küresel ortalama havuzlama (Global Average Pooling (GAP)) katmanı ile sınıflandırma için önemli uzamsal bilgilerin korunması sağlanmıştır. Bu bileşenlerin kombinasyonu ile önerilen model, yüksek sınıflandırma performansı sunmuştur. Çalışmada ayrıca, sınıflandırma başarısında önemli etkisi olan kayıp fonksiyonları derinlemesine incelenmiştir. Standart fonksiyonlara ek olarak hibrit ve dinamik yapılarda

fonksiyonlar tasarlanmış, sınıflandırma eğilimlerine karşı ceza terimi içeren özgün bir fonksiyon önerilmiştir. Önerilen kayıp fonksiyonlarının avantajlarını bir araya getirerek sınıflandırma performansını artıracak farklı topluluk yaklaşımları uygulanmıştır. Bu fonksiyonların performansları sistematik olarak analiz edilmiş ve farklı modellerle de test edilerek modelden bağımsız başarı sağladığı gösterilmiştir.

Başkent Üniversitesi Ankara Hastanesi Radyoloji Bölümü'nden elde edilen klinik veriler ile açık erişimli veri kümeleri birleştirilerek 7, 8, 9, 10, 12, 14 ve 15 sınıflı alt veri kümeleri oluşturulmuş ve her bir alt kümede önerilen model ve kayıp fonksiyonları detaylı şekilde test edilmiştir. Böylece hem veri kümesinden hem de sınıf sayısından bağımsız olarak modelin ve kayıp fonksiyonunun başarısı ortaya konmuştur.

Elde edilen deneysel sonuçlar, önerilen yöntemin literatürdeki yaklaşımların çoğunu geride bıraktığını ve doğruluk, F1-skoru, AUC gibi performans metriklerinde yüksek başarı sergilediğini ortaya koymaktadır. Ayrıca modelin farklı senaryolarda tutarlı ve yüksek performans sergilemesi, güçlü bir genelleme yeteneğine sahip olduğunu kanıtlamaktadır.

Sonuç olarak, bu tez kapsamında, akciğer grafiplerinin otomatik olarak sınıflandırılmasını sağlayan yüksek performanslı ve tekrarlanabilir sonuçlar üreten yenilikçi bir model ve özgün kayıp fonksiyonları geliştirilmiştir.

ANAHTAR KELİMELER: Akciğer Grafipleri, Derin Öğrenme, Evrimsel Sinir Ağı, Dikkat Mekanizması, Kayıp Fonksiyonları.

Başkent Üniversitesi, Proje No: KA21/111

ABSTRACT

Burcu OLTU

CLASSIFICATION OF PATHOLOGIES IN CHEST X-RAYS USING DEEP LEARNING TECHNIQUES

Baskent University Institute of Science

Department of Biomedical Engineering

2025

The lungs are the primary organs of the respiratory system and can lose functionality due to structural disorders, infections, or environmental factors. Lung diseases such as COVID-19, tuberculosis, pneumonia, pulmonary fibrosis, atelectasis, cardiomegaly, and pneumothorax may lead to fatal outcomes if not diagnosed at an early stage. Therefore, early and accurate diagnosis of lung diseases is crucial. Chest radiographs (CXRs) are widely used for this purpose due to their advantages, such as low cost, quick applicability, and low radiation dose. However, factors like overlapping anatomical structures, limited specialists, and high image volume make interpreting CXRs challenging, resulting in a daily error rate of 3–5%. Thus, the demand for automated and reliable diagnostic systems to assist radiologists in interpreting CXRs is increasing.

In this thesis, an end-to-end deep learning model was developed for high-performance classification of CXRs, and novel loss functions were proposed to enhance the model's performance. The pre-trained DenseNet201 architecture was used as the backbone. A Convolutional Long Short-Term Memory (ConvLSTM) layer to obtain richer spatial and temporal information from the feature maps obtained from DenseNet201, a Squeeze and Excitation (SE) block to emphasize channel-wise features, and Vision Transformers (ViT) to capture long-range dependencies were integrated into the model. In addition, a Global Average Pooling (GAP) layer was used to preserve important spatial information for classification. The combination of these components enabled high classification performance.

The study also examined the often-overlooked role of loss functions in classification performance. Beyond standard functions, hybrid and dynamic structures were designed. A custom function with a penalty term was proposed to improve sensitivity to misclassification. Ensemble approaches combining the strengths of proposed loss functions

were implemented. These loss functions were systematically analyzed and tested with various models, demonstrating architecture-independent success.

To evaluate the performance and generalization ability of the proposed model and loss functions, a comprehensive dataset was created by combining clinical images from Başkent University Ankara Hospital with open-access datasets. This dataset was divided into subsets containing 7, 8, 9, 10, 12, 14, and 15 classes, and extensive testing was conducted on each subset. Results showed that the proposed method outperforms many existing approaches in the literature, achieving superior accuracy, F1-score, and AUC. The model's consistent performance in various scenarios demonstrated strong generalization.

In conclusion, this thesis presents a novel deep learning model and original loss functions that produce high-performance and reproducible results for the automatic classification of CXRs.

KEYWORDS: Chest X-Rays, Deep Learning, Convolutional Neural Networks, Attention Mechanism, Loss Functions.

Baskent University, Project No: KA21/111

İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	iii
ABSTRACT	v
İÇİNDEKİLER.....	vii
TABLolar LİSTESİ	xi
ŞEKİLLER LİSTESİ	xii
SİMGELER VE KISALTMALAR LİSTESİ	xiv
1. GİRİŞ	1
1.1. Çalışmanın Konusu, Amacı ve Önemi.....	1
1.2. Literatür Özeti.....	4
1.2.1. Akciğer graflerinin sınıflandırılması için önerilen evrimsel sinir ağı mimarileri.....	4
1.2.2. Akciğer graflerinin sınıflandırılması için önerilen dikkat ağı.....	11
1.2.3. Akciğer graflerinin sınıflandırılması için kullanılan kayıp fonksiyonları.....	18
1.2.4. Önerilen çalışmanın literatüre katkısı.....	24
1.3. Genel Bakış	25
2. KURAMSAL TEMELLER	27
2.1. Akciğer Anatomisi ve Fizyolojisi.....	27
2.2. Akciğer Grafisi	27
2.3. Akciğer Patolojileri	28
2.3.1. COVID-19.....	28
2.3.2. Tüberküloz	29
2.3.3. Pnömoni.....	30
2.3.4. Pnömotoraks	31
2.3.5. Atelektazi.....	31
2.3.6. Kardiyomegali.....	32
2.3.7. Akciğer ödemi	33
2.3.8. Plevral efüzyon.....	33
2.3.9. Nodül ve Kitle.....	34
2.3.10. Pulmoner fibröz	34
2.3.11. Kosta kırığı.....	35

2.3.12. Konsolidasyon ve İnfiltrasyon	35
2.3.13. Akciğer Opasitesi.....	36
2.4. Derin Öğrenme Yöntemleri	37
2.4.1. Evrişimsel sinir ağları (Convolutional neural networks (CNN))	37
2.4.2. Dikkat mekanizmaları.....	41
2.4.3. Diğer derin öğrenme yapıları	46
2.5. Kayıp Fonksiyonları.....	49
2.6. Performans Değerlendirmesi.....	51
2.7. Isı Haritaları	52
3. MATERYAL VE METOD	54
3.1. Çalışmada Kullanılan Veri Kümesi.....	54
3.1.1. Başkent Üniversitesi Ankara Hastanesi veri tabanı.....	54
3.1.2. NIH Chest X-ray14 veri tabanı	55
3.1.3. CheXpert veri tabanı.....	56
3.1.4. COVID-19 Radyografi veri tabanı.....	56
3.1.5. Tüberküloz akciğer grafisi veri tabanı	56
3.1.6. Pnömoni akciğer grafisi veri tabanı (Kaggle)	57
3.1.7. Fibröz akciğer grafisi veri tabanı (Kaggle)	57
3.1.8. JSRT veri tabanı.....	57
3.2. Önerilen Modeller	61
3.2.1. Model 1	62
3.2.2. Model 2	63
3.2.3. Model 3	64
3.2.4. Model 4	64
3.2.5. Model 5	66
3.2.6. Model 6	66
3.2.7. Model 7	67
3.3. Önerilen Kayıp Fonksiyonları.....	68
3.3.1. Hibrit kayıp fonksiyonları	68
3.3.2. Dinamik kayıp fonksiyonları	69
3.3.3. Ceza skoru eklenmiş kategorik çapraz entropi kayıp fonksiyonu	70
3.3.4. Topluluk yöntemi ile birleştirilen kayıp fonksiyonları	71
4. DENEYSEL SONUÇLAR	76
4.1. En Başarılı Modelin Belirlenmesi	76

4.1.1. Dört sınıflı veri kümesi sınıflandırma sonuçları.....	77
4.1.2. Beş sınıflı veri kümesi sınıflandırma sonuçları.....	78
4.1.3. Altı sınıflı veri kümesi sınıflandırma sonuçları	83
4.1.4. Yedi sınıflı veri kümesi sınıflandırma sonuçları.....	85
4.1.5. Sekiz sınıflı veri kümesi sınıflandırma sonuçları.....	87
4.1.6. En başarılı modelin seçilmesi.....	89
4.2. En Başarılı Kayıp Fonksiyonunun Belirlenmesi	91
4.2.1. Hibrit ve dinamik kayıp fonksiyonları için en başarılı iki kayıp fonksiyonunun belirlenmesi.....	91
4.2.2. Altı sınıflı veri kümesi sınıflandırma sonuçları	92
4.2.3. Yedi sınıflı veri kümesi sınıflandırma sonuçları.....	96
4.2.4. Sekiz sınıflı veri kümesi sınıflandırma sonuçları-1	99
4.2.5. Sekiz sınıflı veri kümesi sınıflandırma sonuçları-2	102
4.2.6. Dokuz sınıflı veri kümesi sınıflandırma sonuçları.....	105
4.2.7. On sınıflı veri kümesi sınıflandırma sonuçları.....	108
4.2.8. On iki sınıflı veri kümesi sınıflandırma sonuçları	111
4.2.9. On dört sınıflı veri kümesi sınıflandırma sonuçları	114
4.2.10. On beş sınıflı veri kümesi sınıflandırma sonuçları	117
4.2.11. En başarılı kayıp fonksiyonunun seçilmesi	121
4.2.12. En başarılı kayıp fonksiyonunun modelden bağımsız performans değerlendirmesi.....	126
4.3. Model Kararının Görselleştirmesi	129
5. TARTIŞMA	130
6. SONUÇ VE ÖNERİLER.....	134
KAYNAKLAR.....	136
EKLER	158
EK 1: Dört Sınıf için Model Test Sonuçları	
EK 2: Beş Sınıf için Model Test Sonuçları	
EK 3: Altı Sınıf için Model Test Sonuçları	
EK 4: Yedi Sınıf için Model Test Sonuçları	
EK 5: Sekiz Sınıf için Model Test Sonuçları	
EK 6: Model 2 ile Yapılan Kayıp Fonksiyonları Test Sonuçları	
EK 7: Altı Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları	
EK 8: Yedi Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları	

- EK 9: Sekiz Sınıf İçin Önerilen Kayıp Fonksiyonları Test Sonuçları**
- EK 10: Dokuz Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları**
- EK 11: On Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları**
- EK 12: On İki Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları**
- EK 13: On Dört Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları**
- EK 14: On Beş Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları**
- EK 15: En Başarılı Kayıp Fonksiyonunun Model Bazında Test Sonuçları**

TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. Veri kümesi dağılımı.....	59
Tablo 3.2. Veri kümesi ayrımı.....	60
Tablo 4.1. Altı sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları	94
Tablo 4.2. Yedi sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları	97
Tablo 4.3. Sekiz sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları-1	100
Tablo 4.4. Sekiz sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları-2	103
Tablo 4.5. Dokuz sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları.	106
Tablo 4.6. On sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları	109
Tablo 4.7. On iki sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları .	113
Tablo 4.8. On dört sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları	115
Tablo 4.9. On beş sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları	119
Tablo 4.10. Sınıf bazında Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi ($b=2$, $b=3$, $b=5$), KÇE ve KH ile elde edilen performansların karşılaştırılması.....	124
Tablo 4.11. Model bazında kayıp fonksiyonu performans karşılaştırması	128
Tablo 5.1. Literatürdeki çalışmalar ile tezde elde edilen sonuçların karşılaştırılması...	133

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Tipik CNN mimarisi.....	37
Şekil 2.2. Aktivasyon fonksiyonları	38
Şekil 2.3. Beş katmanlı yoğun blok örneği.....	40
Şekil 2.4. Sıkma- Uyarma bloğu	42
Şekil 2.5. Görü dönüştürücü	44
Şekil 2.6. Dönüştürücü kodlayıcı	45
Şekil 2.7. ConvLSTM'in yapısı.....	47
Şekil 2.8. Sınıf 1 için DP, DN, YP ve YN hesaplamalarını gösteren karışıklık matrisi. 52	
Şekil 2.9. Grad-CAM görüntüleri.....	53
Şekil 3.1. Örnek akciğer grafileleri.	58
Şekil 3.2. Model 1 blok diyagramı.	62
Şekil 3.3. Model 2 blok diyagramı.	63
Şekil 3.4. Model 3 blok diyagramı.	64
Şekil 3.5. Model 4 blok diyagramı.	65
Şekil 3.6. Model 5 blok diyagramı.	66
Şekil 3.7. Model 6 blok diyagramı.	67
Şekil 3.8. Model 7 blok diyagramı.	68
Şekil 3.9. Dinamik kayıp fonksiyonu eğrisi- a) Yaklaşım 1, b) Yaklaşım 2.....	70
Şekil 3.10. Önerilen topluluk yöntemi.....	72
Şekil 4.1. Dört sınıflı veri kümesi için modellerin ortalama performans değerleri.....	77
Şekil 4.2. Dört sınıf için en düşük ve en yüksek başarıya sahip modellerin (Model 1 ve Model 6) ROC eğrileri.....	78
Şekil 4.3. Beş sınıf-1 veri kümesi için modellerin ortalama performans değerleri.	79
Şekil 4.4. Beş sınıf-1 için en düşük ve en yüksek başarıya sahip modellerin (Model 5 ve Model 2) ROC eğrileri.....	80
Şekil 4.5. Beş sınıf-2 veri kümesi için modellerin ortalama performans değerleri.	80

Şekil 4.6.	Beş sınıf-2 için en düşük ve en yüksek başarıya sahip modellerin (Model 4 ve Model 7) ROC eğrileri.....	81
Şekil 4.7.	Beş sınıf-3 veri kümesi için modellerin ortalama performans değerleri.	82
Şekil 4.8.	Beş sınıf-3 için en düşük ve en yüksek başarıya sahip modellerin (Model 3 ve Model 1, Model 2) ROC eğrileri.	83
Şekil 4.9.	Altı sınıflı veri kümesi için modellerin ortalama performans değerleri.	84
Şekil 4.10.	Altı sınıf için en düşük ve en yüksek başarıya sahip modellerin (Model 5 ve Model 2) ROC eğrileri.....	85
Şekil 4.11.	Yedi sınıflı veri kümesi için modellerin ortalama performans değerleri.	86
Şekil 4.12.	Yedi sınıf için en düşük ve en yüksek başarıya sahip modellerin (Model 7 ve Model 5) ROC eğrileri.....	87
Şekil 4.13.	Sekiz sınıflı veri kümesi için modellerin ortalama performans değerleri.	88
Şekil 4.14.	Sekiz sınıf için en düşük ve en yüksek başarıya sahip modellerin (Model 1 ve Model 2) ROC eğrileri.....	89
Şekil 4.15.	Kayıp fonksiyonları test performansları.....	92
Şekil 4.16.	Kayıp fonksiyonlarının farklı modeller için doğruluk değerleri.	126
Şekil 4.17.	Dört sınıf için Grad-CAM örnekleri.....	129

SİMGELER VE KISALTMALAR LİSTESİ

AP	Anteroposterior
BT	Bilgisayarlı Tomografi
CBAM	Convolutional Block Attention Module (Evrişimsel Blok Dikkat Modülü)
CLAHE	Contrast Limited Adaptive Histogram Equalization (Kontrast Sınırlı Adaptif Histogram Eşitleme)
CNN	Convolutional Neural Network (Evrişimsel Sinir Ağı)
ConvLSTM	Convolutional Long Short-Term Memory (Evrişimsel Uzun Kısa Süreli Bellek)
FFN	Feed-Forward Network (İleri Beslemeli Ağ)
GAP	Global Average Pooling (Küresel Ortalama Havuzlama)
GELU	Gaussian Error Linear Unit (Gauss Hatalı Doğrusal Birim)
Grad-CAM	Gradient-weighted Class Activation Mapping (Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama)
KÇE	Kategorik Çapraz Entropi
KH	Kategorik Hinge
KL	Kullback-Leibler Divergence (KL Sapma Kaybı)
MA	Masked Attention (Maskeli Dikkat Mekanizması)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MHSA	Multi-Head Self Attention (Çok Başlı Öz Dikkat)
MLP	Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)
MSE	Mean Squared Error (Ortalama Kare Hata)
PA	Posteroanterior
ReLU	Rectified Linear Unit (Düzeltilmiş Doğrusal Birim)
ROC	Region of Convergence (Yakınsama Bölgesi)
RT-PCR	Reverse Transcription Polymerase Chain Reaction (Ters Transkripsiyon Polimeraz Zincir Reaksiyonu)
SE	Squeeze and Excitation (Sıkıştırma-Uyarma)
TB	Tüberküloz
ViT	Vision Transformer (Görü Dönüştürücü)
WHO	World Health Organization (Dünya Sağlık Örgütü)

1. GİRİŞ

1.1. Çalışmanın Konusu, Amacı ve Önemi

Akciğer hastalıkları, solunum sistemini etkileyen, her biri kendine özgü patofizyolojik özelliklere ve hasta sağlığı açısından önemli etkilere sahip çeşitli medikal durumlardır. Dünya Sağlık Örgütü'ne (World Health Organization (WHO)) göre akciğer hastalıkları dünya çapında önemli bir halk sağlığı sorunudur. Dünya genelinde her yıl milyonlarca insan bu hastalıklara yakalanmakta ve bunların binlercesi yaş faktörü, altta yatan sağlık sorunları ve geç teşhis nedeniyle hayatını kaybetmektedir [1].

COVID-19, tüberküloz (TB), pnömoni, pulmoner fibröz, pulmoner nodüller, atelettazi, kardiyomegali, pnömotoraks, teşhisi ve yönetimi zorlu dolayısıyla hem hastalara hem de sağlık sistemlerine ağır yük oluşturan akciğer hastalıklarının ölümcül örnekleridir. SARS-CoV-2 virüsünün neden olduğu COVID-19, hızlı yayılması, akciğerlerde ciddi solunum sıkıntısı yaratması ve uzun vadeli komplikasyonlara neden olması nedeniyle Mart 2020'de WHO tarafından küresel pandemi olarak ilan edilmiştir. WHO verilerine göre, Mayıs 2025 itibarıyla dünya çapında 777.825.189 doğrulanmış COVID-19 vakası görülmüş ve bu vakaların 7.095.903'ü ölümle sonuçlanmıştır [2]. Mycobacterium tuberculosis bakterisinin neden olduğu ve kemik, beyin, lenf nodları gibi vücut bölümlerini etkilese de özellikle pulmoner bir patojen olarak kabul edilen TB, 2023 yılında dünyada tek bir bulaşıcı etkenden kaynaklanan birincil ölüm sebebidir [3], [4]. Akciğerlerde sıvı birikmesi sonucu kısa sürede boğulmaya neden olabilen ölümcül bir enfeksiyon olan pnömoni, her yıl nüfusun %7'sini etkileyen son derece tehlikeli bir akciğer hastalığıdır [5]. COVID-19, TB, pnömoni gibi bulaşıcı hastalıklara ek olarak, yapısal akciğer anomalileri de önemli bir endişe kaynağıdır. Pulmoner fibröz, esas olarak akciğer dokusu hasar gördüğünde ve yaralandığında oluşan, kronik solunum semptomlarına yol açan bir akciğer hastalığıdır [6]. Pulmoner nodül, akciğerde bulunan küçük, yoğun doku kitlesidir. Nodül boyu 3 cm'den büyük olduğunda bu durum kitle olarak adlandırılmaktadır. Pulmoner nodüllerin ve kitlelerin akciğer kanserinin erken belirtisi olduğu bilinmektedir. Bu nedenle bunların kesin tanısı büyük önem taşımaktadır [7]. Genel anestezinin en yaygın postoperatif pulmoner komplikasyonlarından biri olan atelettazi ise gaz değişimini bozarak hipoksemiye ve pnömoni ve akut akciğer hasarı gibi diğer pulmoner komplikasyonlara yol açabilmekte ve bu da mortalite artışına neden olabilmektedir [8]. Pnömotoraks, plevral boşlukta serbest hava olduğunda ortaya çıkan durum için kullanılan tıbbi bir terimdir. Göğüs yaralanması olan

hastalarda pnömotoraks gelişme olasılığı %30 ila %39'dur ve bu durum erken tespit edilip tedavi edilmezse ölümcül olabilmektedir [9]. Kardiyomegali kendi başına bir hastalık olmamakla birlikte kalbin tamamının ya da bazı kısımlarının büyümesi olarak ifade edilen durumdur ve ciddi kalp hastalıklarının önemli bir işaretidir. Bu durumun erken teşhis edilmesi ve altında yatan sebeplerin araştırılması hayati bir öneme sahiptir [10]. Akciğer ödemi, akciğerlerin alveollerinde sıvı birikmesi nedeniyle oluşmaktadır. Plevral efüzyon ise akciğerleri çevreleyen zarlarda anormal sıvı birikmesi sonucu oluşan klinik bir semptomdur. Sıvının akciğer dokusu ve hava kesecikleri içinde mi (pulmoner ödem) yoksa plevral boşlukta mı (plevral efüzyon) yer aldığını belirlemek etkin tedavi için büyük önem taşımaktadır [11]. Kaburga kırığı ise kaburga kemiklerinin kırılmasını ifade etmektedir, altındaki organlara zarar vermemesi için erken teşhis edilmesi önem taşımaktadır [12].

Bu hastalıkların her biri ölümcül hastalıklar ya da ölüme neden olabilecek durumlar olsalar da erken teşhisi takiben yapılan erken ve etkili tedavi ile ölüm oranları düşürülebilir. Bu amaçla erken ve doğru tanıya ihtiyaç duyulmaktadır [4], [13], [14]. Akciğer hastalıklarının taranmasında ve teşhisinde en yaygın olarak kullanılan görüntüleme yöntem akciğer grafileridir [15], [16]. Akciğer grafisi, ucuz ve hızlı bir klinik tanı yöntemidir. Ayrıca bu yöntemde hastalara uygulanan radyasyon dozları diğer görüntüleme yöntemlerine göre daha düşüktür [17]. Özellikle, radyoloji hizmetlerinin yetersiz olduğu, gelişmekte olan veya kaynak bakımından fakir ülkelerde uygulanmak için mükemmel bir seçimdir [18]. Bununla birlikte akciğer grafileri üzerinden yapılan tanı, 2 boyutlu projeksiyon etkisi nedeniyle anatomik yapıların örtüşmesi, olası anormalliklerin ve hastalıkların çeşitliliği gibi zorluklardan ötürü büyük ölçüde bilgi gerektiren ve radyologların deneyimine bağlı bir süreçtir. Ayrıca, bu işlem oldukça zaman alıcıdır [19], [20]. Radyologların retrospektif olarak ortaya çıkan anlamlı bir patolojide hata ya da kaçırma oranı ortalama %30 iken, günlük gerçek zamanlı okumalarda hata oranı %3-5 arasında değişmektedir [21], [22].

Dolayısıyla akciğer grafilerinin değerlendirilmesi öznel tanı hatalarına eğilimli ve zaman alıcı bir işlemdir. Daha da önemlisi, yanlış pozitifler hasta kaygısına, gereksiz takibe ve invaziv tanı prosedürlerine neden olabilmektedir. Bunun yanında tarama sürecinde gözden kaçan hastalıklar, durum ağırlaşana ve tedavi için uygun olmayana kadar tespit edilemeyebilir [23]–[25]. Öte yandan, her gün hastanelerde yüzlerce akciğer grafisi çekilmektedir. Çok sayıda şüpheli vaka ve sınırlı sayıda eğitimli radyolog olduğu düşünüldüğünde, akciğer grafilerinden hastalık tespiti için radyologlara yardımcı olacak, etkili ve otomatik yöntemlere olan ihtiyaç giderek artmaktadır [17]. Akciğer grafilerinin yorumlama sürecini otomatikleştirebilen ve insan çabasını en aza indirebilen bir bilgisayar

destekli tanı sistemi, radyologlara ikinci bir görüş sağlayarak üzerlerindeki yükü azaltacaktır. Bu durum da tanı doğruluklarının artmasına ve hasta bakımının iyileşmesine yol açarak klinik uygulamada çok büyük fayda sağlayacaktır [1], [23], [26], [27].

Son yıllarda, özellikle derin öğrenme modelleri, akciğer grafilerinin otomatik yorumlanmasında başarılı sonuçlar elde ederek, hastalıkların tespitinde ve sınıflandırılmasında radyologlara önemli destek sağlamıştır. Bu gelişmeler, çeşitli akciğer hastalıklarının erken ve etkili tedavisini mümkün kılarak tanısal verimlilik ve tutarlılığın artırılmasına olanak tanımaktadır [15], [28].

Bu amaçla, sunulan tez çalışmasında, akciğer grafilerinin sınıflandırılması için literatürden farklı, yenilikçi bir derin öğrenme yaklaşımı sunulmuştur. Çalışma kapsamında, önceden eğitilmiş DenseNet201, evrimsel uzun kısa süreli bellek (Convolutional Long Short-Term Memory (ConvLSTM)), sıkma-bırakma bloğu (Squeeze and Excitation (SE)) ve görü dönüştürücülerin (Vision Transformer (ViT)) bir arada kullanılmasıyla hem yerel hem de küresel özniteliklerin çıkarılmasını sağlayan hibrit bir model önerilmiştir. Modelin omurgasını oluşturan DenseNet201 özniteliklerin etkili bir şekilde öğrenilmesini sağlamaktadır. ConvLSTM, uzamsal ilişkileri etkili bir şekilde öğrenirken, SE blokları, kanal bazında önemli öznitelikleri vurgulayarak performansı artırmaktadır. Dönüştürücü ise, özellikle uzun menzilli bağımlılıkları öğrenerek veri arasındaki uzak ilişkileri keşfetmeye olanak tanımaktadır. Küresel ortalama havuzlama (Global Average Pooling (GAP)) bloğu ise karmaşık öznitelik haritalarını sınıflandırma katmanı için uygun hale getirirken, gereksiz parametreleri ortadan kaldırarak modelin genelleme yeteneğine katkı sağlamaktadır. Bu bileşenlerin bir araya gelmesi, modelin yalnızca güçlü bir sınıflandırma performansı sergilemesini değil, aynı zamanda çeşitli akciğer hastalıkları arasındaki ince farklılıkları da etkili bir şekilde tespit etmesini sağlamaktadır. İkinci olarak, bu çalışmada, literatürde genellikle ihmal edilen bir konu olan kayıp fonksiyonlarının sınıflandırma performansı üzerindeki etkileri incelenmiştir. Mevcut yöntemlerin çoğu, standart kayıp fonksiyonlarına bağlı kalmakta ve sınıflandırma performansındaki potansiyel artışları göz ardı etmektedir. Bu bağlamda, çalışmada hibrit, dinamik ve ceza terimi eklenmiş özel kayıp fonksiyonları önerilmiştir. Bu fonksiyonların tek başına da ya da topluluk yöntemleriyle birleştirilerek kullanılması ile modelin genel başarısının artması hedeflenmiştir. Aynı zamanda modelin hangi bölgeleri dikkate alarak karar verdiği Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama (Gradient-weighted Class Activation Mapping (Grad-CAM)) yöntemi ile görselleştirilmiş, böylece modelin karar mekanizması daha anlaşılır hale getirilmiştir. Sonuç olarak, bu çalışmada, yenilikçi model mimarisi ve özel olarak tasarlanmış kayıp fonksiyonları ile, çok

sınıflı akciğer grafilerinin otomatik sınıflandırılması için literatüre katkı sunmak amaçlanmıştır. Geliştirilen yaklaşımların, klinik uygulamalarda pratik ve etkili çözümler üretme potansiyeli olduğu düşünülmektedir.

1.2. Literatür Özeti

Akciğer patolojilerinin erken teşhisini desteklemek amacıyla, akciğer grafilerinin hızlı ve doğru bir şekilde yorumlanmasını sağlayan bilgisayar destekli tanı sistemleri önem kazanmaya başlamıştır. Akciğer grafilerinin çok sayıda olması, yorumlanmalarının karmaşıklığı ve klinik uygulamadaki değerleri, 1960'lardan beri araştırmacıları analiz için otomatik algoritmalar oluşturmaya motive etmektedir. Son yıllarda ise, derin öğrenme algoritmalarının, özellikle evrimsel sinir ağlarının (Convolutional Neural Network (CNN)) ortaya çıkışı tıbbi görüntüleme alanında büyük bir etki yaratmış, hatta bu yöntemlerin çeşitli alanlarda tıp uzmanlarının performansını geride bıraktığı kanıtlanmıştır [27], [29].

Bu bölümde, literatürde akciğer grafilerinin sınıflandırılması amacıyla geliştirilen CNN mimarileri, dikkat mekanizması ve dönüştürücü tabanlı yöntemler detaylı bir şekilde açıklanmış, ayrıca sınıflandırma başarısını etkileyen en önemli parametrelerden biri olan kayıp fonksiyonları üzerine yapılan çalışmalar ele alınmıştır.

1.2.1. Akciğer grafilerinin sınıflandırılması için önerilen evrimsel sinir ağı mimarileri

Akciğer grafilerinden hastalık tespiti için otomatik bir yöntem geliştirmek amacıyla pek çok çalışma yapılmıştır. Özellikle son yıllarda, en iyi öznitelikleri otomatik olarak çıkarabilme yetenekleri ve geleneksel makine öğrenme yöntemlerine göre daha yüksek performans göstermeleri nedeniyle, başta CNN mimarileri olmak üzere derin öğrenme teknikleri yaygın olarak tercih edilmeye başlanmıştır [30]–[32]. Bununla birlikte, geliştirilen algoritmalar çoğunlukla nispeten daha küçük veri kümeleri üzerinde eğitilmekte ve test edilmektedir [33]–[35]. Geliştirilen algoritmalar çoğunlukla COVID-19, TB, pnömoni (viral-bakteriyel) sınıflarını içeren veri kümeleri üzerinde test edilmiş olsa da çalışmalara pnömotoraks ve pulmoner fibröz sınıflarının da dahil edildiği görülmektedir.

2019 yılında Kesim vd. tarafından yapılan çalışmada akciğer grafilerinin sınıflandırılması için yeni ağ yapıları önerilmiş ve giriş görüntüsünün boyutunun analize etkisi araştırılmıştır. ChestX-ray14 veri kümesi kullanılarak yapılan çalışmada veri sayısı dengesizliğinin önüne geçmek için yalnızca 12 sınıf ile analizler yapılmıştır. Bu çalışmada

üç farklı CNN modeli karşılaştırmalı olarak incelenmiştir. Çalışma sonunda CNN-1, CNN-2 ve CNN-3 için sırasıyla %67,3, %86 ve %84,8 doğruluk değerleri elde edilmiştir [36].

Yine aynı yıl ChestX-ray14 veri kümesindeki tüm sınıfları ayırtmak için Chaudhary et al. tarafından önerilen CNN mimarisi üç evrişim katmanı, üç aktivasyon katmanı, üç havuzlama katmanı ve ardından üç tam bağlı katman olmak üzere on iki katmandan oluşmaktadır. Tam bağlı katmanın çıktısı, belirli bir girdi için her bir sınıfın olasılığını veren bir softmax katmanına iletilmektedir. Çalışma sonunda sıfırdan kurulan bu mimari ile %89,77 doğruluk elde edilmiştir [37].

2020 yılında Oh et al. tarafından yapılan çalışmada akciğer grafilerini 5 sınıfa (normal, bakteriyel pnömoni, viral pnömoni, TB, COVID-19) ayırtmak amacıyla bir yöntem önerilmiştir. Önerilen yöntemde bölütleme ağı ile akciğer bölgeleri çıkartılmıştır. Bölütlenen bölgeler yama bazında ResNet18'e beslenmiştir. Nihai karar çoğunluk oylamasına göre verilmiştir. Çalışma sonucunda sırasıyla %88,9 doğruluk, %83,4 kesinlik, %85,9 duyarlılık, %84,4 F1-skoru ve %96,4 özgüllük elde edilmiştir [38].

Mahmud et al., COVID-19 ve diğer pnömoni türlerini sınıflandırmak için CovXNet adlı derin bir sinir ağı mimarisi önermişlerdir. Önerdikleri modelde geleneksel evrişim yerine görüntülerdeki anormallikleri farklı perspektiflerden analiz etmek için farklı bölgelerden çıkartılan öznetelikleri birleştiren derinlikli evrişim (depthwise convolution) kullanmışlardır. CovXNet ağının ilk eğitimi için geleneksel transfer öğrenmesi (transfer learning) yönteminden (ImageNet ile eğitim) farklı olarak normal ve diğer geleneksel pnömoni hastalarından alınan akciğer grafilerini içeren daha büyük bir veri kümesi kullanmışlardır. Daha sonrasında küçük bir veri kümesi ile ağa ince ayar yapmışlardır. Çalışma sonunda COVID-19/normal ayrımı için %97,4 ve çok sınıflı COVID-19/normal/viral/bakteriyel pnömoni ayrımı için %90,2 doğruluk elde etmişlerdir [39].

Apostolopoulos et al., çalışmalarında COVID-19 dahil yedi sınıflı bir akciğer hastalığı sınıflandırma problemi için derin öğrenme yöntemlerinin etkinliğini değerlendirmişlerdir. Bu amaçla MobileNetV2 mimarisi kullanarak üç farklı eğitim stratejisi uygulamışlardır: sıfırdan model eğitimi, transfer öğrenmesine dayalı öznetelik çıkarımı ve ince ayar (fine-tuning) içeren hibrit yaklaşım. Yapılan deneyler sonucunda, elde edilen %86,66 doğruluk oranıyla sıfırdan eğitilen modelin tüm değerlendirme metriklerinde diğer iki stratejiye kıyasla daha yüksek performans gösterdiğini ortaya koymuşlardır [40].

Monshi et al., 2021 yılında yaptıkları çalışmada farklı veri artırma yöntemlerinin COVID-19 ve pnömoni teşhisine olan etkilerini incelemişlerdir. Farklı veri artırma yöntemleri ve farklı transfer öğrenmesi yöntemlerinin sınıflandırma performanslarını

değerlendirdikleri çalışmada en başarılı sonucu akciğer grafilere sırasıyla uygulanan 480x480 piksele sıkıştırma, 20° döndürme, 1,2 ölçekte yakınlaştırma, 0,2 büyüklükte çarpıtma (warping), 0,3 ölçekte aydınlatma ve normalizasyon sonrasında EfficientNet-B0 tabanlı derin ağ ile elde etmişlerdir. Çalışma sonucunda geliştirdikleri CovidXrayNet adını verdikleri mimari ile %95,82 doğruluk elde etmişlerdir [41].

Albahli, akciğer grafilerinden 8 farklı patolojiyi sınıflandırmak için önceden eğitilmiş InceptionV3 mimarisini kullanan bir yaklaşımı önermiştir. Model, GAN ile üretilen sentetik veriler kullanılarak eğitilmiş ve %81,5 doğruluk elde edilmiştir [42].

Bekhet et al. tarafından 2021 yılında yapılan çalışmada COVID-19 teşhisi için hafif (light weight) bir CNN modeli önerilmiştir. Model, üç evrişim katmanı ve bunları takip eden maksimum havuzlama ve yoğun (dense) katmanlardan oluşmaktadır. Çalışmada farklı filtre boyutlarının sınıflandırma performansları değerlendirilmiş ve en iyi performans sağlayan filtre boyutunun 5x5 olduğu gösterilmiştir. Bunun yanında en iyi aktivasyon fonksiyonunu belirlemek amacıyla yapılan analizlerde sigmoid fonksiyonunun en yüksek performansı gösterdiği sonucuna varılmıştır [43].

2021 yılında Zaidi et al. tarafından yapılan çalışmada akciğer patolojilerinin sınıflandırılması için tam otomatik bir hiyerarşik model önerilmiştir. Önerilen model bölütleme ve sınıflandırma adımlarını içermektedir. İlk olarak akciğer grafileri, tasarlanan ağ ile patolojik ve sağlıklı olarak sınıflandırılmıştır. Daha sonra patolojik görüntülerdeki akciğer bölgeleri U-net kullanılarak bölütlenmiştir. Bölütlenen patolojik görüntüler yine tasarlanan ağ ile sınıflandırılmıştır. Tasarlanan ağ, InceptionResNet mimarisinden önce eklenen dört ek evrişim katmanından oluşmaktadır. ChestX-ray14 kullanılarak yapılan bu çalışmada sınıflandırmada ortalama 0,861 AUC elde edilmiştir. Ayrıca modelin, bölütlenmiş akciğer bölgesi üzerinde eğitildiğinde ilgili öznelilikleri daha iyi öğrenebildiği ve böylece tüm akciğer grafilerinde sınıflandırma yapan mevcut modellerden daha iyi performans gösterdiği sonucuna varılmıştır [1].

COVID-19, pnömoni ve normal akciğer grafilerinin sınıflandırılması amacıyla Chakraborty et al. tarafından yapılan çalışmada önceden eğitilmiş CNN mimarilerinin COVID-19 tespiti üzerindeki etkisinin araştırılmasının yanı sıra bu görev için Corona-Nidaan adlı hafif bir CNN modeli önerilmiştir. Yapılan analizler sonucunda, Corona-Nidaan modelinin önceden eğitilmiş CNN mimarilerinden daha iyi performans gösterdiği görülmüştür [44].

Hamida et al. tarafından COVID-19, TB, viral pnömoni ve normal grafilerinin sınıflandırılması için transfer öğrenmesine dayalı bir model önerilmiştir. Önerilen

metodolojide önceden eğitilmiş ResNet152V2, ResNet101V2, MobileNetV2, VGG16 ve VGG19 kullanılmıştır. Bu ağlardan elde edilen tahminler, nihai tahmini yapmak için bir istifleme (stacking) tekniği olan k-en yakın komşu algoritmasıyla birleştirilmiştir. Sonuçta 4 sınıf için %99,23 doğruluk, %98,96 kesinlik, %99,34 duyarlılık ve %99, 75 özgüllük elde edilmiştir [45].

Mamalakis et al., COVID-19, pnömoni, TB ve sağlıklı grafileri sınıflandırmak amacıyla DenResCov-19 adında derin bir transfer öğrenmesi yaklaşımı önermişlerdir. Önerilen metodolojide, DenseNet121 ve ResNet50'den elde edilen öznitelik haritaları evrişim ve havuzlama katmanlarıyla birleştirilerek nihai karar elde edilmektedir. Çalışma sonucunda 4 sınıf için %82,9 kesinlik, %69,7 duyarlılık, %75,8 F1-skoru ve %95,1 mikro-ortalama AUC elde edilmiştir [46].

2021 yılında Xu et al. tarafından akciğer grafilerini kullanarak COVID-19'u normal, TB, bakteriyel pnömoni ve viral pnömoniden ayırmak için bir algoritma geliştirilmiştir. Önerilen MANet adı verilen bölütleme bazlı sınıflandırma algoritması iki aşamadan oluşmaktadır. İlk aşamada görüntüler bölütlenerek akciğer bölgeleri ayrıştırılmakta, ikinci aşamada ise bu bölütlenmiş alanlar üzerinden sınıflandırma işlemi yapılmaktadır. Bölütleme aşamasında ResUNet, sınıflandırma aşamasında ise maskeli ve maskesiz dikkat mekanizmalı dört klasik CNN mimarisi (ResNet34, ResNet50, VGG16 ve InceptionV3) kullanılmıştır. Maskeli Dikkat Mekanizması (Masked Attention (MA)) ile ResNet50 kullanılarak %97,06 test doğruluğu elde edilmiştir [47].

Kumar et al., önerdikleri VGG16 ve DenseNet'i birleştiren topluluk modeli (ensemble model) ile COVID-19, pnömoni, TB ve sağlıklı akciğer grafilerini sınıflandırmışlardır. Önerdikleri modelde her bir ağ çıkışında elde edilen tahminlerin çoğunluk oylamasına göre nihai sonuç belirlenmektedir. Çalışmada sonunda bu modelin, DenseNet201, InceptionResNetV2, ResNet152V2 ve VGG16 gibi yaklaşımlara kıyasla %99,32 doğrulukla daha üstün performans gösterdiğini kanıtlamışlardır [48].

Hong et al. tarafından sunulan çalışmada akciğer grafilerinin sınıflandırılması amacıyla EfficientNet-B7 tabanlı bir model geliştirilmiştir. İlk olarak etkili bir sınıflandırma için görüntülerdeki akciğer bölgeleri dışındaki kısımlar kesilmiştir. Kesilen görüntüler sınıflandırılmak için EfficientNet-B7'ye beslenmiştir. EfficientNet-B7'nin her katmanından elde edilen öznitelikleri çıkartarak bunları GAP ile sıkıştırılan ve birleştiren çoklu GAP yapısı önerilmiştir. Sonuç olarak 4 sınıf (normal, pnömoni, pnömotoraks ve TB) için %96,10 ortalama doğruluk, %92,20 ortalama duyarlılık ve %97,40 ortalama özgüllük elde edilmiştir [49].

2022 yılında Hassanlou et al. tarafından COVID-19'u otomatik olarak tespit eden yeni bir evrişimli sinir ağı olan FirecovNet önerilmiştir. SqueezeNet ve DarkNet-19 ağlarından ilham alan FirecovNet, diğer ağlardan daha az parametreye ve daha hızlı eğitime sahip hafif bir derin öğrenme ağıdır. Çalışmada önerilen model COVID-19, bakteriyel pnömoni, normal, akciğer opasitesi ve viral pnömoni görüntüleri kullanılarak eğitilmiştir ve sonuçta %96,96 doğruluk, %96,97 kesinlik, %96,97 hassasiyet ve %96,9 F1-skoru elde edilmiştir [50].

2022 yılında Huang et al. tarafından yapılan çalışmada COVID-19 tespiti için InceptionV3, ResNet50V2, Xception, DenseNet121, MobileNetV2, EfficientNet-B0 ve EfficientNetV2 dahil olmak üzere yedi CNN modeli ince ayar yapılarak eğitilmiştir. İnce ayar yapılan önceden eğitilmiş ağlara ek olarak AlexNet ve EfficientNetV2'yi temel alan, hafif bir CNN modeli olan LightEfficientNetV2 geliştirilmiştir. Çalışma sonunda önerilen LightEfficientNetV2 modelinin üçlü sınıflandırmada (COVID-19, pnömoni, normal) umut verici bir performans sergilediği gösterilmiştir [51].

Kumar et al., ikili (COVID-19, normal) ve çoklu (COVID-19, normal, pnömoni) sınıflandırma yapmak amacıyla “LiteCovidNet” modelini önermişlerdir. Önerdikleri LiteCovidNet modeli, değişken filtre boyutlarına (32 ve 64) ve 3x3 sabit çekirdek boyutuna sahip üç evrişim katmanından, ardından Doğrultulmuş Doğrusal Birim (Rectified Linear Unit (ReLU)) aktivasyon fonksiyonundan ve her evrişim katmanından sonra uygulanan maksimum havuzlama katmanından oluşmaktadır. Bu model ile çoklu sınıflandırmada %98,82 doğruluk, %98,83 kesinlik, %100 hassasiyet, %100 özgüllük ve %98,33 F1-skoru elde etmişlerdir [52].

Kim et al., akciğer grafiğini kullanarak 4 sınıflı (normal, pnömoni, pnömotoraks ve TB) sınıflandırma için uçtan uca transfer öğrenmesi tabanlı bir derin öğrenme yaklaşımı önermişlerdir. Önerdikleri yaklaşımda, önceden eğitilmiş EfficientNetV2 modeli temel alınmış, bu modele GAP, bırakma (dropout) ve yoğun katmanlar eklenmiştir. Çalışma sonunda %82,20 maksimum doğruluk, %81,40 duyarlılık ve %94,48 özgüllük elde etmişlerdir [53].

Malik et al., normal, COVID-19, pnömotoraks, pnömoni, akciğer kanseri ve TB'yi sınıflandırmak için CDC_Net adında özel bir CNN mimarisi önermişlerdir. Önerdikleri CNN mimarisi, klasik evrişim katmanlarına ek olarak artık ağlardan (residual networks), genişletilmiş evrişim katmanlarından (dilated convolution), GAP katmanı ve yoğun katmandan oluşmaktadır. Önerdikleri ağ ile 6 sınıf için sırasıyla %99,39 doğruluk, %98,13 duyarlılık, %99,42 kesinlik ve %98,26 F1-skoru elde etmişlerdir [5].

2022'de Naseem et al., akciğer hastalıklarının otomatik tespiti için transfer öğrenmesine dayalı bir yaklaşım önermişlerdir. Çalışmalarında, analizlerini 2 farklı veri kümesi kullanarak gerçekleştirmişlerdir; veri kümesi-1 normal, COVID-19, viral pnömoni ve TB sınıflarından 1500'er görüntü, veri kümesi-2 ise normal, COVID-19, viral pnömoni, bakteriyel pnömoni, TB ve pnömotoraks sınıflarından 1200'er görüntü içermektedir. Veri kümelerini oluştururken veri artırma yöntemleri kullanarak sınıflardaki görüntü sayılarını eşitlemişlerdir. Sınıflandırma için önceden eğitilmiş dokuz CNN yaklaşımını (DenseNet201, DenseNet169, DenseNet121, VGG16, VGG19, ResNet50, ResNet101, NasNet-Mobile ve MobileNetV2) kullanmışlardır. Çalışma sonunda 5 sınıf için DenseNet169 ile %94,66 doğruluğa, 6 sınıf için ise DenseNet201 ile %87,29 doğruluğa ulaşmışlardır [54].

Sharma et al. çalışmalarında COVID-MANet adını verdikleri otomatikleştirilmiş uçtan uca çok görevli dikkat ağı (end-to-end multi-task attention network) kullanarak COVID-19, normal, viral pnömoni, bakteriyel pnömoni ve TB grafiğini sınıflandırmışlardır. Önerdikleri ağ, bölütleme modeli olan U-Net ile sınıflandırma modeli olan MA-DenseNet201'i birleştirmektedir. Model eğitiminde kayıp fonksiyonu olarak kategorik çapraz entropi (KÇE) yerine ağırlıklı KÇE kullanmışlardır. Sonuç olarak geliştirdikleri COVID-MANet ile sırasıyla %95,05 doğruluk, %95,40 kesinlik, %95,05 duyarlılık ve %95,19 F1-skoru elde etmişlerdir [55].

COVID-19, pnömoni, TB ve normal akciğer grafiğini sınıflandırmak için Bhandari et al., beş evrişim katmanı, maksimum havuzlama, bırakma, düzleştirme ve yoğun katmanlardan oluşan hafif bir CNN modeli önermişlerdir. Önerdikleri model ile %94,54 genel validasyon doğruluğu elde etmişlerdir [56].

2023 yılında Ahmed et al., COVID-19, sağlıklı, pnömoni ve TB grafiğini sınıflandırmak için beş evrişim katmanı ve ardından maksimum havuzlama, bırakma, düzleştirme ve iki yoğun katmandan oluşan hafif bir CNN modeli önermişlerdir. 4 sınıf için %98,72 oranında validasyon doğruluğu elde ederek önerdikleri modelin literatürdeki en gelişmiş tekniklerden daha iyi performans gösterdiğini öne sürmüşlerdir [57].

Emara et al. tarafından görüntü detaylarını iyileştirmek için süper çözünürlük tekniğini, öznetelik çıkarımı için InceptionResNetV2'yi ve sınıflandırma için çok sınıflı destek vektör makinesini entegre eden bir model önerilmiştir. Geliştirilen modelin performans değerlendirmesi için 2 farklı veri kümesi kullanılmıştır. Çalışma sonucunda, COVID-19, TB, viral pnömoni, bakteriyel pnömoni ve normal grafiğini içeren veri kümesi 1 için sırasıyla %96,8 doğruluk, %97,47 duyarlılık, %98,78 özgüllük, %97,01 kesinlik ve %96,86 F1-skoru; COVID-19, akciğer opasitesi, TB, viral pnömoni ve normal grafiğini

içeren veri kümesi 2 için ise sırasıyla %93,45 doğruluk, %92,76 duyarlılık, %98,58 özgüllük, %92,51 kesinlik ve %90,56 F1- skoru elde edilmiştir [58].

Iqbal et al., normal, TB, pnömoni ve COVID-19 sınıflarını ayırtmak amacıyla yeni bir derin öğrenme modeli önermişlerdir. Önerdikleri model, genişletilmiş füzyon bloğu ve dikkat mekanizmasına dayalı bir bölütleme ağı (TB-UNet) ile, beş ikili evrişim bloğu ve DenseNet169 üzerine kurulu bir sınıflandırma ağının (TB-DenseNet) birleşiminden oluşmaktadır. Bu birleşik yapı ile %95,10 doğruluk, %95,67 kesinlik, %95,10 duyarlılık ve 95,38 F1-skoru elde etmişlerdir [13].

Indumathi et al., COVID-19, pnömoni, fibröz, TB ve normal grafileri sınıflandırmak için hibrit çift yönlü LSTM (Bi-Directional LSTM)-Maske Bölgesi Tabanlı CNN (Mask Region-Based CNN) modeli önermişlerdir. Çalışma sonunda önerdikleri metodoloji ile normalize edilmiş ve histogram eşitleme uygulanmış görüntüleri kullanarak 5 sınıf için %98,71 doğruluk, %98,78 kesinlik, %97,82 duyarlılık ve %98,38 F1-skoru elde etmişlerdir [59].

Bhuiyan et al., normal, COVID-19, pnömoni ve TB olmak üzere dört sınıfa ait akciğer grafilерinin sınıflandırılması amacıyla, yumuşak dikkat mekanizması (soft attention mechanism) içeren özel bir CNN modeli önermişlerdir. Çalışmada ilk olarak görüntülerin kalitesini artırmak amacıyla ön işleme teknikleri uygulamışlardır. Ardından, dört evrişim katmanı, altı maksimum havuzlama katmanı, bir yumuşak dikkat katmanı, bir bırakma katmanı ve bir yoğun katmandan oluşan özel bir CNN mimarisi geliştirerek %95,19 doğruluk, %96,49 kesinlik ve %95,13 F1-skoru elde etmişlerdir [60].

2023 yılında Malik et al. tarafından dokuz farklı akciğer hastalığının (COVID-19, akciğer kanseri, atelettazi, konsolidasyon, TB, pnömotoraks, ödem, pnömoni, plevral kalınlaşma) ve normal görüntülerin sınıflandırılması için yeni bir füzyon modeli geliştirilmiştir. Önerilen model üç ana aşamadan oluşmaktadır. İlk aşamada Info-MGAN (Information Maximizing GAN) ağı kullanılarak akciğer bölgeleri otomatik olarak bölütlenmiştir. İkinci aşamada bölütlenen görüntülerden SURF (speeded- up robust features) ve ORB (Oriented FAST and Rotated BRIEF) yöntemleriyle el ile ayırt edici öznitelikler çıkartılmıştır. Üçüncü aşamada ise sekiz farklı önceden eğitilmiş ağ (ResNet101, ResNet50, DenseNet169, DenseNet201, InceptionV3, VGG16 ve VGG19) kullanılarak öznitelikler elde edilmiştir. Son olarak, hem el ile çıkartılan hem de önceden eğitilmiş CNN'lerden çıkartılan öznitelikler birleştirilerek farklı makine öğrenmesi algoritmalarıyla sınıflandırma yapılmıştır. En yüksek doğruluk değeri olan %98,20, VGG19 ile çıkarılan derin

özniteliklerin ORB öznitelikleriyle birleştirilip softmax sınıflandırıcı ile sınıflandırılması sonucunda elde edilmiştir [61].

Oh et al. dört akciğer patolojisini (pnömoni, pnömotoraks, TB ve akciğer kanseri) ve normal grafileri ayırtırmak için EfficientNet tabanlı bir model önermişlerdir. Analizlerini Soonchunhyang Üniversitesi Hastanesi'nden topladıkları ve her sınıftan 1000 akciğer grafisi içeren veri kümesini kullanarak gerçekleştirmişlerdir. Önerdikleri modelde, önceden eğitilmiş EfficientNet-B7 mimarisi omurga olarak kullanılmış ve ardından ince ayar katmanları eklenmiştir. Sonuç olarak %97,42 ortalama test doğruluğu, %95,93 duyarlılık ve %99,05 özgüllük elde etmişlerdir [62].

Sultana et al. tarafından üç evrişim katmanının ardından eklenen maksimum havuzlama, düzleştirme, bırakma ve tam bağlı katmanlardan oluşan bir CNN mimarisi önerilmiştir. Model, COVID-19, normal, viral pnömoni, bakteriyel pnömoni, fibroz, akciğer opasitesi ve TB olmak üzere yedi sınıftan oluşan bir akciğer grafisi veri kümesi üzerinde değerlendirilmiştir. Ek olarak, modelin performansının değerlendirilmesi amacıyla 2, 3, 4, 5, 6 ve 7 sınıf içeren alt veri kümeleriyle de testler yapılmıştır. Önerilen mimari, VGG16, VGG19 ve InceptionV3 modelleriyle karşılaştırılmış ve elde edilen sonuçlar, önerilen modelin bu CNN mimarilerinden üstün performans sergilediğini ortaya koymuştur [63].

1.2.2. Akciğer grafilерinin sınıflandırılması için önerilen dikkat ağıları

Dikkat mekanizmalarının ve dikkat tabanlı dönüştürücülerin sinir ağılarına entegre edilmesi üzerine yapılan çalışmalar 1980'li yılların sonlarına dayanmaktadır. Görüntü sınıflandırması için dikkat mekanizmalarının kullanımıysa ilk olarak 2010 yılında kısıtlı Boltzmann makinesine eklenen dikkat bileşeni ile başlamıştır. 2015 yılı ise dikkat ağılarının farklı görevler için pek çok derin ağı ile birlikte kullanıldığı altın çağ olarak bilinmektedir [64]. 2015 yılından bu yana akciğer grafilерinin sınıflandırılması için önerilen birçok derin sinir ağı uygulamasında dikkat ağıları ve dönüştürücüler kullanılmış, sınıflandırma başarısı açısından umut verici sonuçlar elde edilmiştir.

2021 yılında Afifi et al. tarafından yapılan çalışmada sağlıklı, pnömoni ve COVID-19 grafilерini sınıflandırmak amacıyla dikkat ağı tabanlı bir model önerilmiştir. Çalışmada ilk olarak RetinaNet kullanılarak akciğer görüntüleri kırpılmış, daha sonra kırpılan görüntüler öznitelik piramit ağı (feature pyramid network) ile bölütlenmiştir. Bölütlenme sonucunda elde edilen akciğer bölgelerinden DenseNet161 kullanılarak küresel öznitelikler, DenseNet161 ve dikkat tabanlı yerel öznitelik çıkarıcı kullanılarak yerel öznitelikler

ıkartılmıřtır. ıkartılan znitelikler softmax aktivasyonuna sahip ek bir evriřim katmanıyla sınıflandırılmıřtır. nerilen model ile %91,2 doęruluk, %92,4 kesinlik ve %91,9 F1-skoru elde edilmiřtir [65].

Fan et al. tarafından 2021 yılında COVID-19'un tespiti amacıyla gerekleřtirilen alıřmada, ok ekirdek boyutlu uzamsal-kanal dikkat (multi-kernel-size spatial-channel attention) mekanizmasına dayalı bir yntem nerilmiřtir. Bu yntemde, akcięer grntlerinden elde edilen znitelik haritalarına farklı boyutlardaki ekirdeklerle (kernel) hem 1 boyutlu hem de 2 boyutlu evriřim iřlemleri uygulanarak kanal ve uzamsal dikkat haritaları oluřturulmuřtur. Elde edilen bu znitelik haritaları birleřtirilmiř, ardından tam baęlı katman ve softmax sınıflandırıcı ile sınıflandırma iřlemi gerekleřtirilmiřtir. Sonu olarak, nerilen model COVID-19 tespitinde %97,82 doęruluk saęlamıřtır. Bununla birlikte alıřma sonucunda, dikkat bileřenlerinin evriřimsel blok dikkat modlnde (Convolutional Block Attention Module (CBAM) [66])) olduęu gibi sıralı řekilde uygulanması yerine ayrı ayrı uygulanarak ıkartılan znitelik haritalarının birleřtirilmesinin sınıflandırma bařarısını artırdıęı gsterilmiřtir [67].

Aynı yıl Li et al. tarafından COVID-19, pnmoni ve saęlıklı akcięer grntlerini sınıflandırmak iin yapılan alıřmada bařlangı modeli olarak farklı boyutlarda znitelik haritalarını ıkartmak iin ResNet50 kullanılmıřtır. ıkartılan farklı boyutlardaki znitelik haritalarına ok lekli dikkat aęı uygulanarak dikkat haritaları elde edilmiřtir. znitelik haritaları ve dikkat haritaları dikkat havuzlaması (attention pooling) yntemi ile birleřtirilerek sonu znitelik haritası ıkartılmıřtır. Bu model ile yapılan l sınıflandırmada %87,12 doęruluk elde edilmiřtir. alıřmada dikkat haritalarının, giriř grntsndeki bilgi tařıyan kısımları etkili bir řekilde vurguladıęı sonucuna varılmıřtır [68].

COVID-19'un karakteristik radyografik bulgularını adaptif řekilde ıkarabilen uyarlanabilir dikkat aęı (Adaptive Attention Network) 2021 yılında Lin et al. tarafından COVID-19, pnmoni ve saęlıklı akcięer grafilelerini sınıflandırmak amacıyla geliřtirilmiřtir. alıřmada  farklı aık eriřimli veri kmesi kullanılmıřtır. nerilen aę yapısında, lezyonların farklı řekillerine uyum saęlayabilmek iin deforme olabilen bir ResNet mimarisi tasarlanmıř, lezyon blgelerinin tespiti ve ilgisiz bilgilerin elenmesi amacıyla dikkat tabanlı bir kodlayıcı entegre edilmiřtir. Elde edilen znitelikler, tam baęlı katman ve softmax kullanılarak sınıflandırılmıřtır. alıřma sonucunda model  farklı veri kmesi iin ortalama %94,36 doęruluk oranına ulařarak bařarılı bir performans sergilemiřtir [69].

Aynı yıl Duong et al. tarafından yapılan çalışmada akciğer grafilerinden TB tespiti için farklı EfficientNet ve ViT mimarilerinin hibrit olarak kullanılmasına dayanan bir yöntem önerilmiştir. Yapılan üçlü sınıflandırma çalışmalarında (normal, TB, pnömoni) ViT-B/16 ve EfficientNet-B1 yapılarının birlikte kullanılmasıyla en yüksek doğruluk olan %97,72 değeri elde edilmiştir. Çalışmada farklı transfer öğrenmesi yaklaşımları da değerlendirilmiş, en iyi transfer öğrenmesi yaklaşımının ImageNet ile eğitilen ağırlardan elde edilen ağırlıkların kullanılması olduğu sonucuna varılmıştır [70].

2021 yılında Shome et al. tarafından yapılan çalışmada COVID-19, pnömoni ve sağlıklı akciğer grafilerini ayırtmak için ViT tabanlı bir derin öğrenme ağı önerilmiştir. Çalışmada ImageNet ile önceden eğitilmiş 16×16 yama boyutuna sahip “Large” varyantı olan ViT-L/16 modeli kullanılmış, ancak önceden eğitilmiş çok katmanlı algılayıcı (Multi Layer Perceptron (MLP)) tahmin bloğu kaldırılarak Gauss hatası doğrusal birimi (Gaussian error linear unit (GeLU)) tabanlı yeni bir MLP bloğu eklenmiştir. Çalışma sonunda üçlü sınıflandırmada %92 doğruluk, %93 kesinlik, %89 duyarlılık, %91 F1-skoru, 0,98 AUC elde edilmiştir. Ayrıca, GeLU aktivasyonunun, dönüştürücü kodlayıcıların çıkışlarını işlemede ReLU aktivasyonuna kıyasla daha etkili olduğunu gösterilmiştir [71].

2022 yılında Kong et al. tarafından yapılan çalışmada COVID-19, pnömoni ve normal görüntüleri sınıflandırmak DenseNet ve VGG16 ağlarının birleşimine dayalı bir model önerilmiştir. Önerilen bu ağı derin öznitelik çıkarımını güçlendirmek amacıyla küresel dikkat makine bloğu (Global Attention Machine Block) ve kategori dikkat bloğu (Category Attention Block) eklenmiştir. Sonuç olarak üçlü sınıflandırma için %97,3 doğruluk elde edilmiştir [72].

2022 yılında yapılan farklı bir çalışmada COVID-19, pnömoni ve sağlıklı görüntüleri sınıflandırmak için Liu et al. tarafından, EfficientNetV2 ve ResNet101 ağlarından çıkartılan özniteliklerin birleşimini sağlayan derin öznitelik füzyon modülü ve çoklu hastalık sınıflandırma modülünden oluşan derin öznitelik füzyon sınıflandırma ağı (deep feature fusion classification network) önerilmiştir. Önerilen ağda öznitelik çıkarımının doğruluğunu artırmak için ResNet101’e CBAM eklenmiştir. İki farklı ağdan çıkartılıp birleştirilen öznitelikler destek vektör makineleri kullanılarak sınıflandırılmıştır. Sonuç olarak %99,89 sınıflandırma doğruluğu elde edilmiştir [73].

2022 yılında Chetoui et al. tarafından yapılan çalışmada akciğer grafilerinden COVID-19 tespiti için farklı ViT modellerinin performansları incelenmiştir. ViT-B/16, ViT-B/32 ve ViT-L/32 mimarileri kullanılarak yapılan üçlü sınıflandırma (COVID-19, pnömoni, sağlıklı)

sonucunda en yüksek performans ViT-B/32 modeli ile elde edilmiş, %96 doğruluk, 0,99 AUC, %96 hassasiyet, %96 özgüllük raporlanmıştır [74].

Okolo et al. tarafından 2022 yılında sunulan çalışmada akciğer grafilerinin sınıflandırılması için farklı ViT modellerinin performansları değerlendirilmiş ve bunlara ek olarak, Girdi Gelişmiş ViT (Input Enhanced ViT) adı verilen yeni bir model önerilmiştir. Bu model, çeşitli akciğer patolojilerinin tespitinde daha yüksek sınıflandırma performansı sağlamayı hedeflemektedir. Dört farklı veri kümesi kullanılarak yapılan sınıflandırma çalışmaları sonucunda (üç farklı ikili ve bir üçlü sınıflandırma) önerilen modelin ViT modellerinden daha iyi performans gösterdiği ortaya konmuştur [75].

2022 yılında yaptıkları çalışmada Usman et al., CheXpert ve pediatrik pnömoni veri kümelerindeki akciğer grafilerini sınıflandırmak amacıyla önceden eğitilmiş bir ViT modeli kullanmışlardır. Çalışma kapsamında, CheXpert veri kümesi üzerinde uygulanan ViT modelinin, VGG16 ve ResNet gibi önceden eğitilmiş CNN tabanlı mimarilere kıyasla daha yüksek performans sergilediği gösterilmiştir. Ayrıca, önceden eğitilmiş modeller ile sıfırdan eğitilen modeller karşılaştırılmış ve transfer öğrenmesinin sınıflandırma başarısını artırdığı sonucuna ulaşılmıştır [76].

Yi et al., normal, COVID-19, viral pnömoni, bakteriyel pnömoni ve TB'yi sınıflandırmak amacıyla RED-CNN adlı bir model önermişlerdir. Önerdikleri model, Res2Net modülü, etkin kanal dikkat (Efficient Channel Attention) modülü ve Double BlazeBlock modülünden oluşan RED adını verdikleri bloklardan oluşmaktadır. Çalışma sonucunda önerdikleri metodolojiyle 5 sınıf için sırasıyla %97,796 doğruluk, %92,062 kesinlik, %91,796 duyarlılık ve %91,892 F1- skoru elde etmişlerdir [14].

Li et al. tarafından akciğer grafilerinin sınıflandırılması amacıyla yama düzeyindeki öznetelikleri ve yamalar arası ilişkileri modelleyebilen, CNN ve ViT mimarilerinin entegrasyonuna dayalı bir yöntem önerilmiştir. Çalışmada, DenseNet tabanlı çok katmanlı bir piramit yapı aracılığıyla öznetelik çıkarımı yapılmış, ardından ViT ile görüntülerin küresel bağlamsal bilgisi elde edilmiştir. Elde edilen bu öznetelikler hem yerel hem de küresel bağımlılıkları dikkate alan özel bir füzyon modülüyle birleştirilmiştir. ChestX-ray14 veri kümesi kullanılarak geliştirilen bu model ile ortalama %81,4 doğruluk, %42,2 kesinlik, %71,4 hassasiyet, %50,3 F1-skoru ve %82,9 AUC değerlerine ulaşılmıştır [77].

2022 yılında Mabrouk et al. tarafından yapılan çalışmada ImageNet ile önceden eğitilmiş DenseNet169, MobileNetV2 ve ViT mimarilerinin çıkışında elde edilen özneteliklerin birleştirilmesi sonucunda pnömoni tespiti yapan bir yöntem önerilmiştir.

Çalışma sonunda ikili sınıflandırmada %93,91 doğruluk, %93,96 kesinlik, %92,99 duyarlılık, %93,43 F1-skoru elde edilmiştir [78].

Cannata et al. tarafından COVID-19, akciğer opasitesi, viral pnömoni ve sağlıklı grafilerin sınıflandırılması amacıyla yapılan çalışmada InceptionV3, ResNet50, Xception ve ViT mimarilerinin performansları karşılaştırılmıştır. Üç farklı CNN mimarisi arasında en yüksek doğruluk %85,58 ile ResNet50 tarafından elde edilmiştir. Ancak ViT-B/32 mimarisi kullanılarak %99,30 doğruluk elde edilmiş ve ViT modelinin diğer mimarilere kıyasla daha üstün bir performans sergilediği gösterilmiştir. Ayrıca ViT ile gerçekleştirilen dörtlü sınıflandırma sonucunda, ortalama %93,75 kesinlik, %94,25 duyarlılık ve %94,25 F1-skoru değerleri raporlanmıştır [79].

2022 yılında Cao et al. tarafından COVID-19'un tespiti için özel bir evrişim modeli ile dönüştürücü yapısını birleştiren üç aşamalı bir füzyon ağı önerilmiştir. Bu modelde yerel öznitelikler evrişim modülü ile çıkartılırken küresel öznitelikler dönüştürücü tarafından çıkartılmaktadır. Daha sonra çıkartılan öznitelikler birleştirilerek sınıflandırma yapılmaktadır. Çalışma sonucunda kurulan ağ ile üçlü sınıflandırmada (COVID-19, pnömoni, sağlıklı) %97,09 doğruluk, %97,16 kesinlik, %96,93 duyarlılık, %97,04 F1-skoru elde edilmiştir [80].

Park et al. tarafından yapılan çalışmada farklı kaynaklardan alınan akciğer grafileri kullanarak COVID-19'un tespiti ve şiddetinin belirlenmesi için “Multi-task ViT” adlı yeni bir yaklaşım önerilmiştir. Bu yaklaşımda, akciğer grafilerindeki konsolidasyon, opasite ve ödem gibi yaygın anormal bulguları ayıklamak için büyük genel veri kümeleri üzerinde eğitilmiş bir omurga ağından yararlanılmaktadır. DenseNet temelli bu ağdan çıkartılan öznitelikler dönüştürücülere verilerek sınıflandırma yapılmaktadır. Farklı veri kümeleri kullanılarak yapılan sınıflandırma sonucunda geliştirilen Multi-task ViT'in olağanüstü genelleme yeteneği sergilediği gösterilmiştir [81].

Ukwuoma et al. tarafından pnömoni, COVID-19 ve akciğer kanserinin sınıflandırılması amacıyla “Akciğer Hastalığı Tanımlaması için Akciğer Grafisi Görüntü Tabanlı Özellik Çıkarma Çerçevesi” adlı bir yöntem geliştirilmiştir. Önerilen model, ayırt edici özniteliklerin çıkarımı için DenseNet201, VGG16 ve GoogLeNet gibi CNN tabanlı mimariler ile küresel ikinci dereceden ortalama havuzlama katmanını ve ViT yapısını bir araya getirmektedir. Bu çalışmada iki farklı veri kümesi, iki farklı öğrenme oranı ve iki farklı kayıp fonksiyonu kullanılarak performans karşılaştırmaları yapılmıştır. Çalışma sonunda COVID-19 Radyografi veri kümesi için (normal, pnömoni, COVID-19, opasite) %98 doğruluk, %96,21 kesinlik, %96,02 hassasiyet, %96,03 F1-skoru elde edilirken; Covid-

ChestX-ray-15k (normal, pnömoni, COVID-19) veri kümesi için %98,19 doğruluk, %97,29 kesinlik, %97,29 duyarlılık, %97,29 F1-skoru elde edilmiştir [82].

Mondal et al. tarafından önerilen xViTCOS modeli, akciğer grafilerinden ve bilgisayarlı tomografi (BT) görüntülerinden COVID-19 tespiti için görü dönüştürücüleri kullanmıştır. Bu modelde, ViT-B/16 temel alınmıştır, ek olarak veri kıtlığı sorununu ele almak için çok aşamalı bir transfer öğrenmesi tekniği önerilmiştir. Model parametreleri, ImageNet-21k ile önceden eğitilip, ImageNet-2012 ve CheXpert ile ince ayar yapılarak belirlenmiştir. Çalışma sonunda üçlü sınıflandırma için %96 doğruluk, %96,5 kesinlik, %95,9 duyarlılık, %96,1 F1 kuru, %97,7 özgüllük elde edilmiştir [83].

2022 yılında TB tespiti için Rajaraman et al. tarafından yapılan çalışmada CNN ve ViT modellerinin yaptığı tahminlerin farklı topluluk yöntemleri ile birleştirilmesiyle bir model geliştirilmiştir. Çalışmada çeşitli CNN ve ViT modellerinin ayrı ayrı ve/veya farklı topluluk yöntemleri ile birleştirilmesi sonucu analizler yapılmıştır. En iyi performans DenseNet121 ve ViT-B/32'nin tahminlerinin Sıralı En Küçük Kareler Kuadratik Programlama (Sequential Least-Squares Quadratic Programming) tabanlı ağırlıklı ortalama yöntemi ile birleştirilmesiyle elde edilmiştir. Çalışma sonucunda her iki yöntemin birleştirilmesiyle elde edilen başarının, farklı CNN ağlarının ve farklı ViT modellerinin ayrı ayrı elde ettikleri başarıdan daha yüksek olduğu gösterilmiştir [84].

Aynı yıl COVID-19 tespiti ve derecelendirilmesi (seviye 1, seviye 2) için Le Dinh et al., beş farklı derin öğrenme modelini analiz etmişlerdir. Çeşitli açık erişimli veri tabanlarından elde edilen görüntüler ile oluşturdukları özelleştirilmiş veri kümesi ile üç CNN (DenseNet121, ResNet50, InceptionNet), iki dönüştürücü (Swin dönüştürücü, Hybrid EfficientNet-DOLG) modeli eğitmişlerdir. Çalışma sonunda dönüştürücü modellerinin CNN modellerinden daha iyi performans gösterdiğini ortaya koymuşlardır [85].

2023 yılında Nafisah et al., COVID-19 tespiti için farklı CNN ve ViT modellerinin performanslarını değerlendirmişlerdir. Çalışmada, EfficientNet-B0, ResNet ve MobileNet gibi CNN mimarileri ile SegFormer, Twins ve Swin dönüştürücü gibi ViT tabanlı modeller kullanılarak üçlü sınıflandırma gerçekleştirmişlerdir. Ayrıca, görüntü bölütleme ve veri artırma tekniklerinin sınıflandırma başarısına etkisini araştırmışlardır. Çalışma sonunda veri bölütleme ve veri artırma tekniklerinin uygulandığı dengeli veri kümesi üzerinde en yüksek performansın (%99,82 doğruluk, %99,72 duyarlılık, %99,72 kesinlik ve %99,72 F1-skoru) EfficientNet-B7 modeli ile elde edildiğini göstermişlerdir [86].

Yang et al. tarafından sunulan çalışmada COVID-19 teşhisi yapmak amacıyla dönüştürücü ve öz-dikkat (self-attention) mekanizmasını kullanan “Covid-Vision-

Transformers” isimli bir ağ önerilmiştir. Çalışma sonucunda sunulan ağ ile %98,2 sınıflandırma doğruluğu elde edilmiştir. Ek olarak çalışma sonunda dönüştürücülerin, birbirinden uzak pikseller arasındaki ilişkileri daha etkili bir şekilde modelleyebilme yeteneği sayesinde, COVID-19 teşhisi gibi görevlerde CNN'lere kıyasla daha avantajlı olabileceği tartışılmıştır [87].

Chen et al. tarafından COVID-19 tespiti için ResNet50 tabanlı yeni bir sınıflandırma ağı olan BoT-ViTNet'i önerilmiştir. Önerilen modelde, ResNet50 modelinin ilk üç aşamasının sonuna çok başlı öz dikkat (multi-head self-attention (MHSA)) yapısı entegre edilmiş, son kısımlara ise dönüştürücü ve darboğaz katmanlarından oluşan TRT-ViT blokları eklenmiştir. Elde edilen öznitelikler GAP katmanına iletilerek sınıflandırma yapılmıştır. Çalışma sonunda üç sınıf (COVID-19, sağlıklı, pnömoni) için %98,91 doğruluk, %97,80 kesinlik, %98,76 hassasiyet, %99,12 özgüllük ve %98,27 F1-skoru elde edilmiştir [88].

2023 yılında Almalki et al. tarafından gerçekleştirilen çalışmada, Swin dönüştürücünün COVID-19'u tespit etme performansı değerlendirilmiştir. Bu değerlendirme için COVID-19, akciğer opasitesi, pnömoni ve sağlıklı akciğer grafileleri kullanılmıştır. Çalışma kapsamında Swin dönüştürücüye iki bırakma ve iki yoğun katman eklenerek model modifiye edilmiş, elde edilen performans sekiz farklı derin öğrenme modeliyle (ResNet50, DenseNet121, InceptionV3, EfficientNet-B2, VGG19, MobileNet, ViT, CaIT) karşılaştırılmıştır. Çalışma sonunda Swin dönüştürücünün %96,6 doğruluk ile diğer CNN tabanlı modellerden daha yüksek performans sergilediğini ortaya konmuştur [89].

2023 yılında yaptıkları çalışmada Marefat et al., akciğer grafilelerinden COVID-19 tespiti yapmak hem CNN hem de ViT tabanlı modellerin kombinasyonu olan Kompakt Evrişimli Dönüştürücü (Compact Convolutional Transformers) mimarisini kullanmışlardır. Böylece bazı durumlarda, özellikle belirgin çizgi veya sınırlar içermeyen görüntülerden, anlamlı öznitelikler çıkaramayan CNN'ler ve genellikle sıralı verilerde iyi çalışırken, görüntü işlemede konumsal bilgi bulmak için ek işlemlere ihtiyaç duyan dönüştürücüler birleştirilerek iki yöntemin kısıtlarının önüne geçilmiştir. Çalışma sonunda önerilen model akciğer grafilelerinden COVID-19 tespiti için literatürdeki çalışmalardan yüksek olarak %99,2 oranında doğruluk sunmuştur [90].

Wang et al. tarafından yapılan çalışmada akciğer grafilelerinden COVID-19 tespiti amacıyla ResNet18 ve ViT modellerinin birleşiminden oluşan PneuNet adlı bir sınıflandırma modeli önerilmiştir. Modelde ResNet18, uzamsal öznitelikleri çıkarmak için omurga olarak kullanılmıştır. Klasik ViT yaklaşımından farklı olarak, elde edilen öznitelikler yamalara bölünmeden, maksimum havuzlama ile boyutu küçültülmüş tek bir yama şeklinde modele

verilmiştir. Bu öznetelikler kodlanıp gömüldükten sonra MLP ile sınıflandırma gerçekleştirilmiştir. COVID-19, bakteriyel pnömoni, viral pnömoni ve pnömoni olmayan görüntüler kullanılarak yapılan dörtlü sınıflandırma çalışmalarında %90,03 doğruluk, %89,58 kesinlik, %89,62 duyarlılık ve %89,59 F1-skoru elde edilmiştir [91].

Mezina and Burget, tarafından 2024 yılında COVID-19 enfeksiyonu sonrasında gelişen akciğer hastalıklarının teşhisine yönelik bir derin öğrenme modeli önerilmiştir. Önerilen model küresel öznetelikleri yakalamak amacıyla tasarlanan Inception tabanlı bir modül ve yerel öznetelik analizini gerçekleştiren Inception ile ViT bileşenlerinin hibrit olarak kullanıldığı bir modülden oluşmaktadır. Çalışmada, yalnızca ChestX-ray14 veri kümesinden elde edilen veriler kullanılarak, COVID-19 sonrası görülen dokuz farklı akciğer patolojisinin sınıflandırılması hedeflenmiştir. Modelin performansı, literatürde yaygın olarak kullanılan VGG19, DenseNet121, EfficientNetB4, InceptionV3 ve ResNet101 gibi mimarilerle karşılaştırılmış, sonuç olarak önerilen modelin elde edilen 0,819 AUC, %73,6 doğruluk, %76,83 duyarlılık ve %72,21 özgüllük değerleriyle bu yöntemlere kıyasla daha başarılı olduğu gösterilmiştir [92].

1.2.3. Akciğer grafilerinin sınıflandırılması için kullanılan kayıp fonksiyonları

Önceden eğitilmiş ya da sıfırdan kurulmuş ağlar ile yapılan sınıflandırma çalışmalarında KÇE en sık kullanılan kayıp fonksiyonudur [20]. Bunun yanında son yıllarda çapraz entropinin geliştirilmesi veya başka kayıp fonksiyonlarıyla birleştirilmesi sonucunda farklı kayıp fonksiyonlarının ortaya çıktığı ve bu fonksiyonların sınıflandırma performansını olumlu yönde etkilediği görülmektedir [15], [19], [20], [28], [68], [93].

Xu et al. tarafından yapılan çalışmada akciğer grafileri üzerinden tanı koymadaki başlıca iki zorluğun görüntülerden ayırt edici özneteliklerin çıkartılması ve dengesiz veri dağılımı problemi olduğu belirtilmiştir. Çalışmada ayırt edici özneteliklerin çıkartılması sorununun üstesinden gelmek amacıyla DeepCXray adlı derin bir sinir ağı önerilmiştir. Önerilen DeepCXray ham görüntülerden öznetelikleri çıkartırken InceptionV3 modelini kullanmaktadır. Ek olarak dengesiz veri dağılımı probleminin üstesinden gelmek için pozitif örneklerin negatif örneklere oranını otomatik olarak ağırlıklandıran çapraz entropi kaybına dayalı bir kayıp fonksiyonu önerilmiştir. Çalışma sonucunda bu özgün kayıp fonksiyonunun özellikle az örnek içeren sınıflarda, yaygın olarak kullanılan ağırlıklı çapraz entropi kaybına göre daha başarılı sonuçlar verdiği, ChestX-ray14 veri kümesi üzerinde gösterilmiştir [32].

Yine 2018 yılında yapılan çalışmada Qin et al. tarafından derin öğrenme alanındaki hızlı gelişmelerin akciğer hastalıklarının otomatik teşhisini iyileştirdiği ancak eğitim sırasında gerçek hayattaki farklı morbidite nedeniyle veri sayılarında kaçınılmaz olarak dengesizlik (farklı patolojilerin miktar sorunu) problemi yaşandığı belirtilmiştir. Bu bağlamda derin öğrenme çalışmalarında sıklıkla kullanılan odak kaybı (focal loss) fonksiyonunu temel alan, ancak modelin zor örneklerle ve az veri sayısı içeren hastalık sınıflarına daha fazla dikkat etmesini sağlayan, kaybı kolay negatiflerin etkisinden koruyan ağırlıklandırılmış odak kaybı (weighted focal loss) fonksiyonu önerilmiştir. ChestX-Ray14 veri kümesi ile yapılan çalışmada AlexNet, InceptionV3 ve ResNet modelleri kullanılmış ve sonuçta önerilen ağırlıklandırılmış odak kaybı ile ağırlıklandırılmış çapraz entropiye göre daha yüksek performans elde edilmiştir. Elde edilen AUC değerleri odak kaybından daha düşük olsa da az veri sayısına sahip veri etiketlerinde, ağırlıklandırılmış odak kaybının daha iyi ayırıştırma yaptığı gösterilmiştir [94].

2019 yılında yapılan çalışmada Chen et al., akciğer grafilerini sınıflandırma amacıyla DualCheXNet adını verdikleri, DenseNet ve ResNet mimarilerini birleştiren ikili bir asimetrik öznitelik öğrenme ağı önermişlerdir. Çalışmada üç farklı sınıflandırıcının (DenseNet, ResNet, birleşim) kararlarını alternatif bir şekilde birleştiren ağırlıklandırılmış ve modülasyon faktörü içeren bir kayıp fonksiyonu geliştirmişlerdir. Bu yapı, modelin zor örnekler üzerinde daha fazla odaklanmasını sağlamış ve eğitim sürecinin daha hızlı yakınsamasına katkı sunmuştur. Çalışma sonunda önerilen yaklaşımın, ChestX-ray14 veri kümesinde hastalık sınıflandırma performansını artırmada etkili olduğunu göstermişlerdir [95].

Xu et al. tarafından yapılan çalışmada önceden eğitilmiş derin ağlarda ince ayar yapmaktansa veriye uygun daha az katmanlı bir ağ kurmanın akciğer grafilerini sınıflandırmada daha iyi performans göstereceği öne sürülmüştür. Bu amaçla ChestX-Ray14 veri kümesi kullanılarak normal/anormal (sağlıklı/hasta) ayrımı yapan bir CNN modeli geliştirilmiştir. Ek olarak sin-loss adlı, yanlış sınıflandırılmış ve ayırt edilemeyen görüntülerden ayırt edici bilgileri öğrenebilen yeni bir kayıp fonksiyonu önerilmiştir. Çalışma sonucunda sin-loss kullanılan az katmanlı model ile yapılan sınıflandırmanın ResNet50 ve çapraz entropi kullanılarak yapılan sınıflandırmaya göre daha iyi doğruluk, F1-skoru ve AUC değeri elde ettiği gösterilmiştir [96].

2020 yılında Ge et al. tarafından sunulan çalışmada akciğer grafilerinden hastalık tespit performansını artırmak amacıyla ikili çapraz entropi kaybına ek olarak, tüm derin öğrenme modellerinde uygulanabilir iki yeni kayıp fonksiyonu önerilmiştir. Bunlardan ilki Çok

Etiketli SoftMax Kaybı (Multi-label SoftMax Loss) pozitif hastalık etiketlerinin mevcut ve yok olması (negatif hastalık etiketleri) arasındaki bağımsızlıkları dikkate almak ve farklı sınıflar arasındaki kaybı en aza indirmek için önerilmiştir. İkinci kayıp fonksiyonu olan Korelasyon Kaybı (Correlation Loss) ise çok etiketli görüntülerde pozitif hastalık sınıfları arasındaki ilişkileri modelleyerek bu sınıflar arasında daha etkili öğrenmeyi hedeflemektedir. Bu kayıp fonksiyonlarının ikili çapraz entropi kaybıyla ağırlıklandırılarak toplanması ile elde edilen toplam kayıp fonksiyonu ile yapılan model (ResNet101 ve DenseNet121) eğitimleri sonucunda, önerilen fonksiyonun ChestX-ray14 veri kümesi için ikili çapraz entropiye göre performans iyileşmesi sağladığı kanıtlanmıştır [97].

2021 yılında Rajaraman et al. tarafından sağlıklı, viral pnömoni ve bakteriyel pnömoni akciğer grafilerini sınıflandırmak amacıyla EfficientNet tabanlı bir model önerilmiştir. Çalışmada ilk olarak akciğer bölgelerinin otomatik olarak çıkartılması amacıyla EfficientNet-B0 tabanlı bir U-Net modeli kullanılmıştır. Daha sonra eğitilmiş EfficientNet-B0 modeline sınıflandırma katmanları eklenerek nihai model oluşturulmuştur. Ayrıca, mevcut kayıp fonksiyonlarının sınırlılıklarını gidermek çeşitli kayıp fonksiyonları da önerilmiştir, bunlar: (i) Entropi bazlı düzenlemeyle KÇE kaybı; (ii) Kalibre edilmiş negatif entropi kaybı, (iii) Kalibre edilmiş Kullback-Leibler sapma (Kullback-Leibler Divergence (KL Sapma)) kaybı; (iv) Kalibre edilmiş kategorik odak kaybı ve (v) Kalibre edilmiş kategorik hinge (KH) kaybıdır. Bu fonksiyonlarda kullanılan kalibrasyon terimi, modelin yalnızca düşük kayıp değerlerine değil, aynı zamanda tahminlerin gerçek doğrulukla ne ölçüde örtüştüğüne de odaklanmasını sağlamayı amaçlamaktadır. On iki farklı kayıp fonksiyonunu performansının değerlendirildiği çalışmanın sonucunda en yüksek performansın kalibre edilmiş KÇE kaybı ile elde edildiği gösterilmiştir [98].

Taresh et al. tarafından COVID-19 tespiti için, MobileNet tabanlı otomatik bir uçtan uca derin öğrenme modeli önerilmiştir. Çalışmada ilk olarak akciğer grafilerinin kalitesini artırmak ve sınıflandırma başarısını desteklemek amacıyla görüntülere adaptif medyan filtre ve yerel-olmayan ortalama filtreleme ve kontrast sınırlı adaptif histogram (Contrast Limited Adaptive Histogram Equalization (CLAHE)) eşitleme gibi ön işleme teknikleri uygulanmıştır. Modelin eğitimi sırasında, sınıflandırma başarımını artırmak ve daha verimli temsiller elde etmek amacıyla, KÇE kaybına ek olarak KL sapma kaybı da kullanılmıştır. Bu iki kayıp fonksiyonu hibrit bir yapı ile birleştirilerek modelin hem doğruluk hem de genel ayırım performansı artırılmaya çalışılmıştır. Sunulan yöntem, üçlü sınıflandırma probleminde %98,70 doğruluk ve %98,82 özgüllük elde ederek yüksek başarı göstermiştir [99].

2021 yılında Qiao et al. tarafından COVID-19'un tespiti amacıyla, InceptionV3, VGG19, ResNeXt101, ResNet152 ve DenseNet161 modellerini bir araya getiren ve odak kaybıyla birleştiren esnek bir modül olan “Odak Kaybına Dayalı Sinir Ağı Topluluğu” adlı bir yaklaşım önerilmiştir. Önerilen yaklaşım iki aşamadan oluşmaktadır. İlk aşamada, her bir model bağımsız olarak COVID-19 sınıflandırması için eğitilmiştir. İkinci aşamada ise bu modellerden elde edilen ağırlıklar birleştirilerek genel bir topluluk modeli oluşturulmuştur. Model eğitimi sırasında, sınıf dengesizliği sorununu azaltmak amacıyla odak kaybı fonksiyonu çok sınıflı sınıflandırma problemine uygun şekilde uyarlanmıştır. Çalışma sonunda, önerilen modelin COVID-19 tespiti için temel modellerden daha iyi performans gösterdiği ortaya konmuştur [100].

Bhowal et al. tarafından sunulan çalışmada COVID-19 tespiti için lambda bulanık tabanlı topluluk model önerilmiştir. Önerilen modelde, ön işleme uygulanan görüntülerden öznetelik çıkarmak amacıyla VGG16, Xception ve InceptionV3 mimarileri kullanılmıştır. Bu üç modelden elde edilen öznetelikler COVID-19, pnömoni ve normal görüntülerini sınıflandırmak amacıyla softmax çıkışlı MLP'ye beslenmiştir. Daha sonra üç CNN modelinde görüntü başına elde edilen güven puanları Choquet integrali kullanılarak bir güven matrisinde birleştirilmiştir. Üç Choquet integralinin çıktısı çoğunluk oyu yöntemiyle birleştirilerek nihai sınıflandırma sonucu elde edilmiştir. Model eğitiminde karşılaştırmalı kayıp (contrastive loss) ve kategorik çapraz entropi birlikte kullanılarak hibrit bir kayıp fonksiyonu oluşturulmuştur. Çalışma sonunda elde edilen deneysel sonuçlar, önerilen yöntemin yakın dönemde literatürde sunulan birçok yaklaşımdan daha üstün performans gösterdiğini ortaya koymuştur [101].

Xu et al. tarafından akciğer grafilerinin sınıflandırılması amacıyla çok ölçekli dikkat ağına dayalı bir derin ağ modeli önerilmiştir. Bu modelde, ağın farklı katman ve dallarından elde edilen öznetelikler birleştirilerek daha anlamlı ve zengin öznetelik temsilleri elde edilmektedir. Ayrıca, çok sınıflı veri kümelerinde sınıflandırma doğruluğunu artırmak amacıyla yeni bir kayıp fonksiyonu geliştirilmiştir. Önerilen kayıp fonksiyonu, algısal kayıp (perceptual loss) ve çok etiketli denge kaybından (multi-label balance loss) oluşmaktadır. Algısal kayıp, modelin görsel tutarlılığı daha iyi temsil etmesini sağlarken, çok etiketli denge kaybı, sınıflar arası dengesizlikleri azaltarak nadir sınıfların öğrenilmesini desteklemektedir. ChestX-ray14 ve CheXpert veri kümeleri üzerinde yapılan analizler sonucunda, önerilen modelin AUC açısından literatürdeki diğer yöntemlere göre daha yüksek başarı sağladığı ortaya konmuştur [15].

Li et al. tarafından yapılan çalışmada akciğer grafileri üzerinden COVID-19'un sınıflandırılmasını hedefleyen “Çok Ölçekli Dikkat Rehberli Ağ” (Multiscale Attention Guided Network) modeli önerilmiştir. Önerilen modelde, ResNet50 tabanlı bir mimariye dikkat modüllerinin entegre edilmesiyle yerel özniteliklerin etkin bir şekilde çıkartılması amaçlanmıştır. COVID-19 vakalarındaki veri sayısı eksikliğini gidermek amacıyla “Dikkat Rehberli Artırma” yöntemi geliştirilmiş ve bu yöntemle, sınırlı veriden elde edilen dikkat haritaları referans alınarak veri artırımı yapılmıştır. Ayrıca, artırma sırasında oluşabilecek gürültüyü azaltmak ve tahminler arasındaki çelişkiyi önlemek için Yumuşak Uzaklık Düzenleştirme (soft distance regularization) yöntemini temel alan bir kayıp fonksiyonu önerilmiştir. Bu yaklaşım ile sınıflandırıcıların tahminleri yumuşak uzaklıklarla ağırlıklandırılarak genelleme performansı artırılmış ve veri eksikliğine rağmen COVID-19 ve pnömoni sınıflandırmasında yüksek başarı elde edilmiştir [68].

2022 yılında yapılan bir çalışmada Li et al. tarafından COVID-19, sağlıklı ve pnömoni görüntülerini ayırtmak için ResNet50 ve DenseNet201 modellerini temel alan hiyerarşik bir sınıflandırma modeli sunulmuştur. Sunulan modelde, önceden eğitilmiş bu iki asimetrik ağ daha ayırt edici ve tamamlayıcı öznitelikler elde etmek amacıyla entegre edilmiştir. Modelin performansının artırılması için, bu ağların arkasına kanal bazlı dikkat mekanizması olan SE modülü ve GAP katmanı eklenmiştir. Ayrıca, tahmin edilen ve gerçek etiket olasılıkları arasındaki farkı gösteren çapraz entropi fonksiyonuna bir ceza terimi (penalty) eklenerek yeni bir kayıp fonksiyonu önerilmiştir. Çalışmada elde edilen sonuçlar, önerilen yaklaşımın sınıflandırma başarısını artırdığını göstermiştir [17].

Roy et al. tarafından sunulan çalışmada, sınıf dengesizliği yüksek olan akciğer grafisi veri kümesini sınıflandırmak amacıyla “Dengeli Ağırlıklı Kategorik Çapraz Entropi” (Balanced Weighted Categorical Cross Entropy) adı verilen özgün bir kayıp fonksiyonu ve SVD-CLAHE Boosting adlı bir veri artırma tekniği önerilmiştir. SVD-CLAHE Boosting algoritması, aynı anda hem aşırı örnekleme (over-sampling) hem de düşük örnekleme (under-sampling) yöntemlerini kullanarak sınıflar arasındaki dengesizliği azaltmayı hedeflemiştir. Geriye kalan küçük dengesizlikler ise, geleneksel ağırlıklı çapraz entropi fonksiyonunun az örnek sayısına sahip sınıflara karşı gösterdiği önyargıyı (bias) dengelemek üzere geliştirilen dengeli kayıp fonksiyonu aracılığıyla giderilmiştir. Çalışma sonunda, ResNet50 ve VGG19 modelleri ile %94 doğruluk, %96 kesinlik, %95 duyarlılık, %95 F1-skoru ve 0,967 AUC elde edilerek önerilen yaklaşımın yüksek sınıflandırma performansı sergilediği gösterilmiştir [102].

Dhere and Sivaswamy tarafından akciğer grafilerinden COVID-19 tespiti için hiyerarşik bir sınıflandırma modeli önerilmiştir. Önerilen model iki aşamadan oluşmaktadır. İlk aşamada DenseNet121 kullanılarak pnömoni görüntüleri normal görüntülerden ayrıştırılmıştır. İkinci aşamada ise COVID-19'un, COVID-19 olmayan pnömoni görüntülerinden ayrışması için çoklu dikkat kalıntı öğrenme (Multi-scale Attention Residual Learning) mimarisi kullanılmıştır. Odak kaybının ve koniklik kaybının hibrit olarak kullanıldığı çalışma sonunda üçlü sınıflandırma için umut verici sonuçlar elde edilmiştir [93].

Chen et al. tarafından yapılan çalışmada akciğer grafilerinin sınıflandırılması için EfficientNet ve CoAtNet modelleri, ChestX-ray14 veri kümesi üzerinde değerlendirilmiştir. Çalışmada sınıflandırma performansını artırmak amacıyla, modelin zor örneklerle odaklanmasını sağlayan özel bir kayıp fonksiyonu önerilmiştir. Bu kayıp fonksiyonu, etiketler arasındaki uzun kuyruk (long-tail) problemini dengeleyerek sınıflandırma performansını iyileştirmiştir. Çalışma sonunda, CoAtNet-0-rw modeli ile önerilen kayıp fonksiyonunun birlikte kullanılmasıyla, ResNet50 ve EfficientNet-B5 gibi yaygın modellerden daha yüksek AUC değerleri elde edildiği gösterilmiştir. Bu bulgular, CNN ve dönüştürücü mimarilerinin birleşiminden oluşan CoAtNet-0-rw modelinin ve özel kayıp fonksiyonunun, dengesiz dağılıma sahip akciğer grafilerinde hastalık tespiti için güçlü bir potansiyele sahip olduğunu ortaya koymuştur [18].

Katona et al. tarafından yapılan çalışmada, çok etiketli akciğer grafilerinin sınıflandırılması için yeni bir çevrimiçi topluluk modeli önerilmiştir. Bu modelde VGG, ResNet ve DenseNet mimarileri, ek bir tam bağlı katman ve etiket ağırlıklı ortalama stratejisiyle birleştirilmiştir. Model eğitimi hem tüm topluluk yapısının hem de her bir alt modelin kaybını dikkate alan özel birleştirilmiş kayıp fonksiyonu ile gerçekleştirilmiştir. ChestX-ray14 ve MIMIC-CXR veri kümeleriyle yapılan testler, önerilen yaklaşımın sınıflandırma başarısını artırdığını ve modelin genelleme yeteneğini güçlendirdiğini göstermiştir [103].

Tang and Yang tarafından, akciğer grafilerinden hastalık tespiti amacıyla üç ana modülden oluşan CheXDouble adlı çift denetimli (dual-supervised) bir derin öğrenme modeli geliştirilmiştir. Omurga modülü olarak kullanılan DenseNet, grafilerdeki ilgili bölgeyi belirleyerek öznitelik haritasını çıkarmaktadır. Küresel Sınıflandırma (Global Classification) modülü, bu öznitelik haritasından sınıflandırma sonuçlarını tahmin etmekte ve öne çıkan alan haritası (saliency map) oluşturmaktadır. Küresel Dikkat Hizalama (Global Attention Alignment) modülü ise, oluşturulan öne çıkan bölgeleri kardiyopulmoner alanlarla

sınırlandırarak modelin dikkatini anlamlı anatomik bölgelere yönlendirmekte bu sayede hem modelin açıklanabilirliği hem de sınıflandırma doğruluğu artırılmaktadır. Çalışmada, veri kümesindeki örnek dengesizliğini çözmek amacıyla “Geliştirilmiş Odak Kaybı” (Improved Focal Loss) adı verilen bir kayıp fonksiyonu önerilmiştir. Bu fonksiyon, pozitif (hastalık varlığı) ve negatif (hastalık yokluğu) örneklerin dengesiz dağılımını dinamik olarak ağırlıklandırarak ve her bir partideki negatif örneklerin etkisini ayarlayarak sınıflandırma hatalarını azaltmaktadır. Önerilen CheXDouble modeli, ChestX-ray14 veri kümesi üzerinde test edilmiş ve literatürdeki mevcut modellere kıyasla hem sınıflandırma başarısı hem de genelleme kabiliyeti açısından üstün performans göstermiştir [104].

1.2.4. Önerilen çalışmanın literatüre katkısı

Literatürde, akciğer grafilerinin derin öğrenme yöntemleriyle sınıflandırması amacıyla çok sayıda çalışma yapılmış ve bu çalışmaların pek çoğunda yüksek performansa ulaşan modeller geliştirilmiştir. Özellikle transfer öğrenmesi ve dikkat mekanizmalarının kullanımı sayesinde sınırlı veri sayısına sahip veri kümeleri üzerinde başarılı sonuçlar elde edilmiştir. Bununla birlikte literatürdeki çoğu çalışmada, az sayıda veri içeren tek bir veri kümesiyle sınırlı kalınmış, önerilen modellerin genelleştirme yeteneği kapsamlı bir şekilde test edilmemiştir. Ayrıca kayıp fonksiyonlarının sınıflandırma başarısına etkisi sistematik olarak analiz edilmemiş, çoğunlukla standart fonksiyonlar tercih edilmiştir. Bu durum, önerilen yöntemlerin gerçek dünya senaryolarına aktarılabilirliğinin sınırlı olmasına yol açmaktadır.

Sunulan tez çalışması, literatürdeki mevcut eksiklikleri gidermek amacıyla kapsamlı bir yaklaşım ortaya koyarak önemli katkılar sağlamaktadır. Literatürdeki çalışmaların aksine sunulan bu çalışmada:

- Başkent Üniversitesi Ankara Hastanesi’nden toplanan klinik görüntüler ile birden fazla açık erişimli veri kümesinden elde edilen görüntüler birleştirilerek geniş ve yüksek çeşitliliğe sahip kapsamlı bir veri kümesi oluşturulmuştur. Böylece önerilen modelin genelleme yeteneği daha gerçekçi senaryolar ile değerlendirilmiştir.
- Literatürde yaygın olarak kullanılan 3 ila 7 sınıflı veri kümelerinin aksine, 7, 8, 9, 10, 12, 14 sınıflı veri kümeleriyle çalışmış, özellikle 15 sınıflı veri kümesiyle gerçekleştirilen analizler sayesinde mevcut çalışmaların ötesine geçilmiştir. Bu sayede çok sınıflı sınıflandırma konusunda literatüre önemli katkılar sunulmuştur.
- Önerilen derin öğrenme modeli ve geliştirilen kayıp fonksiyonları 7-15 sınıflı, farklı patolojiler içeren veri kümeleriyle ayrıntılı olarak test edilmiştir. Yani daha karmaşık ve

gerçekçi klinik senaryolar ele alınmış, böylece modelin ve önerilen kayıp fonksiyonlarının sınıf sayısından ve veri dağılımından bağımsız olarak performansları değerlendirilmiştir.

- Transfer öğrenmesine dayalı olarak geliştirilen modelde, DenseNet201 mimarisine ConvLSTM, SE bloğu ve dönüştürücü kodlayıcılar entegre edilerek hibrit bir yapı oluşturulmuştur. Bu yapı sayesinde görüntülerdeki önemli bölgelerin konumu ve bu bölgelerin birbiriyle olan ilişkileri etkili biçimde öğrenilmiş, özellikle semantik benzerliği yüksek sınıfların daha doğru biçimde ayırt edilmesi sağlanmıştır.
- Literatürde genellikle göz ardı edilen bir konu olan kayıp fonksiyonlarının model performansına etkisi detaylı olarak analiz edilmiştir. Dinamik, hibrit ve ceza terimi içeren kayıp fonksiyonları, bu fonksiyonları topluluk yöntemleriyle birleştiren özgün yaklaşımlar önerilmiştir. Önerilen bu fonksiyonların farklı model mimarileri ve farklı sınıf sayılarına sahip veri kümeleri için yüksek ve tutarlı performans sağladığı gösterilmiştir.
- Önerilen modelin ve kayıp fonksiyonunun çok sayıda sınıf içeren ve dengesiz dağılıma sahip veri kümelerinde kararlı ve yüksek performans göstermesi, bu yöntemin klinik uygulamalarda karar destek aracı olarak kullanılabilme potansiyelini ortaya koymaktadır.

Sonuç olarak, bu tez çalışmasında yüksek sayıda sınıf içeren ve dengesiz dağılıma sahip akciğer grafisi veri kümelerinde başarılı sonuçlar veren ve yüksek genelleme yeteneğine sahip bir derin öğrenme modeli geliştirilmiştir. Model performansını artırmak amacıyla özgün bir kayıp fonksiyonu önerilmiş, bu fonksiyonun, farklı modeller ve veri kümeleri üzerinde de performans iyileştirmesi sağladığı deneysel olarak kanıtlanmıştır. Ek olarak modelin karar verme sürecini daha şeffaf hale getirmek amacıyla Grad-CAM yöntemi uygulanmıştır. Geliştirilen yenilikçi model ve özgün kayıp fonksiyonu ile tıbbi görüntü sınıflandırma alanına önemli bir katkı yapılmış, bu kapsamda geliştirilen yöntemlerin klinik uygulamalarda çözüm üretme potansiyeli olduğu ortaya konmuştur.

1.3. Genel Bakış

Sunulan tez çalışması altı ana bölümden oluşmaktadır. Birinci bölüm, çalışmanın konusunu, amacını ve önemini, akciğer grafilerinin derin öğrenme yöntemleri ile sınıflandırılması konusunda yapılan çalışmalar ile ilgili literatür özetini içermektedir. İkinci bölümde, tezin temelini oluşturan kavramlar açıklanmıştır. Üçüncü bölümde tezde

kullanılan veri kümesi tanıtılmış, önerilen model ve kayıp fonksiyonlarının temelleri verilmiştir. Dördüncü bölümde, bir önceki bölümde açıklanan yöntemler kullanılarak elde edilen araştırma bulguları grafik ve tablolar ile sunulmuştur. Tezin beşinci bölümünde elde edilen sonuçların değerlendirmelerine, literatür karşılaştırmalarına yer verilmiştir. Altıncı ve son bölümde ise sonuçlar ve gelecek çalışmalar için öneriler sunulmuştur.

Sonuç olarak sunulan tez çalışmasında akciğer graflerinin yüksek başarıyla sınıflandırılmasını sağlayan bir derin öğrenme modeli ve kayıp fonksiyonu önerilmiştir.

2. KURAMSAL TEMELLER

2.1. Akciğer Anatomisi ve Fizyolojisi

Solunum sisteminin temel işlevi dokulara oksijen sağlamak ve metabolizma sonucu oluşan karbondioksiti uzaklaştırmaktır [105]. Bu sistemin en önemli bileşeni olan akciğerler anatomik olarak asimetrik bir yapıya sahiptir. Sağ akciğer tipik olarak üç lobdan, sol akciğer ise kalp nedeniyle iki lobdan oluşmaktadır. Her iki akciğer de çift katmanlı plevra zarıyla çevrilidir. İçte bulunan visseral plevra zarı akciğer yüzeyini örterken, dış parietal plevra zarı torasik boşluğu kaplamaktadır. Bu zarlar arasındaki ince plevra sıvı tabakası solunum sırasında akciğerlerin sürtünmesiz bir şekilde hareket etmesini sağlamaktadır [106].

Mikroskobik düzeyde akciğer parankimi gaz değişiminin gerçekleştiği ve oksijen ile karbondioksitin difüzyonu için geniş yüzey alanı sağlayan yoğun bir kılcal damar ağıyla çevirili küçük, balon benzeri yapılar olan alveollerden oluşmaktadır [107].

Fizyolojik olarak akciğerler, inspirasyon (soluk alma) sırasında genişleyebilme ve ekspirasyon (soluk verme) sırasında geri çekilme özelliğine sahip elastik bir yapıya sahiptir. Bu elastik yapı, alveoler hücreler tarafından üretilen, yüzey gerilimini azaltan, alveoler çökmeyi önleyen ve akciğer uyumluluğunun korunmasına yardımcı olan bir madde olan sürfaktan ile desteklenmektedir [105], [106]

Akciğer anatomisi ve fizyolojisi arasındaki hassas denge, yaşamı sürdürmek için gerekli gaz değişimine izin vererek solunum fonksiyonlarının düzenli çalışmasını sağlamaktadır. Alveollerin hassas yapısı, akciğer dokusunun elastikiyeti ve plevranın düzenleyici rolü, optimal solunum fonksiyonunun sürdürülmesi için kritik öneme sahiptir. Ancak, yapısal anormallikler, inflamatuvar süreçler veya dış faktörler nedeniyle solunum fonksiyonlarında bozulmalar meydana gelebilmektedir [105].

2.2. Akciğer Grafisi

Akciğer grafisi, akciğerleri, hava yollarını, diyaframı, kalbi, kaburgaları ve çevreleyen yumuşak dokuları değerlendirmek için amacıyla yaygın olarak kullanılan, invaziv olmayan, ucuz ve hızlı bir tıbbi görüntüleme yöntemidir [15], [16].

Akciğer grafileri, X-ışınlarının hasta vücuduna gönderilmesi ve bu ışınların farklı doku yoğunluklarına göre farklı oranlarda emilmesiyle oluşturulan görüntülerdir. Standart akciğer grafileri, hastanın X-ışını kaynağı ve dedektör paneli karşısındaki konumu ve yönelimine (oryantasyonuna) göre üç ana tipe ayrılmaktadır: posteroanterior (PA), anteroposterior (AP),

lateral (yan). PA ve AP görüntüleri X-ışını kaynağının hastanın arkasına veya önüne konumlandırıldığı görüntülerdir. AP görüntüsü tipik olarak yatar pozisyonda olan hastalardan alınırken, hasta PA görüntüsünün alınması için genellikle dik durmaktadır. Lateral görüntü genellikle bir PA görüntüsü ile birlikte elde edilmekte ve X-ışını hastanın bir tarafından diğerine, tipik olarak sağdan sola doğru yansımaktadır [29]. Farklı yoğunluktaki doku ve yapılar X-ışınıni geçirip yansıtımalarına bağlı olarak akciğer grafilinde siyah ya da beyaz görünmektedir. Kemikler yüksek yoğunlukludur, bu nedenle beyaz görünürken kaslar ve yağlar gri görünmektedir. Akciğerlerdeki hava ise, düşük yoğunluğu nedeniyle siyah görünmektedir. Sonuç olarak akciğer grafileri akciğerleri, kalbi, göğüs kafesini, hava yollarını ve kan damarlarını göstermektedir [108]. Dolayısıyla bu grafilere pulmoner nodül, TB, pnömoni, amfizem, efüzyon gibi pek çok yaşamı tehdit eden akciğer hastalığının tanınmasında ve teşhisinde çok önemli bir rol oynamaktadır [1], [23], [24], [27], [109], [110].

2.3. Akciğer Patolojileri

Akciğer patolojileri, solunum fonksiyonlarını etkileyen ve radyolojik olarak farklı bulgulara sahip geniş bir hastalık yelpazesini ifade etmektedir. Akciğerleri etkileyen enfeksiyöz hastalıklar arasında COVID-19, TB ve pnömoni gibi hastalıklar yer almaktadır. Pnömotoraks, atelektazi ve kardiyomegali gibi yapısal ve mekanik bozukluklar ise akciğerin anatomik bütünlüğünü ve fonksiyonel kapasitesini etkileyen patolojilerdir. Pulmoner ödem ve plevral efüzyon, akciğer dokusunda veya plevral boşlukta sıvı birikimi ile karakterizedir ve genellikle altta yatan kardiyovasküler veya inflamatuvar süreçlere bağlı olarak gelişmektedir. Nodül ve kitle oluşumları akciğerdeki iyi huylu (benign) veya kötü huylu (malign) neoplastik süreçleri temsil ederken, pulmoner fibröz akciğer dokusunda kalıcı skarlaşmaya neden olan kronik bir patolojidir. Travmaya bağlı gelişen kosta kırıkları ise, göğüs duvarı bütünlüğünün bozulması sonucu solunum fonksiyonlarını etkileyerek ciddi klinik sonuçlara neden olabilmektedir. Konsolidasyon, infiltrasyon ve akciğer opasitesi gibi radyolojik bulgular birçok akciğer hastalığının tanısında önemli rol oynamaktadır. Bu bulgular görüntüleme yöntemleri ile akciğer parankimindeki değişiklikleri ortaya çıkararak klinik tanıya yardımcı olmaktadır.

2.3.1. COVID-19

Koronavirüs hastalığı (COVID-19), başta solunum yolları ve akciğerleri etkileyen, SARS-CoV-2 virüsünün neden olduğu bulaşıcı bir hastalıktır [111], [112]. WHO, ilk olarak

Aralık 2019'da Çin'in Wuhan kentinde ortaya çıkan COVID-19'u Mart 2020'de küresel bir pandemi olarak ilan etmiştir [44], [113]. Mayıs 2025 itibarıyla dünya çapında 777.825.189 doğrulanmış COVID-19 vakası görülürken ve bu vakaların 7.095.903'ü ölümle sonuçlanmıştır [2]. Bu ölümcül virüsün yaygın semptomları ateş, kuru öksürük, nefes darlığı, boğaz ağrısı, yorgunluk, baş ağrısıdır [44], [50], [112], [113]. COVID-19'a bağlı olarak akciğerde gelişen yaygın inflamasyon, alveolar hasar ve sıvı birikimi sonucu ortaya çıkan akut solunum sıkıntısı sendromu, kalp yetmezliği, septik şok, pnömoni, solunum sıkıntısı ve akciğer ödemi gibi komplikasyonlar başlıca ölüm nedenleri olarak kabul edilmektedir [90], [111]. Bununla birlikte, COVID-19'un onaylanmış bir tedavisi bulunmadığından sosyal mesafe ve kesin ve hızlı tanı, bu ölümcül virüsle başa çıkmak için temel önlemlerdir [50], [113].

WHO'ya göre, COVID-19 tanısı ve taraması için altın standart, ters transkripsiyon polimeraz reaksiyonu (Reverse Transcription Polymerase Chain Reaction (RT-PCR)) olarak belirlenmiştir [50], [112], [113]. COVID-19'un en yaygın tanı aracı RT-PCR olmasına rağmen, bu testin tespit süresinin uzun olması (2 güne kadar), duyarlılığın düşük olması (%60-70 civarında) ve yanlış negatif oranlarının yüksek olması gibi dezavantajları bulunmaktadır [112], [114]. Virüsün yayılmasının durdurulması ve etkili tedavi için doğru ve hızlı tespit gerektiğinden, WHO'nun önerileri doğrultusunda akciğer grafileri RT-PCR'a alternatif yöntem haline gelmiştir. [113], [115].

COVID-19 olgularına ait akciğer grafilerinde genellikle bilateral (her iki akciğerde) tutulumlar izlenmekte olup, bu tutulumlar özellikle orta ve alt bölgelerde yoğunlaşmaktadır. Lezyonlar akciğerlerin periferik bölgelerinde yani dış kısımlarında yoğunlaşmaktadır. Görüntülerde düzensiz sınırlı, nonhomojen opasiteler ve konsolidasyon alanları görülmektedir [116], [117].

2.3.2. Tüberküloz

Tüberküloz (TB), Mycobacterium tuberculosis bakterisinin neden olduğu bulaşıcı bir hastalıktır. Bu bakteri kemik, beyin, lenf düğümleri gibi vücut bölümlerini etkilese de özellikle pulmoner bir patojen olarak kabul edilmektedir [4]. 2023 yılında TB, dünya genelinde tek bir bulaşıcı etkenden kaynaklanan birincil ölüm sebebi olmuştur [3], [4].

TB tedavi edilebilir bir hastalıktır, ancak hastalığın kontrol altına alınabilmesi için ihtiyaç duyulan erken ve doğru tanı büyük bir zorluk olmaya devam etmektedir [31], [118]–[120]. TB'yi tespit etmek için akciğer grafisi, pozitron emisyon tomografisi, BT,

mikroskopik incelemeler, kültür tabanlı yöntemler ve moleküler testler gibi çeşitli tanı yöntemleri uygulanmaktadır. Bununla birlikte, WHO “End-TB” stratejisi kapsamında akciğer grafilerini TB taramasında bir triyaj aracı olarak önermektedir [119], [121].

TB’nin grafilerdeki görünümü hastalığın durumuna göre değişiklik göstermektedir. Orta-alt akciğer bölgesinde infiltrasyon ve aynı taraf akciğerde hiler ve/veya mediastinal lenf büyümesi primer TB’nin karakteristik bulgularındandır. Reaktivasyon TB’si ise genel olarak üst lobların apikal ve posterior segmentlerinde veya alt lobların superior segmentlerinde nodüler, yamalı, düzensiz konsolidasyonlarla kendini göstermektedir. Orta-alt akciğer bölgesinde infiltrasyon ve aynı taraf akciğerde hiler ve/veya mediastinal lenf büyümesi TB’nin karakteristik bulgularındandır. Orta kalınlıkta duvara sahip, düzgün iç yüzeyli ve genellikle hava-sıvı seviyesi içermeyen boşluklar (kaviteler) TB’nin ilerleyen aşamalarında gözlenebilmektedir [122].

2.3.3. Pnömoni

Pnömoni, bakteri, virüs, mantar gibi mikroorganizmaların alveollerde yanıcı bir reaksiyona neden olması sonucunda oluşan inflamatuvar bir hastalıktır. Mikroorganizmalar, akciğerde yayıldıkça, bağışıklık sistemi bu patojenlere karşı yanıt oluşturmakta ve alveollerin içerisinde inflamatuvar hücrelerin birikmesine neden olmaktadır. Bu süreçte, alveollerde enfekte sıvı birikimi meydana gelerek gaz değişimini bozmakta solunum yetersizliğine yol açmaktadır. Sonuç olarak hastalarda solunum sıkıntısı, öksürük ve ateş gibi semptomlar ortaya çıkmaktadır [5], [123]. Pnömoni, özellikle gelişmekte olan ülkelerde hem yaşlı hem de genç nüfusta önde gelen ölüm sebeplerinden biri olmayı sürdürmektedir. Her yıl dünya nüfusunun yaklaşık %7’sine (yaklaşık 450 milyon) pnömoni teşhisi konulmakla birlikte bu teşhislerin 4 milyonu ölümle sonuçlanmaktadır. [5], [124]. Pnömoni, erken aşamalarda teşhis edilip uygun şekilde tedavi edilmediği takdirde hızla ilerleyerek ciddi komplikasyonlara ve ölüme yol açabilmektedir [5]. Pnömoni teşhisi için en yaygın kullanılan klinik yöntem akciğer grafileridir [124].

Pnömoni, akciğer grafilerinde genellikle alveoller içinde sıvı birikimi ve inflamasyona bağlı olarak artmış opasiteler şeklinde görülmektedir. Bu değişiklikler, enfeksiyonun etkenine ve yayılımına bağlı olarak farklı radyolojik paternler gösterebilmektedir. Pnömokoksik (tipik) pnömonilerde konsolidasyon akciğerin bir bölümünde yoğunlaşırken, atipik pnömonilerde dağınık, yama ya da buzlu cam tarzında (yaygın fakat belirsiz sınırlı)

ya da retiküler opasiteler görülebilmektedir. Tüm pnömonilerdeki ortak radyografik özellik ise hava yollarının süreçten etkilenmeyerek açık kalmasıdır [123].

2.3.4. Pnömotoraks

Pnömotoraks, plevral boşlukta hava birikmesi sonucu akciğerin kısmi ya da tamamen çökmesini ifade eden tıbbi bir terimdir [9], [125]. Pnömotoraks, klinik olarak spontan pnömotoraks ve edinsel (sekonder) pnömotoraks olmak üzere ikiye ayrılmaktadır. Spontan pnömotoraks altta yatan bir akciğer hastalığı olmaksızın kendiliğinden gelişen pnömotoraks türüdür. Edinsel pnömotoraks ise göğüs travmaları, kaburga kırıkları ya da invaziv işlemler sonucu gelişen pnömotoraks türüdür [125]. Özellikle göğüs yaralanması olan hastalarda pnömotoraks gelişme olasılığı %30 ila %39'dur [9]. Pnömotoraks, ani başlangıçlı göğüs ağrısı ve nefes darlığı semptomlarıyla kendini göstermektedir ve erken tespit edilip tedavi edilmezse ölümcül olabilen bir durumdur. Akciğer grafileri pnömotoraks tanısı için yeterli bir yöntemdir.

Normal akciğer grafilerinde visseral ve parietal plevralar görülmemektedir. Dolayısıyla grafide beyaz visseral plevral çizginin görünür olması pnömotoraks varlığını göstermektedir. Plevral çizginin dışındaki bölgede akciğer damarlarının kaybolduğu ve tamamen radyolüsent (koyu) bir alanın oluştuğu gözlenmektedir [126].

2.3.5. Atelektazi

Atelektazi, akciğer dokusunun tam veya kısmi olarak sönmesiyle (kollabe olmasıyla) karakterize edilen klinik bir durumdur. Bu durum, akciğerlere yeterli hava girmemesi sonucunda meydana gelmektedir ve çeşitli pulmoner ve ekstrapulmoner hastalıklarla ilişkili birkaç mekanizma nedeniyle gelişebilmektedir. Pulmoner nedenler, bronşiyal lümenin tıkanması (en yaygın neden), hava yolu iltihabı, artan mukus viskozitesi, azalmış siliyer fonksiyon, nöromusküler hastalıklara bağlı zayıf öksürük refleksi nedeniyle mukusun atılamaması, yabancı cisim aspirasyonu ve solunum yolu ve alveolleri kaplayan sıvının yüzey geriliminin artmasıdır. Ekstrapulmoner nedenler ise akciğer dışı etkenlere bağlı olarak hava yolları ve akciğer dokusunun sıkışması ile nöromusküler hastalıklar sonucu solunum kaslarının zayıflaması nedeniyle yeterli solunum hacminin sağlanamamasıdır. Atelektazinin klinik belirtileri, etkilenmiş lob sayısına, altta yatan nedene, hastanın yaşına ve genel sağlık durumuna bağlı olarak değişebilmektedir. Dispne (nefes darlığı), taşipne, hipoksemi ve öksürük en yaygın belirtilerdir [127]. Genel anestezi sonrası en yaygın görülen postoperatif

pulmoner komplikasyonlarından biri olan atelektazi, gaz değişimini bozarak hipoksemiye yol açmakta ve bu durum pnömoni ve akut akciğer hasarı gibi diğer pulmoner komplikasyonların gelişmesine neden olarak mortalite riskini artırabilmektedir [8]. Dolayısıyla altında yatan sebeplerin araştırılması ve tedavi edilebilmesi için atelektazinin erken teşhisi hayati bir öneme sahiptir. Atelektazi tanısında en sık kullanılan görüntüleme yöntemi akciğer grafisidir [127].

Atelektazinin radyografik bulguları direkt ve indirekt olmak üzere ikiye ayrılmaktadır. Direkt bulgular genellikle hacim kaybının belirtileridir ve en spesifik bulgu interlober fissürlerin yer değiştirmesidir. İnterlober fissürlerin yer değiştirmesi akciğerin çökmüş lobundan kaynaklanmaktadır ve hacim kaybının en güvenilir göstergelerinden biridir. Ayrıca pulmoner damarların veya hava yollarının sıkışması da direkt bulgular arasındadır ancak bu bulgu daha nadir görülmektedir. İndirekt bulgular hacim kaybına bağlı olarak gelişen sekonder değişiklikleri içermektedir. Artan akciğer opasitesi, hacim kaybı nedeniyle çökmüş alanın daha radyopak (beyaz) bir görünüme sahip olmasıyla karakterizedir. Ek olarak, önceden var olan akciğer anormalliklerinin kayması, granülom veya diğer anatomik referans noktalarının farklı bir konuma yerleşmesiyle belirlenebilmektedir [128].

2.3.6. Kardiyomegali

Kardiyomegali kendi başına bir hastalık olmamakla birlikte kalbin tamamının ya da bazı kısımlarının büyümesi ile karakterize edilen durumdur ve çoğu zaman ciddi kalp hastalıklarının önemli bir işaretidir [10]. Klinik olarak çabuk yorulma, nefes darlığı (dispne), çarpıntı ve ayak bileklerinde şişlik gibi belirtilerle kendini gösteren kardiyomegali, koroner arter hastalığı, böbrek hastalığı, hipertansiyon, kalıtsal bozukluk, enfeksiyon ve kardiyomiopati dahil olmak üzere pek çok durumdan kaynaklanabilmektedir. Bu nedenle, bu durumun erken teşhis edilmesi ve altında yatan sebeplerin araştırılması hayati bir öneme sahiptir [129].

Akciğer grafileri, kalp boyutunun değerlendirilmesi için temel ve güvenilir bir tanı yöntemidir. Kardiyotorasik oran hesaplanarak kalp boyutundaki artışın tespit edilmesi için kullanılan akciğer grafileri, kardiyomegali tespitinde %95,8 doğruluk göstermektedir. Akciğer grafilerinde kardiyotorasik alanın kalbin göğüs kafesi genişliğine oranı hesaplanmaktadır ve bu oranın %50'nin üzerinde olması kardiyomegaliye işaret etmektedir. Bununla birlikte sol ya da sağ ventrikül genişlemesine bağlı olarak yuvarlak ve genişlemiş bir kalp görünümü de kardiyomegaliyi göstermektedir [129].

2.3.7. Akciğer ödemi

Akciğer ödemi, akciğerlerin interstisyel dokusunda ya da alveolar boşluklarda normalden fazla sıvı birikmesi durumudur [11]. Bu durum klinikte kardiyojenik (kalp kaynaklı) ve non-kardiyojenik (kalp dışında nedenlerle gelişen) olmak üzere iki kategoriye ayrılmaktadır. Akciğer ödeminin belirtileri, hastada nefes darlığı (dispne), ortopne (yatarken artan nefes darlığı), taşipne (hızlı solunum), pembe köpüklü balgam, hipertansiyon ya da hipotansiyon görülmesidir. Acil müdahale edilmezse, solunum yetmezliği gelişebilmekte ve bu durum ölümle sonuçlanabilmektedir [130]. Akciğer ödeminin tanısında akciğer grafisi yaygın olarak kullanılan görüntüleme yöntemidir [11].

Akciğer ödeminin akciğer grafisindeki bulguları, ödemin evresine ve nedenine bağlı olarak değişebilmektedir. Kardiyojenik ve non-kardiyojenik ödemlerde bazı ortak özellikler olsa da kardiyojenik ödemin daha belirgin radyolojik bulguları bulunmaktadır. Non-kardiyojenik ödemde akciğer grafisinde iki taraflı, yaygın, hava bronkogramı içeren periferik infiltrasyonlar gözlenmektedir. Kardiyojenik ödemde ise özellikle akciğerin üst kesimlerinde uzanan ince çizgiler (Kerley A), alt akciğer bölgelerinde, interlobüler septal sıvı birikimi sonucu gelişen yatay çizgiler (Kerley B) ve hilusların etrafındaki opasiteler (alveoler ödem), kardiyomegali (kalp bölgesinde büyüme), birikmiş plevra sıvısı, fissürlerde sıvı, hilluslarda genişleme ve peribronşiyal kılıflanma (kuffing) izlenmektedir [130].

2.3.8. Plevral efüzyon

Plevral efüzyon, plevral boşlukta anormal sıvı birikmesi sonucu oluşan bir klinik bir durumdur [131]. Plevral efüzyon nedenine bağlı olarak iki gruba ayrılmaktadır. Transidatif plevral efüzyon, hidrostatik ve onkotik kuvvetlerdeki dengesizliklerden kaynaklanan ve kalp yetmezliği ve siroz gibi sistemik hastalıkların neden olduğu efüzyon türüdür. Eksüdatif plevral efüzyon ise plevral sıvının birikimini etkileyen yerel faktörler değiştiğinde ortaya çıkmaktadır, pnömoni, TB, malignite ve tromboembolizm gibi inflamatuvar nedenlerle oluşmaktadır [132]. Plevral efüzyonun klinik belirtileri, nefes darlığı (dispne), göğüs ve üst karın ağrısı, kuru öksürük, ateş gibi semptomlardır [131], [132]. Plevral efüzyonun erken tanısı, altta yatan nedenin belirlenmesi ve uygun tedaviye başlanması açısından büyük öneme sahiptir [11]. Akciğer grafileri, plevral efüzyonun görüntülenmesi için yaygın şekilde kullanılmaktadır. Grafiplerdeki sıvının miktarı ve dağılımı, hastalığın ilerleyişi ile ilgili önemli bilgiler sağlamaktadır. Sıvının akciğer dokusu ve alveollerin içinde mi (pulmoner

ödem) yoksa plevral boşlukta mı (plevral efüzyon) yer aldığını sınıflandırmak etkin tedavi için büyük önem taşımaktadır [11].

Plevral efüzyonun akciğer grafisindeki özellikleri genellikle patognomoniktir. Görülen en erken belirti (50 ml kadar az plevral sıvı) kostofrenik açının sıvı birikimi nedeniyle körelmesidir. Büyük hacimli efüzyonlarda, etkilenen tarafta yaygın opasite gözlenmektedir. Büyük plevral efüzyonlarda, artan sıvı hacmi nedeniyle mediastinal yapılar karşı tarafa itilmiş olarak görülebilmektedir [131].

2.3.9. Nodül ve Kitle

Pulmoner nodül, akciğer grafisinde görülen yuvarlak ya da düzensiz sınırlı opasitelerdir. Bu opasitelerin çapı 3 cm'den büyük olduğunda bu durum kitle olarak adlandırılmaktadır [133]. Pulmoner nodüller ve kitleler, boyutlarına ve karakteristik özelliklerine göre benign (iyi huylu) ya da malign (kötü huylu) olabilmektedir. Pulmoner nodül ve kitlelerin akciğer kanserinin erken belirtisi olduğu bilindiğinden radyolojik değerlendirme, tanı ve takip için büyük önem taşımaktadır [7]. Akciğer grafisi, pulmoner nodül ve kitlelerin tespiti için sıklıkla kullanılan birinci basamak görüntüleme yöntemidir [134].

Nodül ve kitleler akciğer grafilinde malignite şüphesine göre keskin sınırlı ya da düzensiz sınırlı, homojen ya da heterojen yoğunluk gösteren opasiteler olarak görülmektedirler [133].

2.3.10. Pulmoner fibröz

Pulmoner fibröz, esas olarak akciğer dokusu hasar gördüğünde ve yaralandığında oluşan, solunum fonksiyonlarını kısıtlayan bir durumdur. Bu durum akciğerlerde doku sertleşmesine ve elastikiyet kaybına neden olarak oksijen değişimini zorlaştırmaktadır [6]. Pulmoner fibrözün en yaygın nedenleri arasında interstisyel akciğer hastalığı olan İdiyopatik Pulmoner Fibrozis, silika, asbest ve metal tozuna uzun süreli maruz kalmak, romatoid artrit, sistemik skleroz ve vaskülit gibi hastalıklar, kemoterapi ajanları, antibiyotikler ve radyasyon tedavisi gibi bazı tıbbi tedaviler ve genetik faktörler yer almaktadır. Pulmoner fibrözün klinik belirtileri nefes darlığı, kuru öksürük ve yorgunluk gibi semptomlardır. Hastalığın ileri evrelerinde hipoksemi, pulmoner hipertansiyon ve solunum yetmezliği gibi ciddi komplikasyonlar gelişebilmektedir [135]. Pulmoner fibrözün erken tanısı, hastalığın ilerlemesini yavaşlatmak ve uygun tedavi seçeneklerini belirlemek açısından büyük önem

taşımaktadır. Geç tanı konulan vakalarda geri dönüşümsüz akciğer hasarı oluşması nedeniyle solunum fonksiyon kaybı meydana gelmektedir. Pulmoner fibrözün tanısında genellikle ilk basamak görüntüleme yöntemi olarak akciğer grafisi kullanılmaktadır [136].

Grafilerde alt loblarda daha belirgin olmak üzere interstisyel fibrözle uyumlu ince retiküler çizgiler görülebilmektedir. İleri vakalarda akciğerin bazal bölgelerinde bal peteği görünümü oluşabilmektedir. Pulmoner fibröz nedeniyle akciğer esnekliği azaldığından akciğer hacminde önemli bir küçülme ve diyafram yükselmesi izlenebilmektedir [136].

2.3.11. Kosta kırığı

Kosta kırığı göğüs duvarında yer alan kaburga kemiklerinin travma, stres ya da patolojik süreçler nedeniyle kırılmasıyla ortaya çıkan klinik durumdur [12]. Kosta kırıklarının en yaygın sebepleri arasında trafik kazaları, düşme sonucu gelişen travmatik yaralanmalar, osteoporoz gibi kemik hastalıklarına bağlı minimal travmalar ve genellikle sporcularda ve yoğun öksürük atağı geçiren hastalarda görülen uzun süreli tekrarlayan göğüs hareketleri yer almaktadır. Göğüs ağrısı, solunumla artan hassasiyet, öksürükle tetiklenen ağrı ve derin nefes alma zorluğu bu durumlarda sık gözlenen klinik belirtiler arasındadır. Ancak birden fazla kaburga kırığı içeren durumlarda, plevral yaralanmalar, pnömotoraks veya hemotoraks gibi ciddi komplikasyonlar gelişebilmektedir [137].

Kosta kırıklarının erken tanısı, altındaki organlara zarar vermemesi, solunum fonksiyonlarının korunması ve göğüs duvarı stabilitesinin bozulmaması açısından kritik bir öneme sahiptir [12]. Akciğer grafileri kosta kırıklarının görüntülenmesi için sıklıkla tercih edilen bir yöntemdir. Kırıklar, grafilerde belirgin fraktür hattı olarak izlenmektedir. Ek olarak etkilenen bölgede ödem ve yumuşak doku değişiklikleri saptanabilmektedir [137].

2.3.12. Konsolidasyon ve İnfiltrasyon

Akciğer konsolidasyonu ve infiltrasyonu, akciğer parankiminde meydana gelen patolojik değişiklikleri tanımlayan, radyolojide sıklıkla kullanılan iki farklı terimdir. Her iki durum da akciğer grafisinde artan opasite ile kendini gösterse de mekanizmaları ve klinik anlamları farklıdır. İnfiltrasyon, akciğer dokusunda inflamatuvar hücreler, sıvı, kan, protein veya tümör hücrelerinin birikmesiyle oluşan yaygın veya lokalize bir opaklık artışı olarak tanımlanmaktadır. Genellikle interstisyel akciğer hastalıkları, enfeksiyonlar veya tümör infiltrasyonlarında görülmektedir. İnfiltrasyonda hava içeriği korunurken interstisyel dokuda veya alveolar boşlukta sıvı/hücre birikimi mevcuttur. Konsolidasyon ise, alveollerin

tamamen sıvı, eksüda, kan veya hücrel materyalle dolması sonucu hava içeriğinin tamamen kaybolmasıyla karakterize bir durumdur. Konsolidasyonda alveoller hava içermez, tamamen sıvı veya inflamatuvar materyalle doludur [136].

İnfiltrasyon ve konsolidasyonun en yaygın nedenleri arasında pnömoni, pulmoner ödem, akciğer kanseri ve metastazlar, pulmoner hemoraji ve interstisyel akciğer hastalıkları yer almaktadır. Bu iki durumun klinik bulgularına örnek olarak nefes darlığı, öksürük, ateş ve göğüs ağrısı gibi semptomlar verilebilmektedir. Bu semptomların şiddeti ve süresi altta yatan nedene bağlı olarak değişmektedir. Bu patolojik durumların erken tanısı, altta yatan nedeni belirlemek ve uygun tedaviyi başlatmak için kritik öneme sahiptir. Özellikle pnömoni, pulmoner ödem ve akciğer kanseri gibi ciddi hastalıkların erken tanısı, mortalite ve morbiditeyi azaltmada önemli bir rol oynamaktadır. Akciğer grafisi, infiltrasyon ve konsolidasyonun tanısında sıklıkla kullanılan görüntüleme yöntemidir [138].

İnfiltrasyon genellikle ince ve iyi tanımlanmamış sınırları olan retiküler veya buzlu cam opasiteleri ile karakterizedir. İnterstisyel akciğer hastalıklarında, erken pulmoner ödemde ve viral enfeksiyonlarda diffüz veya lokalize opasite artışı olarak gözlemlenebilmektedir. Konsolidasyon daha yoğun, daha homojen ve daha belirgin sınırları olan bir opasite olarak gözlemlenmektedir. Tipik olarak hava bronkogramı (opak alan içindeki hava yollarının gözlemlenmesi) içerebilmektedir, bu durum alveollerin tamamen sıvı veya hücrel materyalle dolu olduğunu gösteren önemli bir bulgudur. İnfiltrasyonu konsolidasyondan radyografik olarak doğru şekilde ayırt etmek, klinik yaklaşımı belirlemede büyük önem taşımaktadır [139].

2.3.13. Akciğer Opasitesi

Akciğer opasitesi, akciğer grafilinde normalde hava dolu olması gereken alanlardaki artmış yoğunluk (opasite) olarak tanımlanan geniş bir terimdir. Bu opasiteler, akciğer dokusunun daha fazla X-ışını emmesi ve çevresine göre beyaz (radyoaktif) görünmesiyle karakterize edilmektedir. Opasite, belirli bir boyutu veya patolojik yapıyı tanımlamamaktadır, yalnızca X-ışınlarını seçici olarak tutan ve çevresine göre daha opak görünen herhangi bir alan için kullanılan genel bir terimdir [136], [140].

Normal akciğer dokusu, büyük miktarda hava içerdiği için akciğer grafisinde siyah görünmektedir. Ancak pnömoni gibi hastalıklarda alveoller hava yerine sıvı, mikroorganizmalar, bağışıklık hücreleri ve iltihaplı maddelerle dolmaktadır. Bu durum normalde siyah olan akciğer alanlarının gri veya beyaz (opak) görünmesine neden

olmaktadır. Akciğer opasiteleri enfeksiyonlarla sınırlı değildir. Akciğer kanseri, pulmoner ödem ve pulmoner emboli gibi birçok farklı hastalık da akciğer grafilerinde opasitelerin oluşmasına neden olmaktadır. Akciğer grafilerinde opasitesinin erken tespiti, altta yatan hastalığın belirlenmesi ve zamanında uygun tedavinin başlatılması için kritik öneme sahiptir [140].

2.4. Derin Öğrenme Yöntemleri


Derin öğrenme, büyük veri kümeleri üzerinden öğrenme yeteneği sayesinde karmaşık problemleri çözmeyi sağlayan makine öğrenmesi alt dalıdır. Özellikle, tıbbi görüntü işleme alanında, hastalıkların tespiti ve sınıflandırılması gibi uygulamalarda yaygın olarak kullanılmaktadır. Bu bölümde tez kapsamında önerilen modellerde yer alan yapılar ayrıntılı olarak ele alınmıştır.

Bu kapsamda herhangi bir manuel müdahale gerektirmeden otomatik olarak öznelik çıkarımı yapabilmeleri sayesinde yaygın olarak tercih edilen CNN mimarileri, CNN tabanlı modellere entegre edildiğinde sınıflandırma performansını artırdığı gösterilen dikkat mekanizmaları, ViT, SE blokları ve LSTM yapıları detaylı bir şekilde açıklanmıştır.

Bunlara ek olarak, model eğitimi sırasında hata fonksiyonlarını minimize ederek genel performansı doğrudan etkileyen çeşitli kayıp fonksiyonları da incelenmiştir. Ayrıca geliştirilen modelin karar alma sürecini görselleştirmek amacıyla kullanılan ısı haritaları ile model performansının nicel olarak değerlendirildiği metrikler (doğruluk, F1-skoru, AUC vb.) hakkında bilgi verilmiştir.

2.4.1. Evrişimsel sinir ağları (Convolutional neural networks (CNN))

Tipik bir CNN modeli evrişim katmanı, doğrusal olmayan aktivasyon katmanı, havuzlama katmanı ve tam bağlı katmanlar olmak üzere dört ana katmandan oluşmaktadır (Şekil 2.1) [37], [141].




Şekil 2.1. Tipik CNN mimarisi [142].

Evrişim katmanı, CNN mimarisinin temel katmanıdır. Bu katmanda girdi görüntüsüne çekirdek (kernel) adı verilen filtreler uygulanmaktadır. Filtre katsayıları (K) görüntünün (G) piksel değerleri ile çarpılmakta ve bu filtre görüntü boyunca kaydırılmaktadır. Böylece her konumdaki özneliklerin çıkartılması sağlanmaktadır. Bu işlem sonucunda öznelik haritası (E) oluşturulmaktadır (eşitlik (2.1)). Oluşturulan öznelik haritası bir sonraki katmana aktarılmaktadır.

$$E(i, j) = \sum_m \sum_n G(i + m, j + n) \cdot K(m, n) \quad (2.1)$$

Burada $E(i, j)$ elde edilen öznelik haritası, $G(i + m, j + n)$ girdi görüntüsündeki $(i + m, j + n)$ konumundaki piksel değerleri, $K(m, n)$ ise çekirdek matrisinin (m, n) konumundaki değeridir.

Evrişim katmanının ardından, ağa doğrusal olmama durumunu sağlamak için doğrusal olmayan bir aktivasyon fonksiyonu (Şekil 2.2) uygulanmaktadır. Bu fonksiyon, yalnızca doğrusal ilişkilerle açıklanamayan karmaşık örüntülerin öğrenilmesini sağlayarak modelin ifade gücünü ve genelleme yeteneğini artırmaktadır.



Şekil 2.2. Aktivasyon fonksiyonları.

Havuzlama katmanı, modeldeki parametre sayısını azaltarak hesaplama yükünü düşüren ve aşırı uyumu (overfitting) önlemeye yardımcı olan bir katmandır. Bu katmanda, çıkarılan öznitelik haritalarına istatistiksel işlemler (örneğin maksimum veya ortalama alma) uygulanarak boyut indirgeme gerçekleştirilir.


Tam bağlı katman, önceki evrişim ve havuzlama katmanlarından çıkartılan öznitelik haritalarını düzleştirerek (flattening) tek boyutlu bir vektöre dönüştürmektedir. Bu vektör, sınıf etiketlerinin belirlenmesinde kullanılmaktadır. MLP yapılarında olduğu gibi, tam bağlı katmanda her bir nöron bir önceki katmandaki tüm nöronlara bağlanır. CNN mimarilerinde genellikle bir veya birden fazla tam bağlı katman yer almaktadır. Son katmanda ise ilgili özniteliklerin sınıfını temsil eden sınıf etiketleri elde edilmektedir. Sınıf etiketi belirleme işlemi uygun aktivasyon fonksiyonunun kullanılmasıyla gerçekleştirilmektedir. İkili sınıflandırma problemlerinde genellikle sigmoid fonksiyonu tercih edilirken, çok sınıflı sınıflandırma senaryolarında softmax fonksiyonu kullanılmaktadır [4], [36], [37], [43], [141], [143], [144].

Kararlı bir CNN mimarisi kurmak ve yüksek bir performans elde etmek için eğitimin büyük ölçekli veri kümeleri kullanılarak yapılması gerekmektedir [145]. Veri kümesinin yeterli büyüklükte olmaması durumunda, bu sorunun üstesinden gelmek için transfer öğrenmesi yaklaşımı sıklıkla tercih edilmektedir. Transfer öğrenmesinin temel amacı, belirli bir görev için eğitilmiş bir derin öğrenme modelinin parametrelerinin başka bir görev için başlangıç noktası olarak kullanılmasıdır. Bu yaklaşım üç farklı stratejiye dayanmaktadır. İlk stratejide, CNN, önceden eğitilmiş katmanlarında hiçbir değişiklik yapılmadan öznitelik çıkarıcı olarak kullanılmakta ve orijinal tam bağlı katmanlar yerine yeni bir sınıflandırıcı katmanı eklenmektedir. İkinci stratejide, önceden eğitilmiş modele görevle uyumlu bir sınıflandırıcı katmanı eklendikten sonra, tüm ağ üzerinde ince ayar (fine-tuning) uygulanarak model tamamen yeniden eğitilmektedir. Üçüncü stratejide, modelin alt katmanları dondurularak yalnızca seçilen üst katmanlara ince ayar yapılmakta, ardından göreve uygun yeni bir sınıflandırıcı katmanı modele entegre edilmektedir. Bunlara ek olarak, modelde herhangi bir değişiklik yapılmadan tüm modelin sıfırdan eğitildiği bir transfer öğrenmesi stratejisi daha bulunmaktadır, bu yöntem genellikle sıfırdan öğrenmeyle (training from scratch) eşdeğer olarak kabul edilmektedir. Son strateji dışındaki transfer öğrenmesi yöntemleri, geniş veri kümeleri gerektirmediği için özellikle tıbbi görüntü sınıflandırma çalışmalarında büyük avantaj sağlamaktadır [146].

Transfer öğrenmesi uygulamalarında yaygın olarak kullanılan önceden eğitilmiş CNN modellerinin çoğu, ImageNet kullanılarak eğitilmiştir. ImageNet, 1000 nesne kategorisine

sahip 14 milyondan fazla etiketli görüntü içeren büyük ölçekli bir görüntü sınıflandırma veri kümesidir. Bu veri kümesine dayalı olarak her yıl, “ImageNet Büyük Ölçekli Görsel Tanıma Yarışması” (ImageNet Large Scale Visual Recognition Challenge) adlı bir nesne sınıflandırma ve algılama yarışması düzenlenmektedir. Bu yarışma derin öğrenme tabanlı görüntü sınıflandırma ve nesne algılama modellerinin gelişimine önemli katkılar sağlamaktadır. Özellikle, AlexNet'in tanıtılmasından sonra, görüntü sınıflandırması için VGG, ResNet, DenseNet, GoogLeNet gibi birçok başarılı model sunulmuş, bu modeller küçük ölçekli veri kümelerinin sınıflandırılmasında yüksek performanslar elde edilmesini mümkün kılmıştır. ImageNet üzerinde eğitilmiş DenseNet201, Inceptionv3, MobileNet gibi önceden eğitilmiş modeller, özellikle tıbbi görüntü analizinde öznetelik çıkarımı ve görüntü sınıflandırma görevlerinde yaygın olarak kullanılmaktadır [115], [147].

Bu çalışmada önerilen derin öğrenme modelinin omurgası olan DenseNet201, 201 katmandan oluşan, yoğun bağlantılı bir CNN modelidir. DenseNet modeli, katmanlar arasındaki bilgi akışını en üst düzeye çıkarmak için Huang et al. tarafından önerilmiştir [148]. Bu modelde, her katman önceki katmanların çıktısını kendi öznetelik haritalarıyla birleştirerek sonraki katmanlara iletmektedir. Bu yapı sayesinde özneteliklerin tekrardan kullanılması ve gradyanların daha verimli yayılması sağlanmaktadır. Böylece parametre paylaşımı yoluyla modelin karmaşıklığı, dolayısıyla da daha küçük eğitim veri kümelerinde aşırı uyum (overfitting) riski azalmaktadır [148]. Birleştirme işleminin yapıldığı ve sonraki katmanlara bilginin gönderildiği bu katmanlar yoğun blok olarak adlandırılmaktadır [149]. Şekil 2.3'te büyüme oranı (growth rate) 4 olan ve her katmanın tüm önceki katmanlardan gelen öznetelik haritalarını girdi olarak aldığı beş katmanlı bir yoğun blok örneği verilmiştir.



Şekil 2.3. Beş katmanlı yoğun blok örneği [148].

2.4.2. Dikkat mekanizmaları

Biyolojik olarak görsel dikkat sistemi (visual attention system) olarak tanımlanan sürece göre, insan gözü bir görüntüye baktığında bu görüntünün tamamını aynı anda algılayamamaktadır. Yalnızca fovea adı verilen küçük merkezi alanı yüksek çözünürlükle görürken geri kalan kısımları daha düşük çözünürlükte görmektedir. Görüntünün tamamının tanınabilmesi için göz, foveadan elde edilen bilgiler tanıma için yeterli oluncaya kadar görüntünün farklı bölgelerine kaydırılmaktadır. Bu göz hareketlerine sakkadik (sıçramalı) göz hareketleri denmektedir. Sakkadik göz hareketleri o kadar hızlıdır ki görüntüler tek bakışta tanınıyormuş gibi hissedilmektedir [64]. İnsan gözünün görüntü oluşturmalarının temeli olan görsel dikkat sistemi pek çok bilim insanı tarafından kapsamlı bir şekilde incelenmiş ve bu sistemin modellenmesi üzerine pek çok çalışma yapılmıştır [67]. Bu çalışmalar birçok yapay zeka görevi için ilham kaynağı olmakla birlikte bu sistemin görüntü tanıma için yararlı olabileceği tespit edilmiştir. Bu nedenle, yıllardır bu sistemden esinlenerek farklı dikkat mekanizmaları geliştirilmiştir. Geliştirilen bu mekanizmalar, görüntü tanıma ve sınıflandırmada görevlerinde başarıları kanıtlanan derin sinir ağlarına da entegre edilmektedir [64].


Dikkat mekanizmalarının sinir ağlarına entegrasyonu üzerine ilk çalışmalar 1980'li yılların sonlarına dayanmaktadır. Görüntü sınıflandırması için dikkat mekanizmalarının kullanımı ise ilk olarak 2010 yılında, kısıtlı Boltzmann makinesine dikkat bileşenlerinin eklenmesiyle gerçekleştirilmiştir. 2015 yılı ise dikkat ağlarının farklı görevler için çeşitli derin öğrenme mimarileriyle birlikte yaygın olarak kullanıldığı altın çağ olarak bilinmektedir [64]. Bu tarihten itibaren akciğer grafilerinin sınıflandırılması için önerilen birçok derin sinir ağı uygulamasında dikkat ağları kullanılmış ve sınıflandırma başarıları açısından umut verici sonuçlar elde edilmiştir.

Bu bağlamda, tez kapsamında kullanılan ve dikkat mekanizmalarının birer uygulaması olan SE bloğu ve ViT yapıları bu başlık altında detaylı şekilde açıklanmıştır.

2.4.2.1.Sıkma-uvarma (Squeeze-and-excitation (SE)) bloğu

Hu at al. [150] uzamsal (spatial) dikkat yaklaşımları yerine kanal (channel) ilişkisine odaklanmak için SE bloğunu önermişlerdir. SE bloğu (Şekil 2.4), kanallar arasındaki karşılıklı bağımlılıkları kullanarak bir ağ tarafından üretilen temsillerin kalitesini iyileştirmeyi amaçlamaktadır [150]. SE blokları CNN mimarilerine entegre edildiğinde

önemli öznitelikleri öne çıkartırken gereksiz olanları bastırmaktadır, böylece sınıflandırma modelinin performansını artırmaktadır.



Şekil 2.4. Sıkma- Uyarma bloğu [150].

SE bloğunda, ilk olarak öznitelik haritası (U), her kanalın (giriş tensörü) uzamsal boyutlarına küresel ortalama havuzlamanın uygulandığı bir sıkıştırma (squeeze) işleminden geçirilmektedir. Bu şekilde her kanal için skalar bir değer üretilerek kanalın genel öznitelikleri yakalanmaktadır. $z \in \mathbb{R}^C$ vektörü kanalların aktivasyon seviyesini temsil etmektedir ve $U \in \mathbb{R}^{H \times W \times C}$ öznitelik haritasının $H \times W$ uzamsal boyutları boyunca sıkıştırılmasıyla oluşturulmaktadır. z 'nin c -inci elemanı eşitlik (2.2)'de verilen şekilde hesaplanmaktadır.

$$z_c = \frac{1}{H \cdot W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (2.2)$$

$$z = [z_1, z_2, \dots, z_C] \quad (2.3)$$

Burada H yükseklik, W genişlik, c ise kanal sayısıdır. z_c , c -inci kanalın sıkıştırılmış değerini ifade etmektedir. z ise elde edilen kanal vektörüdür. Sonuç olarak sıkıştırma işleminin sonucunda giriş öznitelik haritasından C boyutlu bir vektör elde edilmektedir.

Daha sonra uyarma (excitation) aşamasında, kanal bazındaki bağımlılıkları etkili bir şekilde yakalamak için sıkıştırma aşamasından elde edilen vektör ileri beslemeli bir sinir ağına beslenmektedir. Kanal başına dikkat katsayıları (s) eşitlik (2.4)'te verilen şekilde hesaplanmaktadır.

$$s = \sigma(W_2 \delta(W_1 z)) \quad (2.4)$$

Burada δ , ReLU aktivasyon fonksiyonunu, σ , sigmoid fonksiyonunu ifade etmektedir. W_1 ve W_2 tam bağlı katmanların öğrenilebilir ağırlık matrisleridir ve her kanalın önemini

öğrenmek için kullanılmaktadır. W_1 , kanal bilgisini sıkıştırarak özetlerken, W_2 bu bilgiyi yeniden genişleterek, her kanal için önem katsayısı üretmektedir.

Son olarak, gereksiz öznitelikleri bastırmak ve önemli olanları öne çıkartmak amacıyla uyarma aşamasından elde edilen dikkat katsayıları ile giriş tensöründeki öznitelikler kanal bazında çarpılmaktadır [150], [151]. Bu işlem şu şekilde yapılmaktadır:

$$\tilde{U}(i, j, c) = s_c \cdot U(i, j, c) \quad (2.5)$$


Burada s_c , dikkat katsayısı vektörünün (s) c -inci elemanını, $\tilde{U}$ ise SE bloğunun sonunda elde edilen yeniden ölçeklenmiş öznitelik haritasını temsil etmektedir.

2.4.2.2. Görü dönüştürücüler (Vision transformers (ViT))

2017 yılında Vaswani et al. [152] tarafından tanıtılan dönüştürücü (transformer) mimarileri öz-dikkat (self-attention) mekanizmalarına dayanan sinir ağlarıdır ve özellikle doğal dil işleme alanında kayda değer başarılar elde etmiştir. Bu alandaki başarılı performanslarından sonra dönüştürücüler görüntü sınıflandırma ve nesne algılama uygulamalarında da son teknoloji haline gelmişlerdir [76], [81]. Görüntü sınıflandırması için kullanılan ViT, iki kodlayıcı ve bir kod çözücü bloğuna sahip orijinal dönüştürücü bloğuna dayanmaktadır, ancak görüntü sınıflandırma için yalnızca dönüştürücünün kodlayıcı bloğu kullanılmaktadır [76], [83].

Görü dönüştürücüler, görüntüleri küçük parçalara (yama) ayırarak bu parçaları dönüştürücülere vermektedir, böylece pikseller evrişim katmanları yerine öz-dikkat mekanizmalarıyla işlenmektedir. Bu durum da ViT modellerinin CNN mimarilerinden daha iyi performans göstermesini ve genelleme yeteneklerinin daha yüksek olmasını sağlamaktadır [153].

Görü dönüştürücü yapısı Şekil 2.5'te verilmiştir. Şekilde gösterilen işlem adımları aşağıda özetlenmiştir [87], [153].



Şekil 2.5. Görü dönüştürücü [153].


ViT modellerinde, giriş görüntüsü ($x \in \mathbb{R}^{H \times W \times C}$), $P \times P$ boyutlu yamalara bölünmektedir. Bu bölme işleminden sonra elde edilen N adet (eşitlik (2.6)) yama düzeltilerilerek birer vektör haline getirilmektedir. Bu vektörler doğrusal olarak daha düşük boyutlu gömmelere (embedding) dönüştürülmektedir. Gömmelere pozisyon bilgisi eklenerek pozisyon kodlaması (positional encoding) gerçekleştirilmektedir. Böylece her yama konumsal bilgiyi de içerecek şekilde temsil edilmektedir (eşitlik (2.7)).

$$N = \frac{H \cdot W}{P^2} \quad (2.6)$$

$$Z = E + E_{pos} \quad (2.7)$$

Daha sonra yama gömmeleri ($Z \in \mathbb{R}^{(N+1) \times D}$), yamalar arasındaki benzerliği diziler halinde modellemek için dönüştürücü kodlayıcı bloğuna beslenmektedir. Dönüştürücü kodlayıcı bloğu ViT’te özniteliklerin çıkartıldığı yapıdır.

Dönüştürücü kodlayıcı bloğu Şekil 2.6’da görüldüğü gibi çok başlı dikkat (Multi-Head Self Attention (MHSA)) ve ileri beslemeli ağ (Feed-Forward Network (FFN)) katmanlarından oluşmaktadır. Burada ilk olarak girdi gömmeleri normalize edilmektedir. Normalize edilen yama yerleştirmeleri, ilişkilerin ve bağımlılıkların yakalandığı MHSA mekanizmasına iletilmektedir.



Şekil 2.6. Dönüştürücü kodlayıcı [153].

Şekil 2.6’da gösterilen MHSA bloğunda her bir yama için sorgu (Q), anahtar (K) ve değer (V) matrisleri oluşturulmaktadır. Giriş vektörü Z , sorgu (Q), anahtar (K) ve değer (V) matrislerinin oluşturulması için sırasıyla W_Q , W_K ve W_V ağırlıklarıyla çarpılmaktadır (eşitlik (2.8), (2.9), (2.10)).

$$Q = Z \cdot W_Q \quad (2.8)$$

$$K = Z \cdot W_K \quad (2.9)$$

$$V = Z \cdot W_V \quad (2.10)$$

Dikkat skorları, sorgu ve anahtar matrislerinin nokta çarpımı sonucunda elde edilmektedir. Bu çarpım sonucu, kaybolan gradyan sorununu önlemek amacıyla boyutun (D_k) kareköküne bölünmektedir. Bu matris bir softmax katmanından geçirilerek son çıktıyı vermek için değer matrisiyle çarpılmaktadır (eşitlik (2.11)).

$$Dikkat(Q, K, V) = softmax\left(\frac{Q \cdot K^T}{\sqrt{D_k}}\right) \cdot V \quad (2.11)$$

$$D_k = \frac{D}{h} \quad (2.12)$$

Burada D_k , her başlık için dikkat boyutunu belirtmektedir ve toplam boyutun (D) dikkat başlığı (head) sayısına (h) bölünmesiyle elde edilmektedir.

MHSA çıktısı, h adet farklı başlıktan gelen çıktıların birleştirilmesiyle elde edilmektedir. Bu dikkat başlıkları birleştirilerek yoğun (dense) bir katmandan geçirilerek MHSA çıktısı elde edilmektedir (eşitlik (2.13)).

$$MHSA(Z) = dense([head_1, head_2, \dots, head_h]) \quad (2.13)$$

MHSA çıktısı ve girdi yerleştirmeleri, orijinal bilginin korunması amacıyla öğe bazında (element-wise) toplanmaktadır. Bu ekleme işleminin ardından elde edilen çıktı normalize edilmektedir (eşitlik (2.14)). Böylece dikkat çıktısının girişle birlikte daha kararlı bir şekilde öğrenilmesi sağlanmaktadır.

$$Z' = LayerNorm(Z + MHSA(Z)) \quad (2.14)$$

Normalize edilen çıktı, doğrusal olmayan aktivasyon fonksiyonlarının (GeLu) uygulandığı FFN yapısından geçirilmektedir (eşitlik (2.15)).

$$Z'' = FFN(Z') \quad (2.15)$$

Önceki adımda olduğu gibi FFN katmanının girişi ve çıkışı eleman bazında eklenmektedir (eşitlik (2.16))

$$Z_{out} = LayerNorm(Z' + Z'') \quad (2.16)$$

Böylece kodlayıcının çıkışı, yani içerik vektörü, elde edilmektedir. Bu içerik vektörü daha sonra ViT modelinin sonuna eklenen bir sınıflandırıcı katmanı aracılığıyla sınıf etiketlerine dönüştürülmektedir [152].

2.4.3. Diğer derin öğrenme yapıları


2.4.3.1. Evrişimsel uzun-kısa vadeli bellek (Convolutional long short-term memory (ConvLSTM))

ConvLSTM katmanı, uzamsal (spatial) ve zamansal özellikler taşıyan verileri analiz etmek amacıyla 2015 yılında Shi et al. tarafından önerilmiştir [154]. Bu katman, video verileri, yağış tahminleri, sensör tabanlı insan etkinliği verileri gibi uzamsal-zamansal yapıya sahip veri türleri üzerinde çalışmak üzere tasarlanmıştır.

ConvLSTM katmanları, giriş verilerindeki zamansal bağımlılıkların yakalanmasına yardımcı olmaktadır. Bunu, klasik zaman serisi verilerinde olduğu gibi, geçmiş adımlardan

edinilen bilgileri geleceğe aktaran ve depolayan LSTM ağlarının özelliklerini koruyarak, uzamsal veriye uygun hale getirerek başarmaktadır. ConvLSTM katmanının iç çalışma yapısı Şekil 2.7'de gösterilmektedir.

Son yıllarda yapılan pek çok çalışmada, evrişim katmanlarının görüntü temsil yeteneklerinin, bu katmanlar tarafından çıkarılan öznitelikler arasındaki karşılıklı bağımlılıkların artırılmasıyla önemli ölçüde geliştirilebileceği gösterilmiştir. Bu doğrultuda LSTM'nin giriş ve çıkışlarına bağlı olan matris çarpımları yerine evrişim işlemleri kullanan ConvLSTM bloğu önerilmiştir. Böylece LSTM'in zamansal hafıza yönetimi ile CNN'lerin uzamsal öznitelik çıkarma gücü bir araya getirilmiştir. Bu yapı sayesinde, önceden eğitilmiş bir CNN modelinden çıkarılan öznitelik haritaları üzerinde ConvLSTM katmanları kullanılarak, yalnızca zaman serilerinde değil, uzamsal verilerde de bağımlılıkların modellenebileceği gösterilmiştir.



Şekil 2.7. ConvLSTM'in yapısı [151].

Tipik bir LSTM'de en temel bileşen bilgiyi depolamak için kullanılan hücre durumudur (c_t). Eğer giriş kapısı (i_t) aktive edilirse, giriş verisi depolanmaktadır; eğer unutma kapısı (f_t) aktive edilirse bir önceki hücre durumu (c_{t-1}) unutulmaktadır. Ayrıca çıkış kapısı (o_t) mevcut hücre durumunun (c_t) son gizli duruma (h_t) aktarılıp aktarılmayacağını kontrol etmektedir. Bu yapı klasik (vanilla) LSTM mimarisinin temelidir.

ConvLSTM katmanında ise girişler ($x_1, x_2, x_3, \dots$), hücre durumları ($c_1, c_2, c_3, \dots$), gizli durumlar ($h_1, h_2, h_3, \dots$) ve kapılar (i_t, f_t, o_t) üç boyutlu tensörlerdir. ConvLSTM katmanında girişler ve kapılar uzamsal (2 boyutlu) uzayda, ızgara benzeri bir şekilde vektörler olarak kabul edilmektedir. Belirli bir hücre için ConvLSTM katmanı, kendi konumundaki giriş verisini ve komşu hücrelerden gelen bilgileri kullanarak bir sonraki durumu tahmin etmektedir.

ConvLSTM'nin girdisi, her bir zaman adımı için bir öznitelik haritasıdır ($H \times W$) ve bu harita bir video karesi, hava durumu görüntüsü veya başka bir uzamsal veri olabilir. Her giriş karesi (X_t), bir önceki zaman adımından gelen gizli durum (h_{t-1}) ve hücre durumu (c_{t-1}) ile birlikte işlenmektedir. Kapılar (unutma kapısı, giriş kapısı, çıkış kapısı), gelen bilgilerin bir kısmını filtrelemekte veya düzenlemektedir. Aşağıda verilen denklemler bu temel prensibi açıklamaktadır. Giriş kapısı, hangi bilginin hücre durumuna dahil edileceğini belirlemektedir (eşitlik (2.17)).

$$i_t = \sigma(W_{x_i} * X_t + W_{h_i} * H_{t-1} + W_{c_i} \odot c_{t-1} + b_i) \quad (2.17)$$

Unutma kapısı, hücre durumundan hangi bilgilerin unutulacağını belirlemektedir (eşitlik (2.18)).

$$f_t = \sigma(W_{x_f} * X_t + W_{h_f} * H_{t-1} + W_{c_f} \odot c_{t-1} + b_f) \quad (2.18)$$

Yeni aday hücre durumu, geçerli zamandaki giriş ve önceki gizli durum kullanılarak hesaplanmaktadır. Hücre durumu, unutma kapısı, giriş kapısının çıkışı ve yeni hücre aday durumuna göre güncellenmektedir (eşitlik (2.19)).

$$C_t = f_t \odot C_{t-1} + i_t \odot \tanh(W_{x_c} * X_t + W_{h_c} * H_{t-1} + b_c) \quad (2.19)$$

Çıkış kapısı, gizli durumun hangi kısımlarının çıktıya aktarılacağını belirlemektedir (eşitlik (2.20)).

$$o_t = \sigma(W_{x_o} * X_t + W_{h_o} * H_{t-1} + W_{c_o} \odot C_{t-1} + b_o) \quad (2.20)$$

Yeni gizli durum, güncellenmiş hücre durumu ve çıkış kapısı aracılığıyla hesaplanmaktadır (eşitlik (2.21)).

$$H_t = o_t \odot \tanh(C_t) \quad (2.21)$$

Burada '*' işlemi evrişim işlemi, ' $\odot$ ' ise element bazında çarpım (Hadamart çarpımı) işlemidir. ConvLSTM hücresinde i_t giriş kapısını, f_t unutma kapısını, C_t hücre durumunu, o_t çıkış kapısını ve H_t ise gizli durumu temsil etmektedir. Kapıların aktivasyonu için kullanılan σ sigmoid, $\tanh$ ise hiperbolik tanjant fonksiyonudur. Eşitliklerde geçen W ağırlık değerlerini, b sapma (bias) değerlerini göstermektedir. Evrişim işlemleri sırasında satır ve sütun sayılarının eşit olması için işlemler boyunca dolgu (padding) işlemi uygulanmaktadır [151].

2.5. Kayıp Fonksiyonları

Maliyet fonksiyonu (cost function) olarak da bilinen kayıp fonksiyonu (loss function), bir sinir ağını veya makine öğrenmesi modelini eğitmek amacıyla kullanılan temel bileşenlerden biridir. Son on yılda araştırmacılar, makine öğrenmesi alanında ortalama karesel hata (mean squared error (MSE)) ve ortalama mutlak hata (mean absolute error (MAE)) gibi çeşitli kayıp fonksiyonları geliştirmişlerdir. Bununla birlikte, derin öğrenme uygulamalarında, ağların son katmanlarında genellikle bir sigmoid veya softmax fonksiyonları kullanıldığı için geleneksel kayıp fonksiyonlarıyla yapılan eğitim, ağ doğruluğunun ve verimliliğinin düşük olmasına yol açmaktadır [155].

Derin öğrenme uygulamalarında, kayıp fonksiyonu genellikle tahmin edilen değer ile gerçek değer arasındaki doğruluğu, benzerliği veya uyumu ölçmektedir. Aynı zamanda modelin öğrenme sürecini yönlendirerek, hangi örneklerle daha fazla odaklanması gerektiğini belirlemektedir. Bu nedenle derin ağların eğitiminde doğru kayıp fonksiyonlarının seçimi ağın performansının yüksek olması için seçilmesi gereken en önemli parametrelerdendir. Bununla birlikte eksiksiz bir ağ yapısı oluştururken, uygun bir kayıp fonksiyonunun seçilmesi veya tasarlanması da zorlu bir problemdir. Uygun bir şekilde tasarlanmış bir kayıp fonksiyonu, modelin hem test hem de genelleme performansını önemli ölçüde artırabilmektedir [155]. Literatürde sınıflandırma çalışmalarında kullanılan kayıp fonksiyonlarına örnek olarak ortalama karesel hata, LogCosh, çapraz entropi, odak kaybı, kategorik hinge, kosinüs benzerliği verilebilmektedir.

Ortalama karesel hata regresyon problemlerinde kullanılan en temel kayıp fonksiyonlarından biridir. Basitliği nedeniyle genellikle giriş düzeyinde öğrenme algoritmalarında tercih edilmektedir. Bu fonksiyon, tahmin edilen değer ile gerçek değer arasındaki farkın karesel ortalamasının alınması ile hesaplanmaktadır (eşitlik (2.22)). Her ne kadar regresyon problemlerinde sıklıkla kullanılıyor olsa da MSE, derin öğrenme algoritmalarında genellikle bir sigmoid veya softmax işlevi kullanıldığı için yetersiz kalmaktadır [155].

$$L_{MSE}(\hat{y}, y) = \frac{1}{2} \sum (y - \hat{y})^2 \quad (2.22)$$

Burada y , gerçek sınıf etiketi, $\hat{y}$ ise modelin tahmin ettiği sınıf etiketidir.

Ortalama karesel hatadan türetilen LogCosh kaybı regresyon problemleri için tasarlanmış olup, uç değerlerin etkisini azaltmak için ortalama karesel hata ve ortalama mutlak hata arasında bir denge kurmaktadır (eşitlik (2.23)) [156].

$$L(\hat{y}, y) = \sum_{c=1}^M \log(\cosh(\hat{y} - y)) \quad (2.23)$$

Küçük hatalarda MSE gibi davranırken, hata arttığında MAE gibi davranarak uç değerlerin etkisini sınırlandırmaktadır.

Çapraz entropi, derin sinir ağlarında sınıflandırma görevi için en yaygın kullanılan temel kayıp fonksiyonlarından biridir [20]. Çapraz entropi, modelin tahmin ettiği olasılık dağılımının gerçek etiket dağılımıyla olan mesafesini ölçerek, modelin tahmin başarısını değerlendirmektedir (eşitlik (2.24)) [155].

$$L_{CE}(\hat{y}, y) = - \sum_{c=1}^M y \log(\hat{y}) \quad (2.24)$$

Çapraz entropi değerinin düşük olması, modelin başarılı olduğunu ifade etmektedir.

Derin öğrenme algoritmalarında kullanılan kayıp fonksiyonlarında çoğunlukla çapraz entropi temel alınmaktadır. Özellikle dengesiz veri kümelerinin sınıflandırılması amacıyla kullanılan odak kaybı (eşitlik (2.25)), çapraz entropiye bir modülasyon faktörü eklenmesiyle oluşturulmuştur. Bu kayıp fonksiyonu, kolay örneklerin etkisini azaltarak modelin zor örneklerle odaklanmasını sağlamaktadır [157].

$$L_F(\hat{y}, y) = (1 - \hat{y})^\gamma L_{CE} \quad (2.25)$$

Burada γ hiperparametredir ve genellikle 2 olarak kabul edilmektedir.

Özellikle çok sınıflı sınıflandırma problemleri için kullanılan bir diğer kayıp fonksiyonu kategorik hingedir. Maksimum marjinal kayıp prensibiyle çalışarak modelin doğru sınıf için tahmin ettiği skoru yüksek tutmaya çalışırken yanlış sınıflar için skoru doğru sınıftan uzaklaştırmayı hedeflemektedir (eşitlik (2.26)) [98].

$$L_{hinge} = \max(negatif - pozitif + 1, 0) \quad (2.26)$$

$$pozitif = toplam(y * \hat{y}) \quad (2.27)$$

$$negatif = \max((1 - y) * \hat{y}) \quad (2.28)$$

Kosinüs benzerliği (cosine similarity), tahmin edilen ve gerçek vektörler arasındaki yön farkını (kosinüs açısını) minimize etmeye çalışan benzerlik tabanlı bir kayıp fonksiyonudur (eşitlik (2.29)). Açık küçüldükçe benzerliğin arttığı anlamına gelmektedir [156].

$$L_{cos} = 1 - \frac{y \cdot \hat{y}}{\|y\| \|\hat{y}\|} \quad (2.29)$$

Poisson kaybı, gerçek değerler ve tahmin edilen değerler arasındaki farklılığı Poisson dağılımı çerçevesinde ölçen kayıp fonksiyonudur. Modelin tahmin ettiği değerlerin gerçek etiketlerin Poisson dağılımına uygunluğunu ölçmektedir (eşitlik (2.30)) [156].

$$L(\hat{y}, y) = - \sum_{c=1}^M \hat{y}_c - y_c \log(\hat{y}_c) \quad (2.30)$$

KL sapması, tahmin edilen dağılımın gerçek dağılıma ne kadar uyumlu olduğunu ölçen istatistiksel bir ölçüttür (eşitlik (2.31)) [156].

$$L(\hat{y}, y) = - \sum_{c=1}^M y_c \log\left(\frac{y_c}{\hat{y}_c}\right) \quad (2.31)$$

2.6. Performans Değerlendirmesi

Önerilen algoritmanın başarısını belirlemek için doğruluk, kesinlik, hassasiyet (duyarlılık), özgüllük, F1-skoru ve AUC metrikleri kullanılmaktadır. Bu çalışmada veri kümesinin sunduğu sınıf etiketleri altın standart olarak kabul edilmektedir. Doğruluk, kesinlik, hassasiyet (duyarlılık), özgüllük ve F1-skoru hesaplanırken karışıklık matrisindeki doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerleri dikkate alınmaktadır. Şekil 2.8’de bu değerlerin Sınıf 1 için karışıklık matrisindeki konumları görsel olarak gösterilmiştir. Doğruluk, kesinlik, duyarlılık ve F1-skoru sırasıyla eşitlik (2.32), (2.33), (2.34), (2.35) ve (2.36)’da verilen formüllerle hesaplanmaktadır. Duyarlılık, testin gerçekten pozitif olan örneği doğru şekilde sınıflandırma oranını ifade ederken, özgüllük, gerçekten negatif olan örneği doğru şekilde sınıflandırma oranını göstermektedir. Kesinlik, testin pozitif olarak sınıflandırdığı örneklerin gerçekten ne kadarının pozitif olduğunu, doğruluk ise tüm sınıflandırmanın ne kadar doğru olduğunu belirtmektedir. F1-skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır ve özellikle dengesiz sınıf dağılımlarında daha doğru bir genel performans ölçütü sağlamaktadır.

$$Doğruluk = \frac{DP + DN}{DP + YN + DN + YP} \quad (2.32)$$

$$Kesinlik = \frac{DP}{DP + YP} \quad (2.33)$$

$$Duyarlılık = \frac{DP}{DP + YN} \quad (2.34)$$

$$Özgüllük = \frac{DN}{DN + YP} \quad (2.35)$$

$$F1 - skoru = \frac{2xDP}{2xDP + YN + YP} \quad (2.36)$$

Burada, DP doğru pozitif, DN doğru negatif, YN yanlış negatif ve YP yanlış pozitifdir [50], [158].

		Tahmin Edilen						
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Sınıf 5	...	Sınıf 15
Gerçek	Sınıf 1	DP	YN					
	Sınıf 2	YP	DN					
	Sınıf 3							
	Sınıf 4							
	Sınıf 5							
	...							
	Sınıf 15							

Şekil 2.8. Sınıf 1 için DP, DN, YP ve YN hesaplamalarını gösteren karışıklık matrisi.

Yakınsama bölgesi (Region of Convergence (ROC)) eğrisi, modelin sınıfları ayırt etme yeteneğini grafiksel olarak gözlemlemek amacıyla kullanılmaktadır. Bu eğri, farklı eşik değerlerinde DP ve YP oranlarının yani duyarlılık ve 1-özgüllük değerlerinin ilişkisini göstermektedir. Modelin sınıflar arasında ayırım yapma yeteneği bu eğrinin altındaki alan AUC değeri ile ifade edilmektedir [50].


2.7. Isı Haritaları

Görselleştirme teknikleri, derin öğrenme modellerinin karar verme süreçlerini daha şeffaf ve anlaşılabilir hale getirmek amacıyla kullanılan yöntemlerdir. Bu teknikler, modelin

kararını hangi özniteliklere dayanarak verdiğini ortaya koyarak kullanıcı güvenini artırmakta ve modelin yorumlanabilirliğini desteklemektedir [142].

Grad-CAM algoritması, derin öğrenme modellerinde en yaygın olarak kullanılan görselleştirme algoritmasıdır. Grad-CAM, modelin bir sınıfı tahmin ederken görüntü üzerinde hangi bölgelere odaklandığını görselleştirmek için kullanılmaktadır. Bu algorithmada ilk olarak, verilen görüntü için modelin son evrişim katmanındaki aktivasyonlar üzerinden hedef sınıfa ait gradyanlar hesaplanmaktadır. Bu gradyanlar, her kanalın sınıf tahminine olan katkısını ortaya koymaktadır. Ardından, gradyanlar küresel ortalama havuzlama işlemiyle nöron önem ağırlıklarına dönüştürülmektedir [159]. Elde edilen bu ağırlıklar, aktivasyon haritaları ile birleştirilerek sınıfla ilişkili bölgeleri vurgulayan bir ısı haritası oluşturulmaktadır. Bu ısı haritası, tahmin edilen sınıfla ilişkili en belirgin bölgeleri vurgulamak üzere orijinal görüntü üzerine bindirilerek sunulmaktadır [160].

Şekil 2.9’da jet renk haritası (jet color scheme) kullanılarak oluşturulan örnek Grad-CAM görüntüleri sunulmuştur.



Şekil 2.9. Grad-CAM görüntüleri.

3. MATERYAL VE METOD

3.1. Çalışmada Kullanılan Veri Kümesi

Bu çalışmada hem açık erişimli veri tabanlarından elde edilen hem de Başkent Üniversitesi Ankara Hastanesi’nden toplanan akciğer grafileri kullanılmıştır. Açık erişimli veriler, literatürde yaygın olarak kullanılan büyük ölçekli ve çeşitli patoloji sınıflarını içeren veri kümelerinden elde edilmiştir. Buna ek olarak Başkent Üniversitesi Ankara Hastanesi Radyoloji Bölümü’nden alınan veriler, etik kurul izni ile uzman doktor kontrolünde toplanmıştır. Hem açık erişimli veri kümelerinden alınan hem de Başkent Üniversitesi Ankara Hastanesi’nden toplanan tüm veriler birleştirilmiş, farklı sınıf sayılarına sahip alt veri kümeleri oluşturacak şekilde düzenlenmiştir. Böylece, veri çeşitliliği ve kalite açısından zengin ve özgün bir veri kümesi oluşturulmuştur. Bu kapsamlı veri kümeleri kullanılarak önerilen derin öğrenme modelinin hem farklı patoloji türlerini doğru şekilde ayırt edebilme hem de genelleştirme yeteneğinin artması amaçlanmıştır. Kullanılan tüm veri kaynaklarına ait görüntü sayıları Tablo 3.1’de verilmiştir. Her sınıfa ait örnek görüntüler ise Şekil 3.1’de sunulmuştur.

3.1.1. Başkent Üniversitesi Ankara Hastanesi veri tabanı

Başkent Üniversitesi Ankara Hastanesi veri kümesi özel olarak oluşturulmuştur. Bu veriler, Başkent Üniversitesi Ankara Hastanesi Radyoloji Bölümü ve Başkent Üniversitesi Mühendislik Fakültesi ortaklığında yürütülen “Yapay Zeka ile Normal ve Normal Olmayan Akciğer Grafilerinin Ayırt Edilmesi” başlıklı proje kapsamında, 07.04.2021 tarihli Başkent Üniversitesi Tıp ve Sağlık Bilimleri Araştırma Kurulu tarafından onaylanmış etik kurul raporu uyarınca toplanmıştır. Veri toplama adımları aşağıdaki sırayla gerçekleştirilmiştir:

- Hastanenin Bilgi İşlem Daire Başkanlığı aracılığıyla belirli tarih aralıklarında (Örneğin; 01.01.2020-01.01.2022), belirli anahtar kelimeleri (“pnömotoraks”, “kardiyomegali”, vs.) içeren radyoloji raporları sorgulanmıştır.
- Bu raporlar incelenerek yalnızca pozitif bulgu içeren (örneğin, “pnömotoraks bulguları görülmektedir.”) ve net tanı konulan kayıtlar seçilmiştir.
- Seçilen kayıtlara karşılık gelen akciğer grafileri hastanenin PACS sisteminden “.jpg” formatında dışa aktarılmıştır.
- Dışarı aktarılan görüntüler patoloji türüne göre klasörlere ayrıştırılmıştır.

Bu veri kümesinde; yalnızca tek patoloji içeren 121 adet pnömotoraks, 281 adet atelectazi, 260 adet plevral efüzyon, 100 adet nodül, 230 adet kardiyomegali, 56 adet konsolidasyon, 24 adet kitle ve 80 adet infiltrasyon olmak üzere toplam 1152 görüntü bulunmaktadır. Bu veriler doğrudan klinik ortamdan toplanmış olmaları nedeniyle gerçek dünya senaryolarını daha iyi yansıtmaktadır.

3.1.2. NIH Chest X-ray14 veri tabanı

Wang et al. tarafından 2017 yılında oluşturulan “ChestX-ray 8” adlı veri kümesi 32.717 adet hastadan elde edilen 108.948 adet akciğer grafisinden oluşmakta ve sekiz farklı patoloji sınıfını içermektedir. Bu veri kümesi daha sonra atelectazi, kardiyomegali, efüzyon, infiltrasyon, kitle, nodül, pnömoni, pnömotoraks, ödem, amfizem, pulmoner fibroz, plevral kalınlaşma ve fitik olmak üzere 14 patoloji sınıfını içerecek şekilde genişletilmiştir ve sonuç olarak 112.120 akciğer grafisinden oluşan “ChestX-ray14” veri kümesi adını almıştır [161].

ChestX-ray14 veri kümesi, literatürde derin öğrenmeye dayalı akciğer grafisi sınıflandırma çalışmalarında en sık kullanılan veri kümelerinden biridir. Bu çalışmada, söz konusu veri kümesi Kaggle platformu üzerinden (<https://www.kaggle.com/datasets/nih-chest-xrays/data>) 12 farklı klasöre bölünmüş şekilde indirilmiştir. Her klasörün içinde farklı etiketlere sahip görüntüler dağınık bir şekilde yer almaktadır. Veri kümesinde tek patolojiye ait görüntülerin yanı sıra birden fazla patoloji içeren görüntüler de bulunmaktadır. Bu çalışmada tek patolojiye ait görüntüler üzerinde çalışıldığı için veri kümesindeki tek patoloji içeren görüntülerin ayıklanması amacıyla görüntülerle birlikte indirilen excel dosyası kullanılmıştır. Ayıklama işlemi sırasında ilk olarak tek patolojiye sahip görüntüler belirlenmiş, daha sonra bu görüntüler ait oldukları patoloji sınıfına göre yeniden klasörlenmiştir. Bu veri kümesinden bulgu olmayan görüntüler dahil (58494 adet) toplam 88337 akciğer grafisi alınmıştır. Ancak bazı patoloji sınıflarındaki örnek sayısının yetersiz olması nedeniyle analizlerde yalnızca 13 farklı patolojiye ait veriler kullanılmıştır. Bu kapsamda; yalnızca tek patoloji içeren 2004 adet pnömotoraks, 4003 adet atelectazi, 3804 adet plevral efüzyon, 2602 adet akciğer nodülü, 1034 adet kardiyomegali, 1234 adet konsolidasyon, 599 adet ödem, 2068 adet kitle ve 2779 adet infiltrasyon görüntüsü çalışmaya dahil edilmiştir.

3.1.3. CheXpert veri tabanı

CheXpert, Stanford Health Care'de Ekim 2002 ile Temmuz 2017 tarihleri aralığında toplanan, 65240 hastadan çekilen 224316 akciğer grafisinden oluşan, büyük ölçekli ve çok etiketli bir veri kümesidir [162]. Çalışma kapsamında CheXpert veri kümesine erişim, Stanford Üniversitesinin veri paylaşım platformu olan “<https://stanfordaimi.azurewebsites.net/>” adresinden, “.edu.tr” uzantılı e-posta adresiyle kayıt yaptırılarak sağlanmıştır. “Stanford Üniversitesi Veri Kümesi Araştırma Kullanım Sözleşmesi”nin onaylanmasının ardından, etiketli görüntüler “.dcm” (Digital Imaging and Communications in Medicine) formatında indirilmiştir.

Sunulan veri kümesinde tek patoloji içeren akciğer grafilerinin yanı sıra birden fazla patoloji içeren ya da belirsiz olarak etiketlenen (örneğin; atelettazi var, plevral efüzyon belli değil (not certain)) akciğer grafileri de bulunmaktadır. Bu çalışmada yalnızca tek patolojiye sahip görüntüler kullanıldığından, etiket bilgilerinin yer aldığı excel dosyası aracılığıyla bu görüntüler veri kümesinden ayıklanmıştır. Veriler ilk olarak “.dcm” formatından “.jpg” formatına dönüştürülmüş ardından içerdiği patoloji türüne göre klasörlere ayrıştırılmıştır. Bu süreç sonunda, CheXpert veri kümesinden 2108 pnömotoraks, 1087 atelettazi, 2425 plevral efüzyon, 1034 kardiyomegali, 537 konsolidasyon, 2257 ödem ve 1122 kırık görüntüsü olmak üzere yalnızca tek patoloji içeren toplam 10570 veri alınmıştır.

3.1.4. COVID-19 Radyografi veri tabanı

Çalışma kapsamında kullanılan COVID-19, akciğer opasitesi ve normal akciğer grafileri açık erişimli bir veri kümesi olan COVID-19 Radyografi Veri Tabanı'ndan alınmıştır. Bu veri tabanı, Katar Üniversitesi (Doha, Katar) ve Dhaka Üniversitesi (Bangladeş) öncülüğünde, Pakistan ve Malezya'dan araştırmacıların da katılımıyla uluslararası bir iş birliği sonucunda oluşturulmuştur [163], [164]. Veri kümesinde 3616 COVID-19, 1345 viral pnömoni, 6012 akciğer opasitesi ve 10192 normal akciğer grafisi bulunmaktadır. Çalışmada bu veri kümesindeki COVID-19, akciğer opasitesi ve normal grafilerin tamamı kullanılmıştır.

3.1.5. Tüberküloz akciğer grafisi veri tabanı

3500 tüberküloz ve 3500 sağlıklı akciğer grafisinden oluşan bu veri kümesi, Katar Üniversitesi (Doha, Katar) ve Dhaka Üniversitesi (Bangladeş) araştırmacılarının, Malezya'daki iş birliği ortakları ile birlikte, Hamad Medical Corporation ve Bangladeş'te

görev yapan tıp uzmanlarının katılımıyla yürütülen ortak bir çalışma kapsamında oluşturulmuştur [165]. Bu veri kümesinin bir kısmı (700 görüntü) açık erişimlidir, ancak 2800 TB görüntüsü NIAID (National Institute of Allergy and Infectious Diseases, Ministry of Health, Republic of Belarus) TB portalından [166] veri paylaşım anlaşması imzalanarak alınmıştır. Çalışma kapsamında bu veri kümesindeki TB görüntülerinin tamamı (3500 görüntü) kullanılmıştır.

3.1.6. Pnömoni akciğer grafisi veri tabanı (Kaggle)


Pnömoni grafileri, Kaggle platformundan ([167]) alınmıştır. Bu görüntülere ilişkin teşhisler, sınıflandırma modelinin eğitimi amacıyla kullanılmadan önce iki uzman radyolog tarafından derecelendirilmiş ve olası değerlendirme hatalarını en aza indirmek amacıyla değerlendirme kümesi üçüncü bir uzman tarafından da kontrol edilmiştir. Bu çalışma kapsamında, veri kümesinden yalnızca pnömoni görüntüleri alınmıştır. Açık erişimli olarak sunulan bu veri kümesinde 1493 adet viral pnömoni, 2772 adet bakteriyel pnömoni olmak üzere toplamda 4265 pnömoni grafisi bulunmakta olup, bu görüntülerin tamamı analizlerde kullanılmıştır.

3.1.7. Fibröz akciğer grafisi veri tabanı (Kaggle)

Bu çalışma kapsamında kullanılan fibröz akciğer grafileri, Kaggle platformunda ([168]) açık erişimli olarak sunulan veri kümesinden alınmıştır. Bu veri kümesi, yalnızca fibröz patolojisini içeren 1686 adet etiketli akciğer grafisinden oluşmaktadır.

3.1.8. JSRT veri tabanı

JSRT (Japanese Society of Radiological Technology), Japon Radyoloji Teknolojisi Derneği tarafından oluşturulmuş ve araştırma amaçlı kullanıma sunulmuş bir veri tabanıdır. Bu veri tabanı, akciğer nodülü bulunan ve bulunmayan akciğer grafilerinden oluşmakta olup, aynı zamanda temel klinik bilgileri de içermektedir [169]. JSRT veri kümesi 154 nodül içeren, 93 nodül içermeyen toplam 247 akciğer grafisinden oluşmaktadır. Bu çalışma kapsamında yalnızca nodül patolojisine sahip olan 154 görüntü kullanılmıştır.



Şekil 3.1. Örnek akciğer grafileri.

Tablo 3.1. Veri kümesi dağılımı.

Sınıf Etiketi	Başkent Üniversitesi Ankara Hastanesi Veri Tabanı	NIH Chest X-ray14 Veri Tabanı	CheXpert Veri Tabanı	COVID-19 Radyografi Veri Tabanı	Tüberküloz (TB) Akciğer Grafisi Veri Tabanı	Kaggle Pnömoni Akciğer Grafisi Veri Tabanı	Kaggle Fibröz Akciğer Grafisi Veri Tabanı	JSRT Veri Tabanı	TOPLAM
COVID-19				3616					3616
TB					3500				3500
Viral Pnömoni						1493			1493
Bakteriyel Pnömoni						2772			2772
Akciğer Opasitesi				6012					6012
Fibröz							1686		1686
Pnömotoraks	121	2004	2108						4233
Normal				10192					10192
Plevral Efüzyon	260	3804	2425						6489
Atelektazi	281	4003	1087						5371
Kardiyomegali	230	1034	1034						2298
Konsolidasyon	56	1234	537						1827
Ödem		599	2257						2856
Kırık			1122						1122
Nodül	100	2602						154	2856
Kitle	24	2068							2092
İnfiltrasyon	80	2779							2859
TOPLAM	1152	20127	10570	19820	3500	4265	1686	154	61274

Çalışma kapsamında modelin farklı sınıf yapılarındaki ve dağılımlarındaki performansını değerlendirebilmek amacıyla çeşitli sınıf sayısına sahip alt veri kümeleri oluşturulmuştur. Bu alt kümeler hem gerçekleştirilen ön analizlerde hem de modelin sınıflandırma performansının farklı senaryolarda test edilebilmesi amacıyla kullanılmıştır. Oluşturulan tüm veri kümeleri %80 eğitim, %20 test (görülmeyen veriler) olacak şekilde ikiye ayrılmıştır. Model eğitimi sırasında aşırı uyumun (overfitting) üstesinden gelmek ve modelin genelleme yeteneğini değerlendirebilmek için eğitim verilerinin %10'u validasyon kümesi olarak kullanılmıştır. Bu alt kümeleri ayırırken rastgele karıştırma (shuffle) yöntemi tercih edilmiştir. Tüm veri sınıfları için eğitim, validasyon ve test sayıları Tablo 3.2’de detaylı olarak sunulmuştur.

Tablo 3.2. Veri kümesi ayrımı

Sınıf	Eğitim	Validasyon	Test	Toplam
COVID-19	2604	289	723	3616
TB	2520	280	700	3500
Viral Pnömoni	1075	119	299	1493
Bakteriyel Pnömoni	1996	222	554	2772
Akciğer Opasitesi	4329	481	1202	6012
Fibröz	1214	135	337	1686
Pnömotoraks	3047	339	847	4233
Nodül	2056	229	571	2856
Plevral Efüzyon	4672	519	1298	6489
Atelektazi	3867	430	1074	5371
Kardiyomegali	1654	184	460	2298
Konsolidasyon	1316	146	365	1827
Ödem	2057	228	571	2856
Kırık	808	90	224	1122
Kitle	1507	167	418	2092
İnfiltrasyon	2058	299	572	2859
Normal	7339	815	2038	10192
TOPLAM	44119	4972	12253	61274

3.2. Önerilen Modeller

Bu çalışma kapsamında, akciğer grafilerinin sınıflandırılması amacıyla yedi farklı derin öğrenme mimarisi geliştirilmiştir. Tüm mimarilerde öznitelik çıkarımı için omurga ağı olarak ImageNet veri kümesi ile önceden eğitilmiş DenseNet201 tercih edilmiştir. Bunun nedeni, DenseNet201'in hem literatürde hem de yapılan ön çalışmalarda en yüksek sınıflandırma performansını göstermiş olmasıdır [142], [149], [170], [171]. Geliştirilen modellerde DenseNet201'den çıkartılan özniteliklerin daha güçlü temsil edilmesi ve sınıflandırma başarısının artırılması amacıyla SE bloğu, dönüştürücü kodlayıcı, ConvLSTM ve GAP katmanları çeşitli kombinasyonlarla mimariye entegre edilmiştir. Bu farklı blokların modele entegrasyonu ile uzamsal ve kanal bazlı özniteliklerin etkin bir şekilde çıkartılmasını sağlayarak sınıflandırma başarısını artırmak amaçlanmıştır. Kurulan farklı mimariler ayrıntılı olarak analiz edilmiş ve akciğer grafilerinin en yüksek doğrulukla sınıflandırılmasını sağlayacak en uygun modelin belirlenmesi hedeflenmiştir.


Örneğin, Model 1'de yalnızca dönüştürücü bloğu kullanılırken, Model 3'te hem dönüştürücü bloğu hem de SE blokları paralel olarak uygulanmıştır. Model 4'te ise dönüştürücü bloğu ve ConvLSTM+SE blokları paralel olarak kullanılmıştır. Model 2'de, ConvLSTM ve SE çıktıları dönüştürücü bloğuna beslenmiştir böylece dikkat mekanizması öncesi filtreleme yapılmıştır. Model 5 ve 6 daha hafif yapılardır; biri SE+GAP, diğeri ConvLSTM+GAP şeklindedir. Model 7'de ise dönüştürücü bloğu ve ConvLSTM paralel olarak kullanılarak bu iki yapının tamamlayıcı özelliklerinden yararlanmak amaçlanmıştır. Bu karşılaştırmalı yapılar sayesinde, her bloğun katkısı sistematik olarak değerlendirilmiş ve akciğer grafilerinin sınıflandırılması görevi için en uygun mimari belirlenmiştir.

Yapılan tüm analizlerde görüntüler, farklı veri kümelerinden alındığı için analizden önce DenseNet201 girişine uygun olacak şekilde 224x224 boyutuna yeniden boyutlandırılmıştır. Ardından görüntülerdeki pikseller 255'e bölünerek 0-1 aralığına yeniden ölçeklendirilmiştir [113]. Ayrıca veri kümesinin boyutunun neden olabileceği aşırı uyumu önlemek amacıyla yalnızca eğitim verilerine döndürme ve yakınlaştırma gibi veri artırma teknikleri uygulanmıştır. Model eğitiminden optimize edici olarak Stokastik Gradyan İniş (SGD (Stochastic Gradient Descent)) kullanılmış, öğrenme oranı (LR (Learning Rate)) 0,01 olarak belirlenmiştir. Validasyon kaybının iyileşmesi 3 epok boyunca durduğunda, öğrenme oranını 0,7 kat azaltmak için ReduceLROnPlateau tekniği kullanılmıştır. Kategorik çapraz entropi, kayıp fonksiyonu olarak seçilmiştir. Modelin değerlendirilmesi için tüm süreçler, TensorFlow çerçevesini kullanan, NVIDIA L4 GPU sağlanan Google Colab Pro+ platformunda yürütülmüştür. Eğitimin ardından model, görünmeyen test kümesiyle test

edilmiş ve performans değerlendirmeleri yapılmıştır. Model 50 epok kullanılarak eğitilmiş ve en az validasyon kaybına sahip model ağırlıkları test için seçilmiştir.

3.2.1. Model 1


Önerilen model Şekil 3.2’de gösterilmektedir. Bu model, önceden eğitilmiş DenseNet201 ve dönüştürücü kodlayıcıya dayanmaktadır. Modelin omurgasını oluşturan DenseNet201, grafilardan uzamsal özniteliklerin çıkarılmasından sorumludur. DenseNet201’in son evrişim katmanından elde edilen öznitelik haritasının her bir kanalı, Wang et al. tarafından yapılan çalışmada ([91]) önerildiği gibi yamalara bölünmek yerine dönüştürücü kodlayıcıya tam bir yama olarak beslenmektedir. Böylece hem yerel hem de küresel bilgilerin korunması hedeflenmiştir. Bu kanal bazlı yamalar kodlama (embedding) işlemine tabi tutularak vektör temsiline dönüştürülmekte ve ardından normalize edilmektedir. Normalize edilen yama yerleştirmeleri, ilişkilerin ve bağımlılıkların yakalanması amacıyla MHSA katmanındaki çoklu paralel öz-dikkat başlıklarına beslenmektedir. MHSA çıktısında, elde edilen çıktı ve girdi yerleştirmeleri, orijinal bilginin korunması amacıyla öge bazında (element-wise) toplanmaktadır. Bu ekleme işleminin ardından normalleştirilmiş çıktı, doğrusal olmayan aktivasyon fonksiyonlarının (GeLU) uygulandığı MLP katmanından geçirilmektedir. Önceki adımda olduğu gibi MLP katmanının girişi ve çıkışı eleman bazında eklenmekte, böylece kodlayıcının çıkışı elde edilmektedir. Bu çalışmada dönüştürücü kodlayıcı 16 dikkat başlığına sahip 6 adet kodlayıcı bloğundan oluşacak şekilde tasarlanmıştır. Dönüştürücü kodlayıcının çıkışı, ReLU aktivasyonu ile üç yoğun katmandan oluşan MLP’ye beslenmektedir. Her yoğun katmandan sonra %20 bırakma uygulanmaktadır. Son olarak, Densenet201’den sonra uygulanan GAP işlemi ile özetlenen çıktı ve dönüştürücü kodlayıcının MLP katmanının çıkışı birleştirilerek elde edilen öznitelikler sınıflandırma işlemi için yoğun bir katmandan geçirilmektedir.



Şekil 3.2. Model 1 blok diyagramı.

3.2.2. Model 2


Önerilen model Şekil 3.3'te gösterilmektedir. Bu model DenseNet201, ConvLSTM, SE ve dönüştürücü kodlayıcı bileşenlerinden oluşan hibrit bir yapıya sahiptir. Modelin omurgasını oluşturan DenseNet201, grafilerden uzamsal özniteliklerin çıkartılmasından sorumludur. DenseNet201'in çıkışından elde edilen öznitelik haritaları, 512 filtreye sahip ConvLSTM katmanından geçirilmektedir, böylece kanal temelli uzamsal örüntüler işlenerek modelin daha anlamlı bölgelere dikkat etmesi sağlanmaktadır. ConvLSTM katmanının çıktısına, önemli özniteliklerin ön plana çıkarılması ve önemsiz olanların bastırılması amacıyla SE uygulanmaktadır. SE bloğu, her kanal için küresel ortalama havuzlama ile öznitelikleri sıkıştırmakta ve kanal bazında dikkat katsayıları oluşturarak giriş verisini yeniden ölçeklendirmektedir. SE çıkışında elde edilen öznitelik haritalarının her bir kanalı, bir yama olarak kabul edilerek dönüştürücü kodlayıcıya girmeden önce kodlama ve yerleştirme (embedding) işlemine tabi tutulmaktadır. Kodlama ve yerleştirme işlemi sonrasında yamalar normalize edilmekte ve bu normalleştirilmiş yama yerleştirmeleri MHSA mekanizmasına iletilmektedir. MHSA bloğu görüntüdeki öznitelikler arası ilişkilerin ve bağımlılıkların daha iyi öğrenilmesini sağlayarak modelin temsil gücünü artırmaktadır. MHSA katmanının çıktısı, orijinal bilgiyi korumak için girdi yerleştirmelerine öge bazında (element-wise) eklenmektedir. Bu eklemenin ardından normalleştirilmiş çıktıya, MLP katmanında GeLU fonksiyonu uygulanmaktadır. Önceki adıma benzer şekilde, MLP katmanının giriş ve çıkışı eleman bazında eklenerek kodlayıcının çıkışı elde edilmektedir. Bu çalışmada kodlayıcı 16 dikkat başlığı içeren 6 adet kodlayıcı bloğundan oluşacak şekilde tasarlanmıştır. Paralel bir işlem olarak ConvLSTM çıktısındaki öznitelik haritalarına GAP işlemi uygulanmaktadır. GAP, her kanal için uzamsal ortalama olarak sabit boyutlu bir vektör üretmekte ve bu özet bilgi, dönüştürücü kodlayıcının çıktısıyla birleştirilmektedir. Bu birleşim vektörü yoğun bir katmandan geçirilerek sınıf etiketleri üretilmektedir.



Şekil 3.3. Model 2 blok diyagramı.

3.2.3. Model 3

Bu model DenseNet201, dönüştürücü kodlayıcı ve SE bloklarından oluşmaktadır. Önerilen algoritmanın mimarisi Şekil 3.4'te verilmiştir. Algoritma, temsili özniteliklerin çıkartılması için omurga modeli olarak DenseNet201'i kullanmaktadır. DenseNet201'in çıktısı doğrudan dönüştürücü kodlayıcıya aktarılmaktadır. Önerilen yaklaşımda, DenseNet201 çıktısından elde edilen uzamsal özniteliklerin her bir kanalı birer yama olarak değerlendirilmektedir. Yamalar, dönüştürücü kodlayıcıya girmeden önce kodlama ve yerleştirme (embedding) işlemine tabi tutulmaktadır. Daha sonra dönüştürücü kodlayıcıda giriş yamaları normalize edilmektedir. Normalize edilmiş yama yerleştirmeleri MHSA mekanizmasına aktarılmakta ve girişler arasındaki ilişkiler etkin biçimde modellenmektedir. MHSA katmanının çıktısı, orijinal bilginin korunabilmesi amacıyla giriş gömmeleri ile öğe bazında (element-wise) toplanmaktadır. Bu toplamının ardından normleştirilmiş çıktı, GeLU aktivasyon fonksiyonunun uygulandığı MLP'ye gönderilmektedir. Önceki adıma benzer şekilde, MLP katmanının giriş ve çıkışı eleman bazında eklenmektedir. Böylece kodlayıcının çıkışı türetilmektedir. Bu çalışmada kodlayıcı 16 dikkat başlığı içeren 6 adet kodlayıcı bloğundan oluşacak şekilde tasarlanmıştır. Dönüştürücü kodlayıcıya paralel olarak SE bloğu, DenseNet201'in çıkışında elde edilen öznitelik haritasındaki daha az önemli öznitelikleri bastırarak önemli bilgilerin daha fazla vurgulanmasını sağlamaktadır. Son aşamada dönüştürücü kodlayıcı ve SE bloğunun çıkışları birleştirilerek elde edilen vektör, sınıflandırma işlemi için bir softmax katmanına aktarılmaktadır.




Şekil 3.4. Model 3 blok diyagramı.

3.2.4. Model 4

Şekil 3.5’te görüldüğü gibi önerilen algoritma DenseNet201, ConvLSTM, SE ve dönüştürücü kodlayıcı bileşenlerine dayanmaktadır. Algoritma, temsili özneteliklerin çıkartılması için omurga modeli olarak DenseNet201’i kullanmaktadır. DenseNet201


tarafından çıkartılan öznetelikler doğrudan dönüştürücü kodlayıcıya aktarılmaktadır. Önerilen yaklaşımda, DenseNet201'den çıkarılan öznetelik haritasının her kanalı, bir yama olarak kabul edilmektedir. Bu yamalar, dönüştürücü kodlayıcıya girmeden önce kodlama ve yerleştirme işlemine tabi tutulmaktadır. Daha sonra dönüştürücü kodlayıcıda giriş yamaları normalize edilmektedir. Bu normalleştirilmiş yama yerleştirmeleri MHSA katmanı içindeki çok başlı paralel öz-dikkat bloğuna gönderilmekte böylece ilişkilerin ve bağımlılıkların öğrenilmesi sağlanmaktadır. MHSA katmanının çıkışında elde edilen çıktı, orijinal bilgiyi korumak için girdi yerleştirmeleriyle öge bazında toplanmaktadır. Bu eklemenin ardından normalleştirilmiş çıktı, GeLU aktivasyon fonksiyonunu uygulayan bir MLP'ye gönderilmektedir. Önceki adıma benzer şekilde, MLP katmanının giriş ve çıkışı eleman bazında eklenmektedir. Böylece kodlayıcının çıkışı türetilmektedir. Bu çalışmada kodlayıcı 16 dikkat başlığı içeren 6 adet kodlayıcı bloğundan oluşacak şekilde tasarlanmıştır. Dönüştürücü kodlayıcıya paralel olarak DenseNet201'den çıkartılan öznetelik haritalar, 512 filtreye sahip ConvLSTM katmanından geçirilmektedir, böylece öznetelik haritalarındaki uzamsal bağımlılıklar modellenerek gereksiz bilgilerin etkisinin azaltılması ve önemli örüntülerin güçlendirilmesi sağlanmaktadır. ConvLSTM katmanının çıkışından elde edilen öznetelik haritasına uygulanan SE bloğu sayesinde ise, kanal bazında dikkat mekanizması devreye alınarak, önemli öznetelikler vurgulanmakta ve önemsiz olanlar zayıflatılmaktadır. Son aşamada dönüştürücü kodlayıcı ve SE bloğunun çıkışları birleştirilerek elde edilen vektörden sınıf etiketlerinin bulunması için bir softmax katmanı uygulanmaktadır.



Şekil 3.5. Model 4 blok diyagramı.

3.2.5. Model 5


Önerilen model Şekil 3.6'da gösterilmekte olup DenseNet201 ve SE bloklarından oluşmaktadır. Modelde, temsili özneteliklerin çıkartılması için omurga modeli olarak DenseNet201 kullanılmaktadır. DenseNet201'in çıktısı, önemli olan özneteliklere öncelik vermek ve önemli olmayanları bastırmak amacıyla SE bloğuna beslenmektedir. Buna paralel olarak, aynı öznetelik haritalarına GAP uygulanmakta ve böylece her kanalın uzamsal ortalaması alınarak öznetelikler özetlenmektedir. GAP işlemi sayesinde parametre sayısı azaltılarak modelin genelleme yeteneği artırılmaktadır. Son olarak SE ve GAP bloklarının çıktısı birleştirilmektedir. Birleştirilen öznetelik vektörü yoğun bir katmandan geçirilerek nihai sınıf etiketleri elde edilmektedir.



Şekil 3.6. Model 5 blok diyagramı.

3.2.6. Model 6


Önerilen model Şekil 3.7'de verilmiştir. Şekilde görüldüğü gibi model DenseNet201 ve ConvLSTM katmanlarına dayanmaktadır. Algoritmada, temsili özneteliklerin çıkartılması için omurga modeli olarak DenseNet201 kullanılmaktadır. DenseNet201'in çıkışında elde edilen öznetelik haritalarındaki uzamsal bağımlılıkları modellemek ve daha az anlamlı bilgilerin etkisinin azaltılması amacıyla ConvLSTM katmanı uygulanmaktadır. ConvLSTM'e paralel olarak DenseNet201'in çıkışındaki öznetelik haritalarına GAP uygulanarak her kanal için özet temsiller elde edilmektedir. Son olarak ConvLSTM ve GAP katmanlarının çıktısı birleştirilmektedir. Birleştirilen öznetelik vektörü yoğun bir katmandan geçirilerek nihai sınıflandırma işlemi gerçekleştirilmektedir.



Şekil 3.7. Model 6 blok diyagramı.

3.2.7. Model 7

Şekil 3.8'deki blok diyagramda da görüldüğü gibi önerilen algoritma DenseNet201, ConvLSTM ve dönüştürücü kodlayıcı bileşenlerine dayanmaktadır. Algoritma, temsili öz niteliklerin çıkartılması için omurga modeli olarak DenseNet201'i kullanmaktadır. DenseNet201 tarafından çıkartılan öz nitelikler doğrudan dönüştürücü kodlayıcıya aktarılmaktadır. Önerilen yaklaşımda, DenseNet201'in çıktısından elde edilen öz nitelik haritasının her kanalı, bir yama olarak kabul edilmektedir. Bu yamalar, dönüştürücü kodlayıcıya girmeden önce kodlama ve yerleştirme işlemine tabi tutulmaktadır. Daha sonra dönüştürücü kodlayıcıda giriş yamaları normalize edilmektedir. Bu normalleştirilmiş yama yerleştirmeleri MHSA katmanı içindeki çok başlı paralel öz-dikkat bloğuna gönderilmekte böylece ilişkilerin ve bağımlılıkların yakalanması kolaylaştırılmaktadır. MHSA katmanının çıktısı, orijinal bilgiyi korumak için girdi yerleştirmeleri ile öge bazında toplanmaktadır. Bu toplama işleminin ardından normalleştirilmiş çıktı, GeLU aktivasyon fonksiyonlarının uygulandığı bir MLP'ye gönderilmektedir. Önceki adıma benzer şekilde, MLP katmanının giriş ve çıkışı öge bazında toplanmaktadır. Böylece kodlayıcının çıkışı türetilmektedir. Bu çalışmada kodlayıcı 16 dikkat başlığı içeren 6 adet kodlayıcı bloğundan oluşacak şekilde tasarlanmıştır. Dönüştürücü kodlayıcıya paralel olarak DenseNet201'den çıkartılan öz nitelik haritaları, 512 filtreye sahip ConvLSTM katmanından geçirilmektedir, böylece öz nitelik haritalarındaki uzamsal bağımlılıklar modellenerek daha az anlamlı bilgilerin etkisinin azaltılması sağlanmaktadır. Son aşamada dönüştürücü kodlayıcı ve ConvLSTM bloğunun çıktıları birleştirilerek oluşturulan vektör, sınıflandırma işlemi için softmax katmanına aktarılmaktadır.



Şekil 3.8. Model 7 blok diyagramı.

3.3. Önerilen Kayıp Fonksiyonları

Bu çalışmada model performansını iyileştirmek amacıyla hibrit, dinamik ve penaltı terimi içeren yeni kayıp fonksiyonları önerilmiştir. Dinamik ve hibrit kayıp fonksiyonlarının tasarımında temel alınacak iki fonksiyon, önerilen model üzerinde ve literatürdeki başarılı kayıp fonksiyonları ile gerçekleştirilen ön analizler sayesinde belirlenmiştir (Bölüm 4.2.1).

Hibrit yaklaşımda ön analizlerle belirlenen iki kayıp fonksiyonunun güçlü yönlerinin birleştirilmesiyle modelin daha dengeli bir öğrenme sağlayarak daha yüksek performansa ulaşması hedeflenmiştir. Dinamik yaklaşımda ise, eğitim süreci boyunca modelin öğrenme durumu izlenmiş, farklı aşamalarda uygun kayıp fonksiyonlarının kullanılması ile daha etkili bir öğrenme ve yüksek performans elde edilmesi amaçlanmıştır. Ek olarak modelin sınıf dengesizliklerine karşı daha duyarlı olmasını sağlamak amacıyla önerilen penaltı terimi KÇE fonksiyonuna entegre edilmiştir. Son olarak topluluk tabanlı yaklaşımlar ile önerilen kayıp fonksiyonlarının çıktıları birleştirilmiş, böylece farklı fonksiyonların güçlü yönlerinden faydalanılarak modelin genel performansının artırılması hedeflenmiştir.

3.3.1. Hibrit kayıp fonksiyonları

Farklı kayıp fonksiyonlarının ağırlıklandırılarak bir araya getirilmesiyle oluşturulan hibrit kayıp fonksiyonları derin öğrenme modellerinde performansı artırmak amacıyla kullanılan etkili bir yaklaşımdır [95], [97], [99], [15], [101], [93]. Bu yaklaşımda farklı kayıp fonksiyonlarının güçlü yönleri birleştirilerek model performansının iyileştirilmesi hedeflenmiştir.

Bu çalışma kapsamında ön analizler sonucunda en yüksek performansı gösteren iki kayıp fonksiyonu belirlenmiş (Bölüm 4.2.1) ve bu fonksiyonlar hibrit yapıda birleştirilerek

yeni bir toplam kayıp fonksiyonu önerilmiştir. Bu iki fonksiyonun seçilmesinin nedeni, ayrı ayrı kullanıldıklarında sınıflandırma performansı açısından en yüksek sonuçları üretmiş olmalarıdır. Böylece her iki fonksiyonun avantajlarını bir araya getirerek daha başarılı bir sınıflandırma performansının elde edilmesi amaçlanmıştır. En başarılı iki fonksiyon olan KÇE ve KH fonksiyonlarının birleşimiyle oluşturulan hibrit kayıp fonksiyonu eşitlik (3.1)'de verilmiştir.

$$L = w_1 * L_{kçe} + w_2 * L_{kh} \quad (3.1)$$

Burada w_1 ve w_2 kayıp fonksiyonları için belirlenen ağırlıklardır. Bu ağırlıklar $w_1 + w_2 = 1$ koşulunu sağlamakta olup çalışma en yüksek performansı sağlayacak şekilde deneysel olarak belirlenmiştir. Önerilen bu yapıda KÇE fonksiyonu, modelin doğru olan sınıfa daha yüksek olasılık vermesini sağlarken; KH fonksiyonu, doğru sınıf olasılıklarının yanlış sınıf olasılıklarından uzaklaşmasına katkı sunmaktadır [98].

3.3.2. Dinamik kayıp fonksiyonları


Dinamik olarak değişen kayıp fonksiyonu, modelin bir kayıp fonksiyonuyla eğitime başlamasını ve belirli bir epoktan sonra modelin eğitime farklı bir kayıp fonksiyonuyla devam etmesini ifade etmektedir. Bu yaklaşımla model, eğitim sürecinin ilk aşamasında birinci kayıp fonksiyonunun güçlü yönlerinden, sonraki aşamada ise ikinci fonksiyonunun avantajlarından faydalanmaktadır. Böylece genel sınıflandırma performansının artırılması amaçlanmaktadır.

Bu çalışmada Bölüm 4.2.1'de seçimi açıklanan iki kayıp fonksiyonu (KÇE ve KH) farklı kombinasyonlarda dinamik olarak kullanılmıştır. Örneğin eğitim sürecine KÇE ile başlandığında modelin doğru sınıflara daha yüksek olasılıklar vermesi sağlanmış, ardından KH kaybı ile eğitime devam edildiğinde doğru ve yanlış sınıflar arasındaki karar sınırları daha belirgin hale gelmiş, böylece modelin genel sınıflandırma performansı artırılmıştır.

Hibrit yöntem aşağıda sunulan 4 farklı yaklaşım ile uygulanmıştır:

- Model, ilk olarak birinci kayıp fonksiyonu ile belirlenen epok boyunca eğitilmiş, ardından eğitime ikinci kayıp fonksiyonu ile devam edilmiştir. (Şekil 3.9.a)
- Model, ilk olarak ikinci kayıp fonksiyonu ile belirlenen epok boyunca eğitilmiş, ardından eğitime birinci kayıp fonksiyonu ile devam edilmiştir.

- Model, ilk olarak birinci kayıp fonksiyonuyla belirlenen epok boyunca eğitilmiş, ardından eğitime ikinci kayıp fonksiyonu kullanılarak en yüksek test doğruluğunun elde edildiği epoktan itibaren devam edilmiştir (Şekil 3.9.b).
- Model, ilk olarak ikinci kayıp fonksiyonuyla belirlenen epok boyunca eğitilmiş, ardından eğitime birinci kayıp fonksiyonu kullanılarak en yüksek test doğruluğunun elde edildiği epoktan itibaren devam edilmiştir.



Şekil 3.9. Dinamik kayıp fonksiyonu eğrisi- a) Yaklaşım 1, b) Yaklaşım 2.

Bunlara ek olarak, dinamik kayıp fonksiyonu için farklı bir yaklaşım daha önerilmiştir. Bu yaklaşıma göre, her epokta kayıp fonksiyonu değiştirilmektedir. Her epokta hem birinci hem de ikinci kayıp fonksiyonlarıyla ayrı ayrı kayıp değeri hesaplanmakta, ardından bu değerlerden yüksek olanı ilgili epok için toplam kayıp olarak belirlenmekte ve eğitim bu değer üzerinden devam etmektedir. Böylece modelin o epoktaki en zayıf öğrenme yönüne odaklanılarak performansının artırılması hedeflenmektedir. Önerilen yöntem şu şekildedir:

$$L_{son} = \max(L_{kçe}, L_{kh}) \quad (3.2)$$

Her epokta iki kayıp fonksiyonunun da hesaba katılmasını sağlayarak hatayı minimize eden bu yaklaşımla hem genel performansın hem de modelin genelleme yeteneğinin artması amaçlanmaktadır.

3.3.3. Ceza skoru eklenmiş kategorik çapraz entropi kayıp fonksiyonu

Kayıp fonksiyonlarına modelin yanlış etiketlere odaklanmasını ve yanlış sınıflandırma eğilimlerine karşı daha duyarlı olmasını sağlayacak bir ceza terimi eklenmesi, özellikle dengesiz veri kümelerinde model performansını artıran etkili bir yöntemdir. Ayrıca, ceza terimleri modelin aşırı uyumunu (overfitting) önlemeye de yardımcı olabilmektedir [17],

[98]. Bu doğrultuda sunulan çalışmada modelin yanlış sınıf olasılıklarına da odaklanmasını sağlamak amacıyla, KÇE kaybına bir ceza terimi eklenmiştir. Eşitlik (3.3)'te önerilen ceza terimi verilmiştir.

$$penalty = (\hat{y} * (y - 1))^b \quad (3.3)$$

Burada, $\hat{y}$ model tahmini, y gerçek sınıf değeri, b ise ceza katsayısının kayıp fonksiyonuna ne kadar katkı sağlayacağını belirten katsayıdır. Bu katsayı, ceza teriminin toplam kayıp üzerindeki etkisini kontrol etmektedir ve çalışma kapsamında deneysel olarak belirlenmiştir. Ön çalışmalar doğrultusunda b için 1 ile 10 aralığında değerler denenmiş, en başarılı sonuçlar 2, 3 ve 5 değerleriyle elde edilmiştir. Ceza katsayısı eklenmiş KÇE Eşitlik (3.4)'te verilmiştir.

$$L_{KCE}(\hat{y}, y) = - \sum_{c=1}^M y \log(\hat{y}) - \sum_{c=1}^M (\hat{y} * (y - 1))^b \quad (3.4)$$

Bu yaklaşım ile model, yalnızca doğru sınıfa odaklanmakla kalmayıp yanlış sınıflar için üretilen olasılıkları da dikkate alarak daha dengeli bir öğrenme süreci gerçekleştirmektedir. Özellikle dengesiz veri kümelerinde, modelin zor örneklerle ve nadir sınıflara odaklanması sağlanarak, hatalara karşı duyarlılığının artması ve böylece genel sınıflandırma performansının iyileştirilmesi amaçlanmaktadır.

3.3.4. Topluluk yöntemi ile birleştirilen kayıp fonksiyonları


Topluluk yaklaşımında, tek bir modelin çıktısı yerine, birden fazla modelin çıktıları birleştirilerek sınıflandırma yapılmaktadır [172]. Ağırlıklı ortalama ve çoğunluk oylaması gibi topluluk yöntemleri çeşitli sınıflandırma probleminde model performansını artırmak için yaygın olarak kullanılmaktadır [35]. Ağırlıklı ortalama yaklaşımında her bir modelin tahmin ettiği sınıf olasılıkları, önceden belirlenen ağırlıklarla çarpılıp toplanarak son sınıf etiketi belirlenmektedir. Çoğunluk oylaması ise sert ve hafif olarak ikiye ayrılmaktadır. Sert oylamada, farklı modellerin tahmin ettiği sınıf etiketleri arasında en fazla oy alan sınıf, nihai sınıf olarak kabul edilmektedir. Yumuşak oylamada her sınıf için modellerin tahmin olasılıkları toplanmakta ve en yüksek toplam olasılığa sahip sınıf nihai karar olarak kabul edilmektedir [173].

Önerilen ağırlıklı topluluk yöntemi, farklı kayıp fonksiyonlarıyla ile eğitilen modellerin sınıf olasılık tahminlerini, belirli ağırlıklar ile birleştirerek nihai tahmini üretmektedir (Eşitlik (3.5)).

$$\hat{y} = w_1\hat{y}_1 + w_2\hat{y}_2 + w_3\hat{y}_3$$

$$w_1 + w_2 + w_3 = 1$$
(3.5)

Burada $\hat{y}_i$, i -nci kayıp fonksiyonu ile eğitilen modelin sınıf olasılık çıktısını, w_i ise her fonksiyona ait ağırlığı temsil etmektedir. Önerilen topluluk yöntemi Şekil 3.10'da şematik olarak gösterilmektedir. Burada görüldüğü gibi model farklı kayıp fonksiyonlarıyla eğitilmektedir, daha sonra her eğitim çıkışında elde edilen sınıf olasılıkları ağırlıklı olarak birleştirilerek nihai sonuç elde edilmektedir. Bu yaklaşımın temel amacı, farklı fonksiyonlarının model performansına yaptığı katkıyı birleştirerek her fonksiyonun güçlü yönlerinden yararlanmaktır.



Şekil 3.10. Önerilen topluluk yöntemi.

Çalışmada ağırlıklı ortalama alınırken ağırlıklar, en yüksek performansa ulaşılması için üç farklı yöntem kullanılarak belirlenmiştir:

- **Aritmetik Ortalama:** Tüm modeller eşit katkı verecek şekilde ağırlıklar belirlenmiştir. Örneğin iki modelin ortalaması alınacaksa $w_1 = w_2 = 1/2$ olacaktır.
- **Izgara Arama:** Izgara arama yöntemi, farklı kombinasyonları sistematik olarak deneyerek, en iyi performansı veren ağırlıkları bulmaya yarayan bir yöntemdir [174]. Bu

yöntemde eğitim kümesi üzerinde farklı ağırlık kombinasyonları sistematik olarak denenmiş ve en yüksek doğruluğu sağlayan ağırlıklar seçilmiştir.

- **Doğruluk Oranına Göre Normalize Ağırlıklandırma:** Ağırlıklar eğitim setinin sınıflandırma doğruluğuna göre belirlenmiştir. Her kayıp fonksiyonu ile elde edilen doğruluk sonucunun, kayıp fonksiyonlarının doğruluklarının toplamına bölünmesi ile normalize edilmiş ağırlıklar hesaplanmıştır. Örneğin ilk modelin doğruluğu %95, ikinci modelin doğruluğu %87 ise $w_1 = \frac{95}{95+87} = 0,522$, $w_2 = \frac{87}{95+87} = 0,478$ olarak belirlenmiştir.

Bu yöntem sayesinde, model eğitimi sırasında tek bir kayıp fonksiyonuna bağlı kalmanın yol açabileceği önyargı (bias) ve sınırlamalar minimize edilmiştir. Her fonksiyonun farklı avantajları sayesinde, semantik olarak benzer sınıfların ayrıştırılması, modelin dengesiz veri dağılımına karşı duyarlılığının azalması ve genelleme yeteneğinin artması hedeflenmiştir.

Sonuç olarak çalışma kapsamında 5 farklı dinamik, 1 hibrit, 3 farklı ceza terimi içeren ve 9 farklı topluluk yöntemiyle birleştirilmiş olmak üzere toplam 18 kayıp fonksiyonu önerilmiştir.

- **Dinamik Kayıp Fonksiyonu- KÇE + KH:** Eğitime KÇE ile başlayıp belirlenen epoktan sonra eğitime KH ile devam eden fonksiyonu ifade etmektedir.
- **Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH:** Eğitime KÇE ile başlayıp daha sonra eğitime KH ile, KÇE'nin en yüksek test doğruluğunu elde ettiği epoktan devam eden fonksiyonu ifade etmektedir.
- **Dinamik Kayıp Fonksiyonu- KH + KÇE:** Eğitime KH ile başlayıp belirlenen epoktan sonra eğitime KÇE ile devam eden fonksiyonu ifade etmektedir.
- **Dinamik Kayıp Fonksiyonu- En İyi KH + KÇE:** Eğitime KÇE ile başlayıp daha sonra eğitime KH ile, KÇE'nin en yüksek test doğruluğunu elde ettiği epoktan devam eden fonksiyonu ifade etmektedir.
- **Dinamik En Büyük Kayıp Fonksiyonu:** Bölüm 3.3.2'de eşitlik (3.2) ile ifade edilen kayıp fonksiyonudur.
- **Hibrit Kayıp Fonksiyonu:** Bölüm 3.3.1'de eşitlik (3.1) ile ifade edilen, ağırlık değerlerinin $w_{kce} = 0,8$ ve $w_{kh} = 0,2$ olarak seçildiği kayıp fonksiyonudur.
- **Ceza Terimi Eklenmiş KÇE (b=2):** Bölüm 3.3.3'te eşitlik (3.4) ile ifade edilen, b değerinin 2 olarak seçildiği kayıp fonksiyonudur.

- **Ceza Terimi Eklenmiş KÇE (b=3):** Bölüm 3.3.3’te eşitlik (3.4) ile ifade edilen, b değerinin 3 olarak seçildiği kayıp fonksiyonudur.
- **Ceza Terimi Eklenmiş KÇE (b=5):** Bölüm 3.3.3’te eşitlik (3.4) ile ifade edilen, b değerinin 5 olarak seçildiği kayıp fonksiyonudur.
- **Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH:** “Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH” ve “Dinamik Kayıp Fonksiyonu- KÇE + KH” kayıp fonksiyonlarının aritmetik ortalama ile birleştirildiği topluluk yöntemi kayıp fonksiyonudur.
- **Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH:** “Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH” ve “Dinamik Kayıp Fonksiyonu- KÇE + KH” kayıp fonksiyonlarının ızgara arama ile elde edilen ağırlıklar kullanılarak birleştirildiği topluluk yöntemi kayıp fonksiyonudur.
- **Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH:** “Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH” ve “Dinamik Kayıp Fonksiyonu- KÇE + KH” kayıp fonksiyonlarının doğruluk oranına göre normalize ağırlıklandırma yöntemi ile elde edilen ağırlıklar kullanılarak birleştirildiği topluluk yöntemi kayıp fonksiyonudur.
- **Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE:** “Dinamik Kayıp Fonksiyonu- En İyi KH + KÇE” ve “Dinamik Kayıp Fonksiyonu- KH + KÇE” kayıp fonksiyonlarının aritmetik ortalama ile birleştirildiği topluluk yöntemi kayıp fonksiyonudur.
- **Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE:** “Dinamik Kayıp Fonksiyonu- En İyi KH + KÇE” ve “Dinamik Kayıp Fonksiyonu- KH + KÇE” kayıp fonksiyonlarının ızgara arama ile elde edilen ağırlıklar kullanılarak birleştirildiği topluluk yöntemi kayıp fonksiyonudur.
- **Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE:** “Dinamik Kayıp Fonksiyonu- En İyi KH + KÇE” ve “Dinamik Kayıp Fonksiyonu- KH + KÇE” kayıp fonksiyonlarının doğruluk oranına göre normalize ağırlıklandırma yöntemi ile elde edilen ağırlıklar kullanılarak birleştirildiği topluluk yöntemi kayıp fonksiyonudur.
- **Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5):** “Ceza Terimi Eklenmiş KÇE (b=2)”, “Ceza Terimi Eklenmiş KÇE (b=3)” ve “Ceza

Terimi Eklenmiş KÇE (b=5)” kayıp fonksiyonlarının aritmetik ortalama ile birleştirildiği topluluk yöntemi kayıp fonksiyonudur.

- **Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5):** “Ceza Terimi Eklenmiş KÇE (b=2)”, “Ceza Terimi Eklenmiş KÇE (b=3)” ve “Ceza Terimi Eklenmiş KÇE (b=5)” kayıp fonksiyonlarının ızgara arama ile elde edilen ağırlıklar kullanılarak birleştirildiği topluluk yöntemi kayıp fonksiyonudur.
- **Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5):** “Ceza Terimi Eklenmiş KÇE (b=2)”, “Ceza Terimi Eklenmiş KÇE (b=3)” ve “Ceza Terimi Eklenmiş KÇE (b=5)” kayıp fonksiyonlarının doğruluk oranına göre normalize ağırlıklandırma yöntemi ile elde edilen ağırlıklar kullanılarak birleştirildiği topluluk yöntemi kayıp fonksiyonudur.

4. DENEYSEL SONUÇLAR

Bu tez çalışması kapsamında akciğer grafilerinin yüksek doğrulukla sınıflandırılması amacıyla çeşitli derin öğrenme modelleri ve özgün kayıp fonksiyonları geliştirilmiştir. Çalışmanın ilk aşamasında önerilen modeller 4, 5, 6, 7 ve 8 sınıflı veri kümeleri üzerinde kapsamlı bir şekilde değerlendirilmiş ve en yüksek performansı gösteren model nihai model olarak seçilmiştir.

Çalışmanın devamında nihai modelin performansını daha da artırmak amacıyla farklı kayıp fonksiyonları önerilmiştir. İlk olarak, literatürde yaygın olarak kullanılan kayıp fonksiyonları, nihai model ve 5 sınıflı veri kümesi kullanılarak test edilmiştir. Bu ön değerlendirme sonucunda belirlenen en başarılı iki kayıp fonksiyonu, Bölüm 3.3'te ayrıntılı olarak açıklandığı şekilde, hibrit ve dinamik kayıp fonksiyonlarının oluşturulmasında kullanılmıştır. Ardından önerilen kayıp fonksiyonlarının performanslarının değerlendirilmesi amacıyla nihai model ve 7, 8, 9, 10, 12, 14 ve 15 sınıflı veri kümeleri kullanılarak analizler yapılmıştır. Bu detaylı analizler sonucunda sınıf sayısından bağımsız olarak en yüksek performansı sunan kayıp fonksiyonu belirlenmiştir. Son olarak, bu kayıp fonksiyonunun modelden bağımsız olarak başarısının test edilmesi amacıyla önerilen tüm modeller ve 15 sınıflı veri kümesi kullanılarak analizler yapılmıştır. Buna ek olarak modelin karar verirken hangi bölgelere odaklandığı Grad-CAM yöntemi ile görselleştirilmiş, böylece karar sürecinin daha şeffaf ve yorumlanabilir olması sağlanmıştır.


Sonuç olarak bu tez çalışması kapsamında akciğer grafilerinin yüksek başarı ile sınıflandırılması amacıyla yeni bir derin öğrenme modeli ve özgün bir kayıp fonksiyonu önerilmiştir. Bu bölümde, önerilen model ve kayıp fonksiyonlarının etkinliğini değerlendirmek üzere farklı sınıf sayısına sahip veri kümeleri üzerinde yapılan kapsamlı analizlerin sonuçları sunulmuştur.

4.1. En Başarılı Modelin Belirlenmesi

Akciğer grafilerini en yüksek performansla sınıflandıracak modelin belirlenmesi amacıyla Bölüm 3.2'de ayrıntılı olarak açıklanan yedi farklı model kullanılarak analizler yapılmıştır. Bu kapsamda modeller 4 sınıflı, üç farklı 5 sınıflı, 6 sınıflı, 7 sınıflı ve 8 sınıflı veri kümeleri üzerinde eğitilmiş ve test edilmiştir. Farklı sınıf sayılarına sahip veri kümeleri kullanılarak, modellerin hem sınıflandırma performansları hem de genelleme yetenekleri kapsamlı bir şekilde değerlendirilmiştir.

4.1.1. Dört sınıflı veri kümesi sınıflandırma sonuçları


COVID-19, normal, TB ve viral pnömoni görüntülerinden oluşan dört sınıflı veri kümesi kullanılarak, önerilen yedi farklı model ile gerçekleştirilen sınıflandırma çalışmaları sonucunda elde edilen test performans metrikleri, sınıf bazında EK 1’de detaylı bir şekilde verilmiştir. Modellerin karşılaştırılabilmesi için ortalama test performans değerleri ise Şekil 4.1’de sunulmuştur.



Şekil 4.1. Dört sınıflı veri kümesi için modellerin ortalama performans değerleri.

Şekil 4.1’de görüldüğü üzere tüm modeller 4 sınıflı veri kümesi için yüksek performans sergilemiştir. Model 6 ve Model 7, %99,814 doğruluk ile en yüksek performansı göstermiştir, ancak Model 6 kesinlik (%99,843) ve F1-skoru (%99,799) metriklerinde öne çıkmıştır. Bu durum, ConvLSTM’in tek başına uzamsal ilişkileri başarıyla yakalayarak sınıflandırma performansını artırabildiğini göstermektedir. Model 2, Model 3 ve Model 5 benzer doğruluk oranları göstermiştir, bununla birlikte Model 3 duyarlılık (%99,810), özgüllük (%99,905) ve F1-skoru (%99,754) metriklerinde Model 2 ve Model 5’ten daha iyi performans göstermiştir. Bu da dönüştürücü kodlayıcı ve SE bloklarının birlikte kullanımının sınıflar arası ayrımı güçlendirdiğini göstermektedir. Sadece DenseNet201 ve dönüştürücü kodlayıcıdan oluşan Model 1 ise diğer modellere kıyasla en düşük performansı sergileyerek bu yapının tek başına sınıflandırma için yetersiz olduğunu ortaya koymuştur.

Tüm modellerde elde edilen AUC değerleri göz önünde bulundurulduğunda sınıflar arası ayrımın büyük bir başarıyla yapıldığı görülmektedir. Ayrıca ConvLSTM'in 4 sınıflı veri kümesi için SE ve dönüştürücü kodlayıcı gibi diğer modüllere kıyasla daha etkili bir ayrım sağladığı sonucuna varılmaktadır. En başarılı ve en başarısız modellerin ROC eğrileri Şekil 4.2'de verilmiştir.




Şekil 4.2. Dört sınıf için en düşük ve en yüksek başarıya sahip modellerin (Model 1 ve Model 6) ROC eğrileri.

4.1.2. Beş sınıflı veri kümesi sınıflandırma sonuçları

Beş sınıflı sınıflandırma çalışmaları kapsamında, üç farklı 5 sınıflı veri kümesi oluşturulmuştur. Bu veri kümelerinde COVID-19, normal, TB ve viral pnömoni sınıfları sabit tutulmuş; beşinci sınıf olarak sırasıyla fibröz, akciğer opasitesi ve bakteriyel pnömoni sınıfları eklenmiştir. Böylece modellerin farklı 5 sınıflı veri kümeleri üzerindeki performansları incelenerek, en yüksek performansa ulaşan modelin belirlenmesi amaçlanmıştır. Bu kapsamda oluşturulan veri kümeleri ile gerçekleştirilen analizlerin sonuçları aşağıda sunulmuştur.

4.1.2.1. Beş sınıflı sınıflandırma sonuçları-1


COVID-19, fibröz, normal, TB ve viral pnömoni görüntülerinden oluşan beş sınıflı veri kümesi kullanılarak önerilen modellerle yapılan sınıflandırma çalışmalarında elde edilen sınıf bazında test sonuçları EK 2'de detaylı bir şekilde verilmiştir. Modellerin karşılaştırılabilmesi için ortalama performans değerlerinin gösterildiği grafik Şekil 4.3'te sunulmuştur.



Şekil 4.3. Beş sınıf-1 veri kümesi için modellerin ortalama performans değerleri.

Şekil 4.3'te görüldüğü en yüksek performans %99,854 genel doğruluk, %99,905 kesinlik, %99,870 duyarlılık, %99,949 özgüllük ve %99,887 F1-skoru ile Model 2 kullanılarak elde edilmiştir. Bu sonuç, ConvLSTM, SE ve dönüştürücü kodlayıcı bileşenlerinin birlikte kullanıldığı hibrit yapının sınıflar arası ayrımı etkin biçimde gerçekleştirdiğini göstermektedir. Model 4 ve Model 6, doğruluk ve F1-skoru açısından ikinci ve üçüncü en yüksek değerlere ulaşmıştır. ConvLSTM içeren bu modellerin, uzamsal ilişkileri etkili biçimde modelleyerek sınıflandırmaya olumlu katkı sunduğu gözlemlenmiştir. Model 3, dönüştürücü kodlayıcı ve SE birleşimiyle ortalama bir performans ortaya koymuştur. Model 5, sade bir mimariye sahip olduğu için 5 sınıflı veri kümesinde diğer modellere kıyasla daha düşük performans göstermiştir. Benzer şekilde, Model 1 ve Model 7 beklenenin altında bir performans sunmuştur.


Sonuç olarak, en yüksek performans Model 2 ile elde edilmiş, Model 5 ise en düşük performansı sergilemiştir. Her iki modelin ROC eğrileri karşılaştırmalı olarak Şekil 4.4'te sunulmuştur.



Şekil 4.4. Beş sınıf-1 için en düşük ve en yüksek başarıya sahip modellerin (Model 5 ve Model 2) ROC eğrileri.

4.1.2.2. Beş sınıflı sınıflandırma sonuçları-2


COVID-19, akciğer opasitesi, normal, TB ve viral pnömoni görüntülerinden oluşan beş sınıflı veri kümesi kullanılarak yapılan sınıflandırma çalışmalarında elde edilen performans metrikleri sınıf bazında ayrıntılı bir şekilde EK 2’de verilmiştir. Modellerin karşılaştırılabilmesi için ortalama test performans değerlerinin gösterildiği grafik ise Şekil 4.5’te sunulmuştur.



Şekil 4.5. Beş sınıf-2 veri kümesi için modellerin ortalama performans değerleri.

Şekil 4.5'te görüldüğü gibi beş sınıflı (5_2) veri kümesi ile yapılan analizlerde modeller %96,655 ile %97,259 arasında genel doğruluk oranlarına ulaşmıştır. Bu sonuçlar, önceki analizlere kıyasla daha düşük olmakla birlikte, AUC değerlerinin yaklaşık 0,997 olması, modellerin sınıflar arası ayırım yeteneklerinin yüksek olduğunu göstermektedir. Model 7, %97,259 genel doğruluk, %98,258 kesinlik, %97,939 duyarlılık, %99,154 özgüllük ve %98,095 F1-skoru ile en yüksek başarıyı göstermiştir. Bu model, dönüştürücü kodlayıcının dikkat mekanizmasını ve ConvLSTM'in uzamsal ilişkileri modelleme yeteneğini bir araya getirerek, başarılı sonuçlar elde etmiştir. Model 2, Model 5 ve Model 6 benzer düzeyde performanslar sergileyerek %97,239 ve %97,138 oranlarında genel doğruluk elde etmiştir. Bununla birlikte Model 2 kesinlik, duyarlılık, özgüllük ve F1-skoru metriklerinde Model 5 ve Model 6'yı geride bırakmıştır. Benzer şekilde Model 1 ve Model 3 diğer modellerden düşük ancak birbirine çok yakın performans değerleri göstermiştir. En düşük performans, %96,655 genel doğruluk ve %97,555 F1-skoru ile Model 4 tarafından sergilenmiştir. Bu modelde ConvLSTM, SE ve dönüştürücü kodlayıcı katmanları birlikte kullanılmış olmasına rağmen diğer modellere kıyasla daha düşük duyarlılık ve özgüllük değerleri elde edilmiştir. Bu durum, modelin bazı sınıflarda yanlış pozitif ve negatif tahminlere daha yatkın olduğunu göstermektedir. Bununla birlikte, her ne kadar elde edilen performans metrikleri diğer modellerden düşük olsa da ulaşılan yüksek AUC değeri, modellerin genel olarak sınıflar arasındaki ayrımı başarıyla gerçekleştirebildiğini ortaya koymaktadır.


Sonuç olarak, Model 7 en başarılı performansı sergilerken, Model 4 en düşük sonuçları elde etmiştir. Her iki modelin ROC eğrileri Şekil 4.6'da karşılaştırmalı olarak sunulmuştur.



Şekil 4.6. Beş sınıf-2 için en düşük ve en yüksek başarıya sahip modellerin (Model 4 ve Model 7) ROC eğrileri.

4.1.2.3. Beş sınıflı sınıflandırma sonuçları-3

Bakteriyel pnömoni, COVID-19, normal, TB ve viral pnömoni görüntülerinden oluşan beş sınıflı veri kümesi kullanılarak yapılan sınıflandırma çalışmalarında elde edilen sınıf bazında performans metrikleri detaylı bir şekilde EK 2’de verilmiştir. Modellerin karşılaştırılabilmesi için ortalama test performans değerlerinin gösterildiği grafik ise Şekil 4.7’de sunulmuştur.




Şekil 4.7. Beş sınıf-3 veri kümesi için modellerin ortalama performans değerleri.

Şekil 4.7’de görüldüğü gibi beş sınıflı (5_3) veri kümesi ile yapılan analizlerde, önceki sınıflandırma görevlerine göre tüm modellerin genel doğruluk, F1-skoru ve duyarlılık değerlerinde bir düşüş gözlemlenmektedir. Bu durum, sınıflar arasındaki semantik benzerliğinin arttığını, ayırmanın daha zorlaştığını göstermektedir.

En yüksek genel doğruluk %96,129 ile Model 1 tarafından elde edilmiştir, bu model kesinlik (%91,767) ve F1-skoru (%91,664) açısından da en başarılı sonucu göstermiştir. DenseNet201’den sonra dönüştürücü kodlayıcının tek başına kullanıldığı bu modelin, daha karmaşık sınıfların ayrımı için dikkat mekanizması sayesinde öne çıktığı sonucuna varılmıştır. Bu sonuç, belirli veri kümelerinde basit modellerin de başarılı performans gösterebileceğini ortaya koymaktadır. Model 2, %95,318 doğruluk, %98,127 kesinlik, %90,367 duyarlılık ve %90,428 F1-skoru ile ikinci en başarılı modeldir. Model 1’e kıyasla tüm metriklerde daha düşük sonuçlar göstermesine rağmen daha yüksek bir AUC (%0,992) değeri elde etmiştir. ConvLSTM, SE ve dönüştürücü kodlayıcının hibrit olarak kullanıldığı

Model 2, karmaşık bir mimari olmasına rağmen, sınıf dengesizliği olan durumlarda güçlü bir performans sergilemiştir. Model 4 ve Model 5 birbirine yakın ancak diğer modellerden daha düşük performans değerleri elde etmiştir. Bu durum SE ve GAP gibi bileşenlerin etkisinin bu veri kümesi için sınırlı kaldığını göstermektedir. Model 3 ise %94,715 genel doğrulukla en düşük performansı göstermiştir.

Sonuç olarak, Şekil 4.7’de de görüldüğü üzere en başarılı performans Model 1 tarafından elde edilirken, en düşük genel doğruluk Model 3 tarafından sağlanmıştır. Model 2 ise tüm metrikler dikkate alındığında ikinci en başarılı model olmuştur. Bu üç modelin ROC eğrileri karşılaştırmalı olarak Şekil 4.8’de sunulmuştur.




Şekil 4.8. Beş sınıf-3 için en düşük ve en yüksek başarıya sahip modellerin (Model 3 ve Model 1, Model 2) ROC eğrileri.

4.1.3. Altı sınıflı veri kümesi sınıflandırma sonuçları

Bakteriyel pnömoni, COVID-19, akciğer opasitesi, normal, TB ve viral pnömoni görüntülerinden oluşan altı sınıflı veri kümesi kullanılarak önerilen modellerle sınıflandırma

çalışmaları gerçekleştirilmiştir. Bu analizler sonucunda her bir sınıf için elde edilen test performans metrikleri ayrıntılı bir şekilde EK 3'te verilmiştir. Modellerin genel performanslarını karşılaştırmak amacıyla hesaplanan ortalama değerler ise grafiksel olarak Şekil 4.9'da sunulmuştur.




Şekil 4.9. Altı sınıflı veri kümesi için modellerin ortalama performans değerleri.

Şekil 4.9'da da görüldüğü 6 sınıflı veri kümesi ile yapılan analizlerde elde edilen genel doğruluk oranları %93,002 ve %94,471 aralığında değişmektedir. Bununla birlikte sınıf sayısının artması ile birlikte beklendiği gibi doğruluk ve F1-skoru metriklerinde 4 ve 5 sınıflı veri kümeleri için elde edilen değerlere göre düşüş gözlenmektedir. Yine de elde edilen yüksek AUC değerleri modellerin başarılı bir şekilde sınıf ayrımı yapabildiğini göstermektedir.

Altı sınıflı veri kümesi için en başarılı performans, %94,471 genel doğruluk, %91,532 kesinlik, %91,062 duyarlılık, %91,280 F1-skoru ve 0,9916 AUC değeri ile Model 2 ile elde edilmiştir. ConvLSTM, SE ve dönüştürücü kodlayıcı bileşenlerinin hibrit bir şekilde kullanıldığı bu model, tüm performans metriklerinde diğer modellere göre daha yüksek başarı göstermiştir. Model 3 ve Model 4, genel doğruluk açısından Model 2'yi takip etmektedir. Model 3, %94,380 genel doğruluk ve 0,9930 AUC değeri sunarken, Model 4 ise %94,289 genel doğruluk ve 0,9936 AUC değeri elde etmiştir. Bu sonuçlar, SE ve dönüştürücü kodlayıcı bloklarının birlikte kullanıldığında sınıflandırma performansına katkı

sağladığını göstermektedir. Model 1 ve Model 6, benzer doğruluk değerleriyle orta düzeyde başarı göstermiştir. Model 6, ConvLSTM ve GAP birleşimiyle %94,017 genel doğruluk ve %90,509 F1-skoruna ulaşırken, Model 1 dönüştürücü kodlayıcı tabanlı basit yapısıyla %93,927 genel doğruluk elde etmiştir. Bu modellerin duyarlılık ve kesinlik metrikleri düşük kalmıştır. En düşük performans %93,002 genel doğruluk ve %89,090 F1-skoru ile Model 5 tarafından sunulmuştur. Bu modelde yalnızca SE katmanının kullanılması sınırlı katkı sağlamıştır. Benzer şekilde, Model 7 de %93,582 genel doğrulukla düşük performans göstermiştir.


Sonuç olarak, tüm performans metrikleri göz önünde bulundurulduğunda Model 2 en yüksek başarıya ulaşmışken, Model 5 en düşük sınıflandırma sonuçlarını göstermiştir. Bu iki modelin ROC eğrileri karşılaştırmalı olarak Şekil 4.10'da sunulmuştur.



Şekil 4.10. Altı sınıf için en düşük ve en yüksek başarıya sahip modellerin (Model 5 ve Model 2) ROC eğrileri.

4.1.4. Yedi sınıflı veri kümesi sınıflandırma sonuçları

Bakteriyel pnömoni, COVID-19, fibröz, akciğer opasitesi, normal, TB ve viral pnömoni görüntülerinden oluşan yedi sınıflı veri kümesi kullanılarak önerilen modellerle yapılan sınıflandırma çalışmalarında her bir sınıf için elde edilen test performans metrikleri ayrıntılı olarak EK 4'te verilmiştir. Modellerin performanslarını karşılaştırmak amacıyla hesaplanan ortalama test performans değerleri ayrıca Şekil 4.11'de grafiksel olarak gösterilmiştir.



Şekil 4.11. Yedi sınıflı veri kümesi için modellerin ortalama performans değerleri.


Şekil 4.11’de görüldüğü üzere, 7 sınıflı veri kümesi ile gerçekleştirilen sınıflandırma çalışmalarında, tüm modellerin genel doğruluk oranları %93,166 ile %94,379 arasında değişmektedir. Bu sonuçlar, sınıf sayısının artmasına rağmen modellerin yüksek sınıflandırma performansını koruduğunu göstermektedir. Ayrıca tüm modeller için elde edilen AUC değerlerinin 0,9939 ve üzeri olması, modellerin sınıfları başarılı bir şekilde ayırtılabildiğini ortaya koymaktadır.

Yedi sınıf için en başarılı performans, %94,379 genel doğruluk, %92,555 kesinlik, %92,232 duyarlılık ve %92,338 F1-skoru ile Model 5 ile elde edilmiştir. Bu da DenseNet201’e ek olarak SE ve GAP bloklarının birlikte kullanıldığı bu basit mimari ile başarılı bir sınıflandırma yapılabildiğini göstermektedir. Model 5’in daha az sayıda sınıf içeren veri kümelerinde düşük başarı göstermesine rağmen 7 sınıflı veri kümesinde öne çıkması, modellerin veri kümelerine bağlı olarak farklı performanslar gösterebildiğini ortaya koymaktadır.

Model 5’e yakın başarı gösteren ikinci en iyi model ise Model 2’dir. Bu model, %94,259 genel doğruluk, %91,931 kesinlik ve %91,574 F1-skoru, 0,9939 AUC değeri elde etmiştir. ConvLSTM, SE ve dönüştürücü kodlayıcının hibrit bir şekilde kullanıldığı bu yapı, önceki sınıflandırmalarda olduğu gibi dengeli ve yüksek performans sunmuştur. Model 4 ve Model 6 ise benzer doğruluk ve F1-skoru ile ortalama bir performans göstermiştir. Model 1, diğer modellere göre daha düşük F1-skorlarına ulaşmıştır. Model 7 ve Model 3 sırasıyla

%93,781 ve %93,166 genel doğruluk oranlarıyla en düşük genel başarıyı göstermişlerdir. Model 7, elde ettiği F1-skoruyla Model 3'ün gerisinde kalarak en başarısız model olmuştur.

Sonuç olarak, Model 5 bu görevde en yüksek performansı göstermiş, Model 2 onu takip etmiştir. En düşük performans ise Model 7 tarafından elde edilmiştir. Bu iki modelin ROC eğrileri karşılaştırmalı olarak Şekil 4.12'de sunulmuştur.




Şekil 4.12. Yedi sınıf için en düşük ve en yüksek başarıya sahip modellerin (Model 7 ve Model 5) ROC eğrileri.

4.1.5. Sekiz sınıflı veri kümesi sınıflandırma sonuçları

Bakteriyel pnömoni, COVID-19, fibröz, akciğer opasitesi, normal, pnömotoraks, TB ve viral pnömoni görüntülerinden oluşan sekiz sınıflı veri kümesi kullanılarak yapılan sınıflandırma çalışmalarında sınıf bazında elde edilen performans metrikleri EK 5'te detaylı olarak sunulmuştur. En başarılı modelin belirlenmesi amacıyla ortalama test performans metriklerinin gösterildiği grafik Şekil 4.13'te gösterilmiştir.


Sekiz sınıflı veri kümesi üzerinde yapılan analizlerde sınıf sayısının artması ile birlikte beklendiği gibi performanslarda hafif bir düşüş yaşanmıştır. Buna rağmen modellerin genel doğruluk oranları %91,060 ile %92,791 arasında değişmektedir. Ayrıca elde edilen AUC değerleri 0,9892 ve üzerindedir, bu da modellerin başarılı bir şekilde sınıf ayrımı yapabildiğini göstermektedir. En başarılı performans, %92,791 genel doğruluk, %89,301 duyarlılık ve %89,237 F1-skoru ile Model 2 tarafından sağlanmıştır. ConvLSTM, SE ve dönüştürücü kodlayıcı bloklarının hibrit biçimde kullanıldığı bu model, sınıf sayısı arttığında da başarılı sonuçlar göstermeye devam etmiştir. Model 2'yi takiben Model 5, %92,776 genel doğruluk ve %88,983 F1-skoru ile ikinci en başarılı sonuçları elde etmiştir. DenseNet201'e ek olarak SE ve GAP bileşenlerini içeren bu basit yapı, 7 sınıflı senaryoda olduğu gibi burada

da güçlü bir performans sergilemiştir. Model 3 ve Model 4 ise sırasıyla %92,433 ve %92,463 genel doğruluk oranları ile benzer sonuçlar elde etmiştir, her iki modelin duyarlılık ve F1-skoru da birbirine yakındır. Bu durum, SE ve dönüştürücü kodlayıcı bloklarının birlikte kullanımının tutarlı performans sergileyebildiğini göstermektedir. Model 6 ve Model 7, %91,985 ve %91,925 genel doğruluk oranları ile orta düzeyde bir performans sunmuştur. Bu modellerde yer alan ConvLSTM bloğu düşük sınıflarda (4 ve 5 sınıf) olduğu gibi tek başına yeterli olmamış, duyarlılık ve F1-skoru açısından diğer modellere göre daha düşük değerler üretmiştir. Model 7'nin F1-skoru %87,560 ile en düşük ikinci değerken, Model 6'nın F1-skoru %88,313'tür. En düşük genel performans ise %91,060 genel doğruluk, %84,509 F1-skoru ve %84,138 duyarlılık ile Model 1 tarafından elde edilmiştir. DenseNet201'e ek olarak dönüştürücü kodlayıcının tek başına kullanıldığı bu modelin, sınıf sayısı arttıkça düşen performansı göz önünde bulundurulduğunda bu modelin yüksek sınıflı veri kümeleri için uygun olmadığı gözlemlenmiştir.



Şekil 4.13. Sekiz sınıflı veri kümesi için modellerin ortalama performans değerleri.

Sonuç olarak, 8 sınıflı veri kümesini sınıflandırmakta en başarılı performans değerleri Model 2 ile elde edilirken, en düşük performans ise Model 1 tarafından sergilenmiştir. Bu iki modelin ROC eğrileri karşılaştırmalı olarak Şekil 4.14'te sunulmuştur.



Şekil 4.14. Sekiz sınıf için en düşük ve en yüksek başarıya sahip modellerin (Model 1 ve Model 2) ROC eğrileri.

4.1.6. En başarılı modelin seçilmesi

Bu tez kapsamında çok sınıflı akciğer grafilerini yüksek performansla sınıflandırabilen bir model geliştirilmesi hedeflenmiştir. Bu kapsamda 4, 5, 6, 7 ve 8 sınıflı veri kümeleri üzerinde, önerilen yedi farklı model kullanılarak analizler yapılmış ve bu modellerin performansları doğruluk, kesinlik, duyarlılık, özgüllük, F1-skoru ve AUC metrikleri ile değerlendirilmiştir. Önceki bölümlerde detaylı bir şekilde gösterildiği gibi sınıf sayısı arttıkça model performanslarında doğal bir düşüş gözlenmiştir. Bu düşüş bazı modellerde daha belirginken bazı modeller sınıf sayısının artmasından daha az etkilenmiştir.

Tüm sınıflarda elde edilen performanslar değerlendirildiğinde Model 1, bazı sınıflarda güçlü sonuçlar vermiş olsa da 4 sınıflı ve 8 sınıflı veri kümelerinde en düşük başarıyı göstermiştir. Model 2 özellikle 5, 6 ve 8 sınıflı veri kümeleri gibi yüksek sınıf sayısına sahip veri kümelerinde en yüksek performansı göstermiş, ayrıca hiçbir sınıflandırma görevinde en düşük performansı sergilememiş, istikrarlı bir şekilde yüksek başarı elde etmiştir. Model 3, genellikle ortalama düzeyde sonuçlar elde etmiş olsa da 5 ve 7 sınıflı veri kümelerinde düşük başarı göstererek sınırlı bir performans sunmuştur. Model 4, tüm analizlerde ortalama bir düzeyde kalmış, üstün bir başarı sergilememiştir. Model 5, özellikle 7 sınıflı veri kümesinde en yüksek performansa ulaşsa da 5 ve 6 sınıfta en düşük performansları göstererek modelin genellenebilirliğinin sınırlı olduğunu göstermiştir. Model 6, en az sınıflı veri kümesinde (4 sınıf) iyi bir performans sergilemiş olmasına rağmen sınıf sayısının artmasıyla ortalama bir düzeyde kalmıştır. Model 7 ise 4 ve 5 sınıflı veri kümelerinde başarılı bir performans göstermiş olmasına rağmen özellikle 7 sınıflı veri kümesinde en düşük performansı

göstermiştir. Sonuç olarak yapılan bu değerlendirmeler doğrultusunda Model 2'nin en başarılı ve istikrarlı model olduğu sonucuna varılmıştır.

En iyi modelin belirlenmesi amacıyla modellerin sınıf bazında da performans değerlendirilmesi sekiz sınıflı veri kümesi üzerinde gerçekleştirilmiştir (EK 5). Bu veri kümesi; bakteriyel pnömoni, COVID-19, fibröz, akciğer opasitesi, normal, pnömotoraks, tüberküloz ve viral pnömoni olmak üzere 8 farklı patoloji türünü içermekte ve sınıflandırma açısından en kapsamlı senaryoyu temsil etmektedir. Dolayısıyla modellerin genelleme yeteneğini değerlendirme açısından en zorlayıcı görevdir. Sekiz sınıflı veri kümesi değerlendirildiğinde bakteriyel pnömoni sınıfında Model 2, %97,627 genel doğruluk ve %85,791 F1-skoru ile en iyi başarıyı göstermiştir. COVID-19 sınıfında, Model 4, %99,746 genel doğruluk, %99,579 kesinlik, %98,064 duyarlılık ve %98,815 F1-skoru en iyi performansı sergilemiştir. Fibröz sınıfında en başarılı model %97,642 doğrulukla Model 5 olurken, onu %97,627 doğruluk değeri ile Model 2 takip etmiştir. Akciğer opasitesi için en yüksek başarı, %98,060 doğruluk ve %94,601 F1-skoru ile Model 3 tarafından elde edilmiştir. Normal sınıfında Model 2, %97,970 doğruluk ve %96,668 F1-skoru ile öne çıkmıştır. En zorlayıcı sınıflardan biri olan viral pnömoni sınıfında, Model 2 %97,687 doğruluk ve %73,684 F1-skoru ile en yüksek başarıyı göstermiştir. Tüberküloz sınıfında ise Model 6 %99,955 doğruluk ve %99,786 F1-skoru ile en başarılı sınıflandırma performansına ulaşmış, bunu takiben Model 1 ve Model 2 %99,925 doğruluk ve %99,642 F1-skoru ile benzer düzeyde başarılı sonuçlar üretmiştir. Veri kümesindeki sınıf sayısına yönelik genel değerlendirmelerin yanı sıra yapılan sınıf bazında performans analizleri de Model 2'nin farklı patolojileri yüksek doğrulukla ayırt etme kapasitesine sahip olduğunu ve sekiz sınıflı karmaşık bir veri kümesinde bile sınıflar arası dengeyi koruyabildiğini ortaya koymuştur.

Model 2'de ConvLSTM, SE ve dönüştürücü kodlayıcı bloklarının hibrit olarak kullanılmasının başarıyı artırdığı görülmektedir. Bu modelde DenseNet201'den çıkartılan öznitelik haritaları ConvLSTM bloğuna aktarılmaktadır böylece öznitelikler arasındaki uzamsal bağıntılar yakalanmaktadır. Daha sonra ConvLSTM çıkışı sırasıyla SE ve dönüştürücü kodlayıcı bloklarına beslenmektedir. Burada SE bloğu, kanal düzeyinde özniteliklerin önem derecesini öğrenerek modelin daha anlamlı bilgilere odaklanmasını sağlamakta, dönüştürücü kodlayıcı bloğu ise uzun menzilli bağlamsal ilişkileri yakalayarak sınıfların daha doğru ayrıştırılmasına katkıda bulunmaktadır. SE+ dönüştürücü kodlayıcı bloğuna paralel olarak GAP uygulanarak ConvLSTM çıkışının daha sade ama etkili bir temsili elde edilmektedir. Bu iki koldan elde edilen öznitelikler birleştirilerek nihai

sınıflandırma yapılmaktadır. Sonuç olarak model, özellikle yüksek sınıflı ve dengesiz veri kümelerinde tutarlı, dengeli ve başarılı bir sınıflandırma performansı sergilemiştir.

Çalışmanın devamında önerilen modelin performansını daha da artıracak kayıp fonksiyonunun belirlenmesi hedeflenmiştir. Bu kapsamda, test edilen modeller arasında en yüksek başarıyı gösteren Model 2, kayıp fonksiyonu analizleri için temel model olarak seçilmiştir.


4.2. En Başarılı Kayıp Fonksiyonunun Belirlenmesi

Akciğer grafiğini en yüksek performansla sınıflandıran nihai modelin (Model 2) belirlenmesinin ardından elde edilen performansı daha da iyileştirmek amacıyla Bölüm 3.3'te ayrıntılı olarak açıklanan, yeni önerilen kayıp fonksiyonları ile analizler yapılmıştır. Bu kapsamda model 6, 7, 8, 9, 10, 12, 14 ve 15 sınıflı veri kümeleri üzerinde eğitilmiş ve test edilmiştir. Farklı sınıf sayılarına sahip veri kümelerinin tercih değerlendirilmesindeki amaç, önerilen kayıp fonksiyonlarının yalnızca sınıflandırma performansı açısından değil, aynı zamanda genelleme yeteneği açısından da kapsamlı biçimde değerlendirilmesini sağlamaktır. Bu analizler ile, karmaşıklığı artan sınıflandırma görevlerinde kayıp fonksiyonlarının etkisi detaylı bir şekilde gösterilmiştir.

4.2.1. Hibrit ve dinamik kayıp fonksiyonları için en başarılı iki kayıp fonksiyonunun belirlenmesi

Bu çalışmada, önerilen hibrit ve dinamik kayıp fonksiyonlarında temel alınacak iki güçlü kayıp fonksiyonunun belirlenmesi kritik bir adımdır. Bu doğrultuda, farklı kayıp fonksiyonlarının başarılarını değerlendirmek amacıyla bir ön analiz gerçekleştirilmiştir. Ön analizler kapsamında Model 2, COVID-19, fibröz, normal, tüberküloz ve viral pnömoni sınıflarını içeren 5 sınıflı bir veri kümesi üzerinde, literatürde sıklıkla kullanılan ve Bölüm 2.5'te açıklanan çeşitli kayıp fonksiyonları ile eğitilip test edilmiştir.

Elde edilen test sonuçları, sınıf bazında performansları gösterecek şekilde EK 6'da ayrıntılı biçimde sunulmuştur. Karşılaştırma amacıyla hesaplanan ortalama test performans değerleri ise Şekil 4.15'te grafiksel olarak özetlenmiştir. Bu ön analizler sayesinde, sonraki aşamada hibrit ve dinamik kayıp fonksiyonlarında temel alınacak en başarılı iki fonksiyon belirlenmiştir.



Şekil 4.15. Kayıp fonksiyonları test performansları.

Şekil 4.15'te gösterildiği üzere yedi farklı kayıp fonksiyonu ile yapılan ön analizler sonucunda, tüm performans değerleri göz önünde bulundurulduğunda KÇE ve KH fonksiyonlarının en başarılı iki fonksiyon olduğu sonucuna varılmıştır. KÇE, %99,854 genel doğruluk, %99,870 duyarlılık ve %99,887 F1-skoru ile tüm performans metriklerinde en yüksek başarıyı göstermiştir. Bu sonuç, KÇE'nin çok sınıflı dengesiz veri kümelerinde güçlü bir seçim olduğunu göstermektedir. İkinci en başarılı kayıp fonksiyonu ise KH olarak belirlenmiştir. Bu fonksiyon, %99,658 genel doğruluk ve %99,738 duyarlılık ile KÇE'ye yakın sonuçlar üretmiş, özellikle sınıf ayırma duyarlı olan F1-skoru (%99,673) ve kesinlik (%99,608) gibi metriklerde başarılı bir performans sergilemiştir. KH, karar sınırlarını daha belirgin hale getirerek başarılı bir genelleme sunmuştur. Diğer fonksiyonlar (örneğin Log-Cosh, Poisson, KL sapma) ortalama sonuçlar vermiş olsa da KÇE ve KH'nin gerisinde kalmıştır. Bu nedenle hibrit ve dinamik kayıp fonksiyonlarında temel alınacak en uygun iki fonksiyon, KÇE ve KH olarak belirlenmiştir.

4.2.2. Altı sınıflı veri kümesi sınıflandırma sonuçları

Bakteriyel pnömoni, COVID-19, akciğer opasitesi, normal, TB ve viral pnömoni grafiplerinden oluşan altı sınıflı veri kümesi üzerinde gerçekleştirilen sınıflandırma çalışmalarında, nihai model, Bölüm 3.3'te açıklanan kayıp fonksiyonları kullanılarak

eğitilmiş ve test edilmiştir. Bu kapsamda KÇE ve KH kayıp fonksiyonlarının yanı sıra, çalışmada önerilen 18 farklı kayıp fonksiyonunun sınıflandırma performansları karşılaştırılmıştır. Tüm analiz sonuçları, sınıf bazında elde edilen performans metriklerini gösterecek şekilde EK 7’de ayrıntılı bir şekilde verilmiştir. Önerilen kayıp fonksiyonlarının ortalama test performans değerleri ise başarı sıralamasına göre Tablo 4.1’de sunulmuştur.

Tablodan da görüldüğü üzere en yüksek başarıya “Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH” ve “Dinamik Kayıp Fonksiyonu- KÇE + KH” kayıp fonksiyonlarının ağırlıklı topluluk yöntemi ile birleştirilmesi ile ulaşılmıştır. Bu yöntem ile %95,051 genel sınıflandırma doğruluğu, %98,350 sınıf bazında ortalama doğruluk ve 0,992 ortalama AUC değeri elde edilmiştir. Modelin üstün başarısı, KÇE fonksiyonunun doğru sınıfa yüksek olasılık verme gücü, KH fonksiyonunun sınıflar arasında belirgin sınırlar koyma yeteneğinin birleşimi sayesinde sağlanmıştır. Ayrıca, bu fonksiyonlar tek başına kullanıldığında doğruluk oranı yaklaşık %94 seviyesinde kalırken, topluluk yöntemi ile bu oran %95’e yükselmiştir.

En düşük başarı ise, “Ceza Terimi Eklenmiş KÇE (b=5)” ile elde edilmiştir. Bu fonksiyonun genel doğruluğu %93,328 olup, bu değer standart KÇE fonksiyonunun doğruluğu olan %94,471 değerinin de altındadır. Ceza terimi eklenen kayıp fonksiyonları ayrı ayrı değerlendirildiğinde özellikle KÇE ve KH fonksiyonlarına kıyasla daha düşük performans sergilemiş olsalar da bu fonksiyonların topluluk yaklaşımı ile birleştirilmesi ve uygun şekilde ağırlıklandırılmasıyla duyarlılık ve kesinlik metriklerinde performans artışı elde edilmiştir.

Sonuç olarak, elde edilen bulgular, topluluk yöntemlerinin hem genel doğruluğun hem de sınıf bazlı performans değerlerinin iyileşmesine büyük katkı sağladığını göstermektedir. Altı sınıflı veri kümesinde, önerilen kayıp fonksiyonlarının kullanılmasıyla, standart KÇE’ye kıyasla daha yüksek sınıflandırma performansları elde edilmiştir.

Tablo 4.1. Altı sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları.

Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	95,051	98,350	92,071	91,872	98,971	91,967	0,992
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu -En İyi KÇE + KH, KÇE + KH	95,033	98,344	91,989	91,806	98,970	91,893	0,992
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	95,015	98,338	91,945	91,776	98,967	91,855	0,992
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	94,966	98,332	91,915	92,267	98,964	91,918	0,995
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	94,966	98,332	91,946	92,315	98,963	91,952	0,995
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	94,888	98,296	91,761	92,266	98,948	91,783	0,995
Dinamik En Büyük Kayıp Fonksiyonu	94,815	98,272	91,970	91,798	98,906	91,865	0,992
Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	94,797	98,266	91,717	91,732	98,915	91,705	0,993
Hibrit Kayıp Fonksiyonu ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)	94,652	98,217	91,624	91,465	98,879	91,538	0,987
Dinamik Kayıp Fonksiyonu- KÇE+ KH	94,616	98,205	91,699	91,428	98,874	91,559	0,988
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	94,561	98,187	91,458	91,362	98,863	91,400	0,992

Tablo 4.1. devam ediyor.

Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	94,471	98,157	91,233	91,078	98,846	91,147	0,992
<i>KÇE</i>	<i>94,471</i>	<i>98,157</i>	<i>91,532</i>	<i>91,062</i>	<i>98,839</i>	<i>91,280</i>	<i>0,992</i>
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	94,471	98,157	91,233	91,078	98,846	91,147	0,992
Dinamik Kayıp Fonksiyonu- KH + KÇE	94,344	98,115	91,239	91,141	98,815	91,183	0,988
<i>KH</i>	<i>94,289</i>	<i>98,096</i>	<i>90,909</i>	<i>90,774</i>	<i>98,821</i>	<i>90,835</i>	<i>0,982</i>
Dinamik Kayıp Fonksiyonu- En İyi KH + KÇE	94,217	98,072	90,677	90,563	98,802	90,598	0,992
Ceza Terimi Eklenmiş KÇE (b=3)	93,981	97,994	90,454	91,165	98,782	90,325	0,990
Ceza Terimi Eklenmiş KÇE (b=2)	93,945	97,982	90,258	90,260	98,745	90,162	0,993
Ceza Terimi Eklenmiş KÇE (b=5)	93,328	97,776	90,484	89,288	98,562	89,821	0,992

4.2.3. Yedi sınıflı veri kümesi sınıflandırma sonuçları

Bakteriyel pnömoni, COVID-19, fibröz, akciğer opasitesi, normal, TB ve viral pnömoni grafigerinden oluşan yedi sınıflı veri kümesi kullanılarak yapılan sınıflandırma çalışmalarında nihai model, Bölüm 3.3'te detaylı biçimde açıklanan kayıp fonksiyonları kullanılarak eğitilmiş ve test edilmiştir. Bu kapsamda KÇE ve KH kayıp fonksiyonlarının yanı sıra, çalışmada önerilen kayıp fonksiyonlarının sınıflandırma performansları karşılaştırılmıştır. Tüm analiz sonuçları, sınıf bazında elde edilen performans metriklerini gösterecek şekilde EK 8'de sunulmuştur. Önerilen kayıp fonksiyonlarının ortalama performans değerlerinin sıralaması başarı düzeyine göre Tablo 4.2'de sunulmuştur.

Tabloda görüldüğü üzere en yüksek sınıflandırma başarısı, %95,319 genel doğruluk oranı ile "Ağırlıklı Topluluk Kayıp Fonksiyonu- En KÇE + KH, KÇE + KH" yöntemi ile elde edilmiştir. Literatürde yaygın olarak kullanılan ve standart kabul edilmiş fonksiyonlardan biri olan KÇE, doğruluk, kesinlik ve F1-skoru gibi kritik metrikler açısından diğer kayıp fonksiyonlarına göre çok düşük performans göstermiştir. Önerilen dinamik kayıp fonksiyonları ve ağırlıklandırılmış topluluk kayıp fonksiyonları yüksek performans sağlamıştır. Bunun yanında, ceza terimi eklenmiş kayıp fonksiyonları (b=2, b=3, b=5), tek başlarına değerlendirildiğinde düşük performans sergilemiş olsalar da topluluk yöntemleriyle birleştirildiklerinde performans iyileşmesi sağlamışlardır.

Sonuç olarak, önerilen kayıp fonksiyonlarının çoğunluğu, doğruluk, kesinlik, duyarlılık, özgüllük, F1-skoru ve AUC gibi metriklerde literatürde sıklıkla kullanılan standart kayıp fonksiyonlarını geride bırakmıştır. Özellikle topluluk yöntemleri ve ağırlıklandırma stratejileri, model performansını önemli ölçüde artırarak daha istikrarlı sonuçlar elde edilmesini sağlamıştır.

Tablo 4.2. Yedi sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları.

Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	95,319	98,662	93,155	92,728	99,181	92,924	0,992
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu -En İyi KÇE + KH, KÇE + KH	95,284	98,653	93,195	92,661	99,172	92,903	0,992
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	95,267	98,648	93,188	92,649	99,168	92,893	0,992
Dinamik Kayıp Fonksiyonu- KÇE + KH	95,216	98,633	93,066	92,512	99,159	92,756	0,993
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	95,131	98,609	92,903	92,569	99,145	92,728	0,995
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	95,097	98,599	92,834	92,473	99,139	92,644	0,995
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	94,943	98,555	92,721	92,210	99,107	92,433	0,995
Dinamik Kayıp Fonksiyonu- KH+ KÇE	94,892	98,540	92,709	92,932	99,097	92,729	0,993
<i>KH</i>	<i>94,874</i>	<i>98,536</i>	<i>92,617</i>	<i>92,338</i>	<i>99,107</i>	<i>92,471</i>	<i>0,993</i>
Dinamik Kayıp Fonksiyonu- KH + KÇE	94,874	98,536	92,617	92,338	99,107	92,471	0,993
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	94,857	98,531	92,325	92,931	99,099	92,547	0,989
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	94,806	98,516	92,187	92,910	99,092	92,463	0,989

Tablo 4.2. devam ediyor.

Ceza Terimi Eklenmiş KÇE (b=5)	94,789	98,511	92,424	92,721	99,093	92,519	0,989
Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	94,721	98,492	92,118	92,352	99,087	92,216	0,989
Dinamik En Büyük Kayıp Fonksiyonu	94,567	98,448	92,220	92,267	99,050	92,199	0,993
Ceza Terimi Eklenmiş KÇE (b=2)	94,447	98,414	92,172	90,946	99,022	91,378	0,989
Hibrit Kayıp Fonksiyonu ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)	94,328	98,379	91,741	91,074	99,002	91,337	0,994
<i>KÇE</i>	<i>94,259</i>	<i>98,360</i>	<i>91,931</i>	<i>91,249</i>	<i>98,983</i>	<i>91,574</i>	<i>0,994</i>
Ceza Terimi Eklenmiş KÇE (b=3)	93,354	98,101	89,931	91,007	98,846	90,339	0,989
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	87,801	96,515	84,881	88,588	98,097	84,629	0,988

4.2.4. Sekiz sınıflı veri kümesi sınıflandırma sonuçları-1

Atelektazi, COVID-19, akciğer opasitesi, nodül, normal, pnömoni, pnömotoraks ve TB graflerini içeren sekiz sınıflı veri kümesi üzerinde yapılan sınıflandırma çalışmalarında önerilen model, Bölüm 3.3'te açıklanan kayıp fonksiyonları kullanılarak eğitilmiş ve test edilmiştir. Bu analiz kapsamında, önceki sınıflandırma çalışmalarında ayrı ayrı ele alınan viral pnömoni ve bakteriyel pnömoni sınıfları birleştirilerek tek bir pnömoni sınıfı olarak değerlendirilmiştir. Bu doğrultuda KÇE ve KH kayıp fonksiyonlarının yanı sıra, çalışmada önerilen kayıp fonksiyonlarının sınıflandırma performansları karşılaştırılmıştır. Tüm analiz sonuçları, sınıf bazında elde edilen performans metriklerini gösterecek şekilde EK 9'da sunulmuştur. Önerilen kayıp fonksiyonlarının ortalama test performans değerlerine göre başarı sıralaması Tablo 4.3'te sunulmuştur.

Tabloda da gösterildiği üzere, sekiz sınıflı veri kümesi için en yüksek sınıflandırma performansı %90,872 genel doğruluk oranı ile "Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)" ile elde edilmiştir. Bu yöntemi takiben "Doğruluğa Göre Ağırlıklı Topluluk Yöntemi- Ceza Terimi (b=2, b=3, b=5)" de benzer şekilde yüksek doğruluk oranı (%90,834) ve F1-skoru (%89,315) sunmuştur.

Topluluk temelli yöntemler, özellikle ağırlıklandırılmış topluluk yöntemleri etkileyici sonuçlar sunmuştur. Dinamik kayıp fonksiyonları, doğruluk ve F1-skoru açısından orta düzeyde bir performans sergilemiştir. Bununla birlikte, ceza terimi eklenmiş KÇE (b=2, b=3, b=5) fonksiyonları, tek başlarına değerlendirildiklerinde nispeten daha düşük performansa sahipken, topluluk yöntemiyle birleştirildiğinde performans iyileşmesi sağlamıştır. Standart yöntem olan KÇE, %89,398 doğruluk ve %87,868 F1-skoru ile orta seviyede kalmıştır. Bununla birlikte, KH, dinamik en büyük kayıp ve hibrit kayıp fonksiyonları, en düşük performans gösteren yöntemler olmuştur.

Sonuç olarak, önerilen topluluk yöntemleri, doğruluk, kesinlik, duyarlılık, özgüllük, F1-skoru ve AUC gibi metriklerde, geleneksel kayıp fonksiyonlarının başarısının önüne geçmiştir. Özellikle ceza terimi ve ağırlıklandırma stratejileri ile geliştirilen yaklaşımlar, model performansını artırmada etkili olmuş ve sınıflar arası ayrımı daha tutarlı bir biçimde gerçekleştirmiştir.

Tablo 4.3. Sekiz sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları-1.

Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	90,872	97,718	89,536	89,236	98,691	89,379	0,989
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	90,834	97,709	89,492	89,155	98,686	89,315	0,989
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	90,509	97,627	89,117	88,635	98,640	88,840	0,986
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	90,485	97,621	89,019	89,030	98,641	88,988	0,989
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	90,485	97,621	89,019	89,030	98,641	88,988	0,989
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu -En İyi KÇE + KH, KÇE + KH	90,485	97,621	89,008	89,028	98,641	88,981	0,988
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	90,472	97,618	89,106	88,578	98,634	88,802	0,986
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	90,472	97,618	89,106	88,578	98,634	88,802	0,986
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	90,460	97,615	89,092	88,650	98,633	88,847	0,988
Dinamik Kayıp Fonksiyonu- KH + KÇE	90,310	97,577	89,064	88,328	98,604	88,651	0,988
Ceza Terimi Eklenmiş KÇE (b=2)	89,710	97,428	88,469	87,550	98,520	87,932	0,984

Tablo 4.3. devam ediyor.

Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	89,660	97,415	88,353	87,485	98,511	87,828	0,986
Dinamik Kayıp Fonksiyonu- KH + KÇE	89,660	97,415	88,083	87,967	98,525	87,996	0,983
Ceza Terimi Eklenmiş KÇE (b=3)	89,523	97,381	88,161	87,985	98,503	87,992	0,988
Ceza Terimi Eklenmiş KÇE (b=5)	89,510	97,378	88,302	88,153	98,494	88,044	0,990
<i>KÇE</i>	89,398	97,350	88,173	87,841	98,478	87,868	0,985
Dinamik Kayıp Fonksiyonu- KÇE + KH	89,273	97,318	87,771	88,355	98,482	87,759	0,990
<i>KH</i>	88,936	97,234	86,986	87,088	98,417	86,924	0,988
Dinamik En Büyük Kayıp Fonksiyonu	88,249	97,062	87,647	86,024	98,281	86,648	0,989
Hibrit Kayıp Fonksiyonu ($\mathbf{w}_{KCE} = \mathbf{0,8}$ ve $\mathbf{w}_{KH} = \mathbf{0,2}$)	88,149	97,037	86,636	85,983	98,298	85,987	0,989

4.2.5. Sekiz sınıflı veri kümesi sınıflandırma sonuçları-2

Atelektazi, COVID-19, fibröz, akciğer opasitesi, normal, pnömoni, pnömotoraks ve TB grafiğini içeren farklı bir sekiz sınıflı veri kümesi üzerinde gerçekleştirilen sınıflandırma çalışmalarında önerilen model, Bölüm 3.3'te açıklanan kayıp fonksiyonları kullanılarak eğitilmiş ve test edilmiştir. Bu veri kümesi Bölüm 4.2.4'te analiz edilen sekiz sınıflı veri kümesinden farklı olarak “nodül” sınıfı yerine “fibröz” sınıfının dahil edilmesiyle oluşturulmuştur. Ayrıca daha önce açıklandığı gibi pnömoni sınıfı viral ve bakteriyel pnömoni alt sınıflarının birleştirilmesiyle tek bir sınıf olarak değerlendirilmiştir. Önerilen kayıp fonksiyonlarının genelleştirme yeteneğini göstermek için yapılan çalışmalar kapsamında, KÇE ve KH kayıp fonksiyonları ile çalışmada önerilen kayıp fonksiyonlarının sınıflandırma performansları karşılaştırılmıştır. Tüm analiz sonuçları, sınıf bazında elde edilen performans metriklerini gösterecek şekilde EK 9'da sunulmuştur. Önerilen kayıp fonksiyonlarının başarı sıralaması, ortalama performans metriklerine göre Tablo 4.4'te verilmiştir.

En yüksek performans, “Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE” ile elde edilmiş, bu yöntem %91,008 genel doğruluk ve %87,828 F1-skoru ile öne çıkmıştır. Bunu takiben “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE” yöntemi de %90,996 genel doğruluk ve %87,815 F1-skoru ile benzer düzeyde iyi bir performans göstermiştir. Dinamik kayıp fonksiyonları, doğruluk ve F1-skoru açısından ortalama bir performans sergilemişlerdir. Bununla birlikte, ceza terimi içeren yöntemler ($b=2$, $b=3$, $b=5$), tek başlarına değerlendirildiğinde daha düşük performans sergilemiş olsa da topluluk ve ağırlıklandırma stratejileri ile birleştirildiklerinde performans artışı sağlamışlardır. Standart yöntem olan KÇE %89,220 doğruluk ve %86,234 F1-skoru ile diğer yöntemlerin gerisinde kalmıştır. Genel olarak, önerilen topluluk ve ağırlıklı topluluk yöntemleri, temel metriklerde standart yöntemlere göre daha yüksek performans sergilemiştir. Özellikle ceza terimi ve dinamik yaklaşımlar ile önerilen yöntemlerin, performansı artırmadaki etkinlikleri kanıtlanmıştır.

Tablo 4.4. Sekiz sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları-2.

Kayıp Fonksiyonları	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	91,008	97,752	88,106	87,590	98,708	87,828	0,985
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	90,996	97,749	88,093	87,578	98,706	87,815	0,985
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	90,957	97,739	88,117	87,543	98,700	87,805	0,988
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	90,880	97,720	88,137	87,177	98,680	87,519	0,989
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu -En İyi KÇE + KH, KÇE + KH	90,16	97,704	88,116	86,825	98,668	87,251	0,989
Dinamik Kayıp Fonksiyonu- KH + KÇE	90,803	97,701	87,816	87,180	98,676	87,474	0,986
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	90,790	97,697	87,734	87,565	98,682	87,555	0,975
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	90,751	97,688	87,633	87,523	98,678	87,469	0,973
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	90,648	97,662	87,577	87,460	98,665	87,417	0,971
Dinamik Kayıp Fonksiyonu- KH + KÇE	90,648	97,617	87,493	87,010	98,632	87,208	0,981
Hibrit Kayıp Fonksiyonu ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)	90,391	97,598	87,261	88,367	98,640	87,589	0,991

Tablo 4.4. devam ediyor.

Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	90,391	97,598	87,342	87,000	98,613	87,129	0,989
<i>KH</i>	<i>90,160</i>	<i>97,540</i>	<i>87,276</i>	<i>86,007</i>	<i>98,590</i>	<i>86,231</i>	<i>0,979</i>
Ceza Terimi Eklenmiş KÇE (b=3)	90,147	97,537	87,244	85,416	98,577	86,043	0,985
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	90,147	97,537	87,311	85,679	98,569	86,122	0,988
Ceza Terimi Eklenmiş KÇE (b=5)	90,095	97,524	87,135	86,649	98,576	86,862	0,989
Dinamik Kayıp Fonksiyonu- KÇE + KH	90,069	97,517	87,230	85,601	98,558	86,037	0,988
Ceza Terimi Eklenmiş KÇE (b=2)	89,892	97,498	86,810	86,802	98,567	86,744	0,989
<i>KÇE</i>	<i>89,220</i>	<i>97,305</i>	<i>85,985</i>	<i>87,148</i>	<i>98,479</i>	<i>86,234</i>	<i>0,991</i>
Dinamik En Büyük Kayıp Fonksiyonu	88,835	97,209	85,936	85,055	98,390	85,149	0,988

4.2.6. Dokuz sınıflı veri kümesi sınıflandırma sonuçları

Atelektazi, COVID-19, fibröz, akciğer opasitesi, normal, plevral efüzyon, pnömoni, pnömotoraks ve TB graflerini içeren dokuz sınıflı veri kümesi üzerinde gerçekleştirilen sınıflandırma çalışmalarında önerilen model, Bölüm 3.3'te açıklanan kayıp fonksiyonları kullanılarak eğitilmiş ve test edilmiştir. Bu veri kümesi, önceki analizlerde kullanılan sekiz sınıflı veri kümesine plevral efüzyon sınıfının eklenmesiyle genişletilmiş ve modelin daha karmaşık sınıf ayrımları üzerindeki başarımı değerlendirilmiştir. Bu kapsamda elde edilen sınıflandırma sonuçları, sınıf bazında doğruluk, kesinlik, duyarlılık, özgüllük, F1-skoru ve AUC metrikleri açısından EK-10'da sunulmuştur. Önerilen kayıp fonksiyonlarının ortalama test performans değerlerinin karşılaştırması başarı sıralamasına göre Tablo 4.5'te verilmiştir.

Elde edilen sonuçlara göre, en yüksek performans “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)” yöntemi ile sağlanmış ve bu yöntem %86,089 genel doğruluk, %83,185 F1-skoru ve %98,243 özgüllük ile öne çıkmıştır. Bunu çok yakın başarıyla izleyen “Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)” yöntemi de benzer şekilde %86,078 genel doğruluk ve %83,204 F1-skoru ile başarılı sonuçlar üretmiştir. Ceza terimi eklenmiş fonksiyonların ve dinamik kayıp fonksiyonlarının topluluk yöntemleriyle birleştirilmesiyle önemli performans iyileşmesi sağlanmıştır. Bu durum, topluluk yöntemlerinin öğrenme sürecinde farklı kayıp fonksiyonlarının güçlü yönlerini birleştirerek modelin genelleme kapasitesini artırdığını göstermektedir. Dinamik kayıp fonksiyonları ise, %85 doğruluk seviyelerine ulaşmış olsa da duyarlılık, kesinlik ve F1-skorundaki küçük düşüşler nedeniyle diğer yöntemlere göre daha düşük performans sergilemiştir. Bunun yanında, standart yöntem olan KÇE, %84,943 genel doğruluk ve %81,794 F1-skoru ile ortalamanın altında bir performans göstermiştir. Diğer yandan KH fonksiyonu ise özellikle duyarlılık (%79,498) ve F1-skoru (%79,743) açısından düşük performans sergileyerek diğer yöntemlere göre başarısız olmuştur.

Sonuç olarak, önerilen topluluk ve ağırlıklı topluluk kayıp yaklaşımları, doğruluk, duyarlılık, özgüllük ve F1-skoru gibi metriklerde standart yöntemleri geride bırakmıştır. Sınıf sayısının artmasıyla birlikte, özellikle ceza terimi içeren KÇE fonksiyonlarının topluluk yöntemiyle birleştirilmesinin, genel sınıflandırma başarısını ve modelin genelleştirme yeteneğini artırdığı ortaya konmuştur.

Tablo 4.5. Dokuz sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları.

Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	86,089	96,909	83,495	82,915	98,243	83,185	0,979
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	86,078	96,906	83,505	82,942	98,241	83,204	0,979
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	86,034	96,896	83,519	82,443	98,233	82,872	0,977
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	85,736	96,830	83,185	82,197	98,195	82,611	0,976
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	85,692	96,820	83,066	82,596	98,195	82,798	0,978
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	85,582	96,796	82,995	82,677	98,183	82,686	0,978
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	85,549	96,789	83,016	82,661	98,178	82,664	0,978
Dinamik Kayıp Fonksiyonu- KÇE + KH	85,317	96,737	82,620	81,864	98,144	82,202	0,976
Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	85,284	96,730	82,713	81,545	98,137	81,960	0,976
Hibrit Kayıp Fonksiyonu ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)	85,086	96,686	82,607	81,722	98,117	82,093	0,977
Ceza Terimi Eklenmiş KÇE (b=5)	84,954	96,656	82,390	81,899	98,100	82,085	0,976
<i>KÇE</i>	<i>84,943</i>	<i>96,654</i>	<i>82,821</i>	<i>81,222</i>	<i>98,088</i>	<i>81,794</i>	<i>0,979</i>

Tablo 4.5. devam ediyor.

Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	84,888	96,642	82,219	82,079	98,099	81,921	0,977
Dinamik Kayıp Fonksiyonu- KH + KÇE	84,866	96,637	82,239	82,038	98,091	82,024	0,976
Dinamik Kayıp Fonksiyonu- KH + KÇE	84,788	96,620	82,092	81,915	98,087	81,769	0,973
<i>KH</i>	<i>84,579</i>	<i>96,573</i>	<i>83,103</i>	<i>79,498</i>	<i>98,043</i>	<i>79,743</i>	<i>0,971</i>
Ceza Terimi Eklenmiş KÇE (b=3)	84,557	96,568	81,876	81,210	98,046	81,491	0,976
Ceza Terimi Eklenmiş KÇE (b=2)	84,226	96,495	81,727	81,121	98,009	81,367	0,976
Dinamik En Büyük Kayıp Fonksiyonu	83,973	96,438	81,480	81,607	97,981	81,302	0,976

4.2.7. On sınıflı veri kümesi sınıflandırma sonuçları

Atelektazi, COVID-19, kardiyomegali, fibröz, akciğer opasitesi, normal, plevral efüzyon, pnömoni, pnömotoraks ve TB grafiğini içeren on sınıflı veri kümesi üzerinde yapılan sınıflandırma çalışmalarında model, Bölüm 3.3'te açıklanan kayıp fonksiyonları kullanılarak eğitilmiş ve test edilmiştir. Bu veri kümesi, bir önceki analizde kullanılan dokuz sınıflı yapıya ek olarak “kardiyomegali” sınıfının eklenmesiyle daha karmaşık hale gelmiştir. Böylece sınıflar arası ayrımın zorlaştığı daha yüksek sınıf sayısına sahip bir veri kümesi elde edilmiştir. Elde edilen tüm sonuçlar için sınıf bazında doğruluk, kesinlik, duyarlılık, özgüllük, F1-skoru ve AUC metrikleri EK 11'de sunulmuştur. Tablo 4.6'da ise önerilen kayıp fonksiyonlarının ortalama performans değerlerinin karşılaştırılması verilmiştir.

Sunulan performans karşılaştırmasına göre, önerilen kayıp fonksiyonları içerisinde en yüksek başarı “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi ($b=2$, $b=3$, $b=5$)” yöntemi kullanılarak elde edilmiştir. Bu yöntem, %84,274 genel doğruluk, %80,452 F1-skoru ve %98,225 özgüllük değerleri ile yüksek başarı göstermiştir. Dinamik kayıp fonksiyonları, yaklaşık %83 oranında genel doğruluk ile ortalama seviyede bir performans göstermiş, ancak duyarlılık ve F1-skoru açısından diğer yöntemlerin gerisinde kalmıştır. Bu durum, dinamik yapıların sınıf dengesizliği olan veri kümelerinde her zaman avantaj sağlamayabileceğini göstermektedir. Standart yöntemler olan KÇE ve KH fonksiyonları, sırasıyla %82,774 ve %82,826 genel doğruluk değerleriyle orta sıralarda yer almış, özellikle kesinlik açısından diğer yöntemlerin gerisinde kalmıştır. Ceza terimi eklenmiş KÇE ($b=3$ ve $b=5$) yöntemleri ise genel doğruluk ve F1-skoru açısından en düşük performansı sergilemiştir.

Genel olarak, topluluk tabanlı kayıp fonksiyonları özellikle ceza terimi ve ağırlıklandırma yaklaşımlarıyla desteklendiğinde doğruluk, duyarlılık ve F1-skoru gibi metriklerde üstün bir performans sağlamıştır. Bu da yüksek sınıf sayısına ve dengesiz dağılıma sahip veri kümelerinde bu yaklaşımların etkili ve genelleştirilebilir bir çözüm sunduğunu ortaya koymaktadır.

Tablo 4.6. On sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları.

Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	84,274	96,855	81,742	79,599	98,225	80,452	0,979
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	84,253	96,851	81,748	79,506	98,223	80,354	0,979
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	83,980	96,796	80,761	79,887	98,200	80,265	0,972
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	83,949	96,790	81,274	79,221	98,189	80,086	0,977
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	83,875	96,775	80,643	79,658	98,187	80,090	0,972
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KH + KÇE, KH + KÇE	83,456	96,691	80,185	79,423	98,143	79,723	0,972
Dinamik Kayıp Fonksiyonu- KÇE + KH	83,256	96,651	80,842	78,067	98,109	78,979	0,965
Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	83,256	96,651	80,842	78,067	98,109	78,979	0,965
Ceza Terimi Eklenmiş KÇE (b=2)	82,942	96,588	80,237	77,881	98,071	78,736	0,975
Dinamik Kayıp Fonksiyonu- KH + KÇE	82,889	96,578	79,785	78,397	98,074	78,889	0,972
<i>KH</i>	82,826	96,565	78,982	79,376	98,087	79,076	0,968
Dinamik Kayıp Fonksiyonu- KH + KÇE	82,816	96,563	79,441	78,622	98,073	78,925	0,967
<i>KÇE</i>	82,774	96,555	79,672	79,047	98,064	79,226	0,964
Dinamik En Büyük Kayıp Fonksiyonu	82,721	96,544	80,504	77,521	98,039	78,547	0,974

Tablo 4.6. devam ediyor.

Hibrit Kayıp Fonksiyonu ($\mathbf{w}_{KCE} = \mathbf{0,8}$ ve $\mathbf{w}_{KH} = \mathbf{0,2}$)	82,459	96,492	79,038	78,873	98,034	78,603	0,973
Ceza Terimi Eklenmiş KÇE (b=5)	82,165	96,433	79,386	77,222	97,993	77,733	0,975
Ceza Terimi Eklenmiş KÇE (b=3)	81,861	96,372	78,953	76,862	97,962	77,628	0,974

4.2.8. On iki sınıflı veri kümesi sınıflandırma sonuçları

Atelektazi, COVID-19, kardiyomegali, konsolidasyon, ödem, fibröz, akciğer opasitesi, normal, plevral efüzyon, pnömoni, pnömotoraks ve TB sınıflarını içeren on iki sınıflı veri kümesi, on sınıflı veri kümesine ek olarak “konsolidasyon” ve “ödem” sınıflarının dahil edilmesiyle oluşturulmuştur. Böylece sınıf sayısı artırılarak modelin ve kayıp fonksiyonlarının yalnızca çok sınıflı yapıdaki genel performansı değil, aynı zamanda birbiriyle yakın ilişkili sınıflar arasındaki ayrım yapabilme yeteneği de değerlendirilmiştir. Bu sınıfların çoğu, benzer klinik belirtilere ve görüntüleme bulgularına sahip olup, görüntü düzeyinde ayrıştırılması zorlu olan patolojik grupları temsil etmektedir. Bu doğrultuda önerilen model Bölüm 3.3’te açıklanan kayıp fonksiyonları kullanılarak eğitilmiş ve test edilmiştir. Çalışma kapsamında elde edilen tüm performans sonuçları EK 12’de ayrıntılı olarak sunulmuştur. Tablo 4.7’de ise önerilen kayıp fonksiyonlarının ortalama test performans değerleri verilmiştir.

Sunulan performanslara göre, önerilen kayıp fonksiyonları arasında en yüksek başarı “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)” ile elde edilmiştir. Bu yöntem %79,404 genel doğruluk, %72,217 F1-skoru, %98,104 özgüllük sunmuştur. Hemen ardından gelen “Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)” ve “Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)” ise sırasıyla %79,394 ve %78,888 genel doğruluk oranlarıyla en iyi performansa yakın sonuçlar göstermiştir. Ceza terimi eklenmiş KÇE (b=2 ve b=5) fonksiyonları, sırasıyla %77,665 ve %77,598 genel doğruluk ile daha düşük performans göstermiş olsalar da duyarlılık ve kesinlik açısından orta düzeyde sonuçlar elde etmişlerdir. Ayrıca bu fonksiyonların, sınıf sayısının az olduğu veri kümelerinde düşük performans sergilerken, 12 sınıfa sahip veri kümesinde daha yüksek başarı sağlaması özellikle dengesiz dağılıma sahip ve semantik benzerliği yüksek sınıfların bulunduğu durumlarda daha etkili olduğunu göstermektedir. Dinamik kayıp fonksiyonları, benzer şekilde yaklaşık %77 genel doğruluk ile orta sıralarda yer almış, özellikle duyarlılık ve kesinlikteki düşüşler nedeniyle diğer yöntemlerin gerisinde kalmıştır. Bu durum, dinamik yapıların yüksek sınıf sayısı ve semantik olarak benzer sınıflar içeren veri kümelerinde sınıf ayrımında sınırlı kaldığını göstermektedir. En düşük performansı sergileyen yöntemler arasında KH, %76,538 genel doğruluk, %68,899 kesinlik ve %68,097 duyarlılık ile yer alırken en başarısız kayıp fonksiyonu %76,175 genel doğruluk ile KÇE olmuştur.

Bu sonuçlar, sınıf sayısının artmasıyla birlikte modelin karşılaştığı zorlukları da ortaya koymaktadır. Özellikle semantik benzerliği yüksek sınıfların varlığı (örneğin pnömoni ve

konsolidasyon gibi), sınıflar arası ayrımı daha karmaşık hale getirmekte ve bu durum bazı kayıp fonksiyonlarının performansını doğrudan etkilemektedir. Ancak bu zorluğa rağmen, önerilen topluluk ve ağırlıklı topluluk yaklaşımlarının, özellikle ceza terimi ile desteklendiğinde, doğruluk, duyarlılık ve F1-skoru gibi temel metriklerde standart yöntemleri belirgin biçimde geride bıraktığı görülmektedir. Sonuç olarak, bu bulgular, önerilen kayıp fonksiyonlarının sadece yüksek doğruluk değil, aynı zamanda genelleştirilebilir ve istikrarlı bir sınıflandırma başarısı sunduğunu, özellikle yüksek sınıf sayısına ve dengesiz dağılıma sahip tıbbi görüntü sınıflandırma problemleri için güçlü bir alternatif olduğunu ortaya koymaktadır.

Tablo 4.7. On iki sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları.

Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	79,404	96,567	73,489	71,672	98,104	72,217	0,967
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	79,394	96,566	73,504	71,712	98,103	72,250	0,967
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	78,888	96,481	72,701	70,862	98,057	71,468	0,966
Ceza Terimi Eklenmiş KÇE (b=2)	77,665	96,278	71,578	70,431	97,947	70,831	0,963
Ceza Terimi Eklenmiş KÇE (b=5)	77,598	96,266	71,395	69,412	97,942	70,095	0,959
Dinamik Kayıp Fonksiyonu- KÇE + KH	77,503	96,250	71,060	69,197	97,935	69,707	0,957
Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	77,503	96,250	71,060	69,197	97,935	69,707	0,957
Dinamik Kayıp Fonksiyonu- KH + KÇE	76,700	96,117	70,338	69,562	97,870	69,721	0,955
Dinamik Kayıp Fonksiyonu- KH + KÇE	76,700	96,117	70,338	69,562	97,870	69,721	0,955
Hibrit Kayıp Fonksiyonu ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)	76,614	96,102	70,290	68,869	97,852	69,418	0,953
<i>KH</i>	76,538	96,090	68,899	68,097	97,849	67,420	0,939
Ceza Terimi Eklenmiş KÇE (b=3)	76,433	96,072	70,151	69,074	97,832	69,251	0,959
Dinamik En Büyük Kayıp Fonksiyonu	76,223	96,037	69,484	69,306	97,833	69,301	0,944
<i>KÇE</i>	76,175	96,029	69,815	68,339	97,814	68,849	0,948

4.2.9. On dört sınıflı veri kümesi sınıflandırma sonuçları

Atelektazi, COVID-19, kardiyomegali, konsolidasyon, ödem, fibröz, kosta kırığı, akciğer opasitesi, kitle, normal, plevral efüzyon, pnömoni, pnömotoraks ve TB sınıflarını içeren on dört sınıflı veri kümesi üzerinde gerçekleştirilen sınıflandırma çalışmalarında, model Bölüm 3.3'te açıklanan kayıp fonksiyonları kullanılarak eğitilmiş ve test edilmiştir. Bu veri kümesi, 12 sınıflı yapıya göre “kosta kırığı” ve “kitle” sınıflarının eklenmesiyle genişletilmiştir. Böylece model yalnızca yüksek sınıf sayısı ile değil, aynı zamanda ayırt edilmesi güç görüntü özelliklerine sahip yeni sınıflarla da test edilmiştir. Bu kapsamda, çalışmada önerilen kayıp fonksiyonları ve KÇE ve KH fonksiyonları kullanılarak yapılan analizlerin sonuçları, sınıf bazında elde edilen performans metriklerini gösterecek şekilde EK 13'te sunulmuştur. Önerilen kayıp fonksiyonlarının ortalama test performans değerleri ise Tablo 4.8'de verilmiştir.

Ortalama performans karşılaştırmasına göre, önerilen kayıp fonksiyonları arasında en yüksek başarı, %76,877 genel doğruluk ile “Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)” yöntemiyle elde edilmiştir. Bu sonuç, ceza terimi ile desteklenen topluluk temelli yaklaşımların, artan sınıf sayısına rağmen modelin ayırt edici gücünü koruyabildiğini göstermektedir. İkinci sırada yer alan “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)” yöntemi, %76,841 doğruluk oranı ile benzer düzeyde güçlü bir performans sergilemiştir. Bunu takiben, dinamik KÇE + KH kombinasyonlarına dayalı aritmetik ortalama ve ağırlıklı topluluk fonksiyonları sırasıyla %75,761 ve %75,554 genel doğrulukla dikkat çekici başarı göstermiştir. Dinamik kayıp fonksiyonları, %74,410-74,794 aralığında doğruluk elde etmiş ve duyarlılık ile kesinlik metriklerinde ortalama bir performans sergilemiştir. Standart yöntem olan KÇE, %74,543 genel doğruluk ile orta seviyede bir performans göstermiştir. Ancak, duyarlılık ve özgüllük metriklerinde diğer yöntemlerin gerisinde kalmıştır. KH ise genel %74,149 doğruluk ile düşük bir performans elde etmiştir.

Sınıf sayısının 14'e çıkarılmasıyla birlikte, semantik benzerliği yüksek sınıflar (örneğin konsolidasyon, pnömoni, akciğer opasitesi, ödem) arasındaki ayrım daha karmaşık hale gelmiş; bu durum genel doğruluk oranlarında doğal bir düşüşe yol açmıştır. Ancak bu zorluklara rağmen, önerilen topluluk tabanlı kayıp fonksiyonları, özellikle ceza terimi ve ağırlıklandırma yaklaşımlarıyla birleştirildiğinde, sınıflar arası ayrımı başarıyla sağlayarak yüksek doğruluk, duyarlılık ve F1-skoru değerleri sunmuştur. Dolayısıyla bu yöntemlerin çok sınıflı ve dengesiz dağılıma sahip tıbbi görüntü veri kümelerinde genellenabilirliği yüksek, istikrarlı ve etkili bir sınıflandırma performansı gösterebileceği kanıtlanmıştır.

Tablo 4.8. On dört sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları.

Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	76,877	96,565	69,441	67,833	98,118	68,172	0,961
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	76,841	96,562	69,416	67,760	98,117	68,121	0,961
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	75,761	96,376	67,927	66,552	98,015	67,063	0,953
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	75,554	96,355	68,078	66,202	97,995	66,887	0,954
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	75,293	96,338	67,507	66,214	98,004	66,471	0,959
Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	74,797	96,249	66,604	65,903	97,961	66,106	0,947
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	74,797	96,249	66,607	65,903	97,961	66,108	0,947
<i>KÇE</i>	<i>74,543</i>	<i>96,218</i>	<i>67,167</i>	<i>66,425</i>	<i>97,939</i>	<i>66,703</i>	<i>0,955</i>
Ceza Terimi Eklenmiş KÇE (b=2)	74,563	96,213	67,588	65,344	97,902	65,444	0,957
Dinamik Kayıp Fonksiyonu- KÇE + KH	74,410	96,181	67,769	64,659	97,880	65,757	0,951
Hibrit Kayıp Fonksiyonu ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)	74,239	96,165	66,604	65,574	97,898	65,918	0,951
<i>KH</i>	<i>74,149</i>	<i>96,155</i>	<i>64,473</i>	<i>65,597</i>	<i>97,925</i>	<i>63,899</i>	<i>0,933</i>
Ceza Terimi Eklenmiş KÇE (b=3)	73,951	96,143	65,953	64,964	97,908	65,103	0,947

Tablo 4.8. devam ediyor.

Dinamik En Büyük Kayıp Fonksiyonu	73,798	96,115	66,211	65,072	97,881	64,996	0,946
Ceza Terimi Eklenmiş KÇE (b=5)	73,780	96,102	66,534	64,181	97,889	64,765	0,952
Dinamik Kayıp Fonksiyonu- KH+ KÇE	73,627	96,077	65,997	65,963	97,900	65,590	0,950
Dinamik Kayıp Fonksiyonu- En İyi KH + KÇE	73,627	96,077	65,997	65,963	97,900	65,590	0,950

4.2.10. On beş sınıflı veri kümesi sınıflandırma sonuçları

Atelektazi, COVID-19, kardiyomegali, konsolidasyon, ödem, fibröz, kosta kırığı, infiltrasyon, akciğer opasitesi, kitle, normal, plevral efüzyon, pnömoni, pnömotoraks ve TB sınıflarını içeren on beş sınıflı veri kümesi üzerinde gerçekleştirilen sınıflandırma çalışmalarında, model Bölüm 3.3'te açıklanan kayıp fonksiyonları kullanılarak eğitilmiş ve test edilmiştir. Bu veri kümesi, 14 sınıflı veri kümesine “infiltrasyon” sınıfının eklenmesiyle oluşturulmuş, böylece modelin yalnızca artan sınıf sayısı ile değil, aynı zamanda görüntüsel benzerliği yüksek ve ayırt edilmesi zor olan yeni sınıflarla başa çıkma yeteneğinin de değerlendirilmesini sağlamıştır. Bu kapsamda, farklı kayıp fonksiyonlarıyla yapılan analizlerin sonuçları, sınıf bazında elde edilen performans metriklerini gösterecek şekilde EK 14'te sunulmuştur. Önerilen kayıp fonksiyonlarının ortalama test performans değerleri Tablo 4.9'da verilmiştir.

Tablo incelendiğinde, en yüksek başarının %74,345 genel doğruluk, %66,968 kesinlik ve %66,393 F1-skoru ile “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu – Ceza Terimi (b=2, b=3, b=5)” yöntemi ile elde edildiği görülmektedir. Bu sonuç, sınıf sayısı 15'e ulaşmış olmasına rağmen topluluk yapısına entegre edilmiş ceza terimi fonksiyonunun modelin genelleme yeteneğini artırarak yüksek performans sağladığını ortaya koymaktadır. En başarılı performansı takiben “Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)” yöntemiyle %74,260 genel doğruluk oranı elde edilmiştir. Bunun yanı sıra, ceza terimi içermeyen diğer topluluk yöntemleriyle (“Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH”, “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH”, “Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH”) ortalama düzeyde doğruluk değerleri elde edilmiş (%72,2 – %72,7 aralığında), ancak bu yöntemler duyarlılık ve F1-skoru açısından geride kalmıştır. Dinamik kayıp fonksiyonları yaklaşık %71 oranında genel doğruluk sağlayarak ortalama bir başarı elde etmiştir. Bu durum, dinamik yapıların çok sayıda semantik olarak benzer sınıf içeren veri kümelerinde daha az etkili olabileceğini göstermektedir. Ceza terimi içeren KÇE fonksiyonları da benzer şekilde %71 düzeyinde doğruluk sunmuş, ancak topluluk tabanlı yöntemlerle kıyaslandığında daha zayıf kalmıştır. Standart yöntemler olan KÇE ve KH fonksiyonları ise sırasıyla %71,366 ve %71,854 genel doğruluk oranları ile düşük performans sergilemişlerdir. Özellikle KH fonksiyonunun duyarlılık (%62,146) ve F1-skoru (%61,579) gibi kritik metriklerde yetersiz performans gösterdiği tespit edilmiştir.

Sınıf sayısının artmasıyla birlikte modelin genel sınıflandırma performansında doğal olarak bir düşüş yaşanmıştır. Bunun temel nedeni, sınıflar arasındaki semantik benzerliklerin

artması ve bazı sınıfların görüntüsel olarak kolay ayırt edilememesidir. Ancak bu zorluklara rağmen, önerilen topluluk temelli kayıp fonksiyonları özellikle ceza terimi ile desteklendiğinde yüksek sınıf sayısına sahip dengesiz veri kümelerinde güvenilir bir performans sunmuştur. Sonuç olarak, 15 sınıflı çoklu sınıflandırma probleminde en yüksek başarı farklı ceza terimi fonksiyonlarının topluluk yaklaşımıyla birleştirilmesiyle sağlanmıştır. Bu yöntemler, sadece genel doğruluk açısından değil, aynı zamanda duyarlılık, özgüllük ve F1-skoru gibi önemli metriklerde de tatmin edici sonuçlar göstermiştir. Bu durum da önerilen yaklaşımın, özellikle tıbbi görüntü sınıflandırması gibi çok sınıflı ve dengesiz veri dağılımına sahip problemler için güçlü bir potansiyel sunduğunu ortaya koymaktadır.

Tablo 4.9. On beş sınıf için önerilen kayıp fonksiyonlarıyla elde edilen test sonuçları.

Kayıp Fonksiyonları	Genel		Sınıf Bazında Ortalama				
	Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	74,345	96,579	66,968	66,286	98,164	66,393	0,956
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	74,260	96,568	66,797	66,161	98,157	66,271	0,956
Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	73,112	96,415	66,045	64,911	98,076	65,091	0,954
Aritmetik Ortalama Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	72,710	96,361	65,115	64,024	98,042	64,354	0,938
Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	72,419	96,322	65,085	63,916	98,022	64,267	0,938
Ağırlıklı Topluluk Kayıp Fonksiyonu- En İyi KÇE + KH, KÇE + KH	72,205	96,293	65,158	63,822	98,006	64,216	0,938
Dinamik Kayıp Fonksiyonu- KÇE + KH	72,137	96,284	64,314	63,156	97,999	63,497	0,941
Ceza Terimi Eklenmiş KÇE (b=5)	71,965	96,262	65,044	63,503	97,992	63,995	0,948
<i>KH</i>	71,854	96,246	62,706	62,146	97,981	61,579	0,928
Ceza Terimi Eklenmiş KÇE (b=3)	71,674	96,223	63,187	63,149	97,970	63,000	0,948

Tablo 4.9. devam ediyor.

Dinamik Kayıp Fonksiyonu- KH + KÇE	71,563	96,208	65,143	61,593	97,948	62,484	0,943
Dinamik Kayıp Fonksiyonu- En İyi KH + KÇE	71,563	96,208	65,143	61,593	97,948	62,484	0,943
<i>KÇE</i>	<i>71,366</i>	96,182	<i>64,599</i>	<i>63,624</i>	<i>97,961</i>	<i>63,643</i>	<i>0,944</i>
Ceza Terimi Eklenmiş KÇE (b=2)	71,195	96,159	63,613	62,671	97,936	62,617	0,948
Hibrit Kayıp Fonksiyonu ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)	71,118	96,148	63,800	61,132	97,911	61,611	0,953
Dinamik Kayıp Fonksiyonu- En İyi KÇE + KH	71,007	96,134	64,194	62,615	97,922	63,097	0,929
Dinamik En Büyük Kayıp Fonksiyonu	68,028	95,736	61,641	58,107	97,683	57,651	0,951

4.2.11. En başarılı kayıp fonksiyonunun seçilmesi

Bu bölümde 6'dan 15'e kadar farklı sınıf sayısına sahip veri kümeleri ile yapılan sınıflandırma çalışmalarını sonuçları karşılaştırmalı olarak sunulmuştur. Buradaki temel amaç, özellikle çok sınıflı ve dengesiz dağılıma sahip tıbbi görüntü sınıflandırma problemlerinde en etkili kayıp fonksiyonunu belirlemektir.

Önceki bölümlerde ayrıntılı bir şekilde gösterildiği gibi daha düşük sınıf sayısına sahip veri kümelerinde (6, 7 sınıf) dinamik yöntemlerin topluluk kaybıyla birleştirilmesi sonucunda yüksek performanslar elde edilmiştir. Ancak sınıf sayısı arttıkça bu yöntemler yerine ceza terimi eklenmiş KÇE'lerin topluluk yöntemleriyle birleştirilmesi ile sunulan kayıp fonksiyonları en yüksek başarıyı göstermeye başlamıştır.

Özellikle “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi ($b=2$, $b=3$, $b=5$)”, 9, 10, 12 ve 15 sınıflı veri kümelerinde en yüksek performansı sağlamıştır. Ayrıca 6, 7, 8 sınıflı veri kümelerinde en başarılı ilk beş fonksiyon içinde yer almış, 14 sınıflı veri kümesinde ise ikinci en iyi performansı göstermiştir.

Dolayısıyla tüm sınıflandırma görevleri birlikte değerlendirildiğinde önerilen “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi ($b=2$, $b=3$, $b=5$)” yaklaşımının en başarılı, en istikrarlı ve en genellenebilir kayıp fonksiyonu olduğu ortaya konmuştur.

Tablo 4.10'da tüm sınıflar için “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi ($b=2$, $b=3$, $b=5$)”, KÇE ve KH ile elde edilen performanslar verilmiştir. Bu karşılaştırmada referans olarak KÇE'nin seçilmesinin nedeni, bu fonksiyonun çok sınıflı sınıflandırma problemlerinde derin öğrenme modellerinde en yaygın kullanılan, literatürde standart kabul edilen bir yöntem olmasıdır. Bu nedenle bu çalışmada da önerilen hibrit, dinamik, ceza terimi içeren ve topluluk tabanlı kayıp fonksiyonları ile elde edilen sonuçlar KÇE ve KH ile kıyaslanarak değerlendirilmiştir.

Tablo 4.10 incelendiğinde sınıf sayısı arttıkça model performanslarında bir düşüş yaşandığı görülmektedir. Bu düşüş, özellikle sınıf sayısının arttığı, ayrımının zorlaştığı ve semantik benzerliğin yüksek olduğu sınıflarda daha belirgindir. Bunun nedeni sınıf sayısının artmasıyla sınıflandırma probleminin karmaşılaşması dolayısıyla zorluk derecesinin artmasıdır. Bununla birlikte sınıf sayısı arttıkça kesinlik ve duyarlılıkta düşüş yaşanırken özgüllük değerinde belirgin bir azalma yaşanmadığı görülmektedir Çok sınıflı sınıflandırma problemlerinde, her bir sınıf için negatif örnekler, ilgili sınıfa ait olmayan tüm diğer sınıfları kapsar. Örneğin, “kardiyomegali” sınıfı için negatif örnekler; COVID-19, pnömotoraks, ödem, normal, vb. gibi bu sınıfa ait olmayan diğer hastalıklardan oluşmaktadır. Dolayısıyla,

özgüllük metriği, modelin kardiyomegali dışındaki tüm diğer sınıfları doğru biçimde "kardiyomegali değil" olarak ayırt etme başarısını göstermektedir. Bu bağlamda özgüllüğün yüksek olması, modelin her bir sınıfa ait olmayan örnekleri büyük ölçüde doğru dışlayabildiğini ve aşırı pozitif tahminlerden kaçındığını ortaya koymaktadır. Bu durum özellikle klinik açıdan önemlidir çünkü yanlış negatif hatalar yani mevcut bir hastalığın model tarafından atlanması, doğrudan tanı gecikmesine, yanlış yönlendirmelere ve tedavi sürecinin aksamasına yol açabilirken, yanlış pozitif hatalar çoğunlukla gereksiz tetkiklere ve kısa süreli psikolojik streslere neden olmaktadır [175]. Bu çalışmada, modelin özellikle yanlış sınıflandırmaları minimize etmesi ve gerçek negatifleri doğru tanıma yeteneğinin yüksek olması hedeflenmiştir. Özgüllüğün korunması hem modelin güvenilirliğini artırmakta hem de klinik uygulamalarda yanlış yönlendirmeleri azaltarak tanı sürecini daha etkili ve güvenilir hâle getirmektedir.

Önerilen “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi ($b=2$, $b=3$, $b=5$)” yaklaşımı, KÇE ve KH’ye kıyasla anlamlı performans artışı sağlamıştır. Özellikle sınıf sayısı arttığında bu fonksiyonun sağladığı iyileştirme daha belirgin hale gelmiştir. Önerilen fonksiyon yalnızca genel doğruluk açısından değil, duyarlılık, özgüllük ve F1-skoru gibi kritik metriklerde de KÇE ve KH’ye kıyasla üstün sonuçlar vermiştir. Özellikle 15 sınıflı veri kümesinde KÇE ve KH’ye göre %3’e yakın doğruluk artışı sağlanmıştır. Bu görevde sınıf bazında değerlendirme yapıldığında (EK 14) atelektazi sınıfında, F1-skoru %45,571’den %49,435’e, kesinlik %48,330’dan %55,161’e yükselmiş, AUC değeri ise 0,894’ten 0,911’e çıkarak sınıf ayırt ediciliğinin arttığını göstermiştir. Kardiyomegali sınıfında duyarlılık %53,696’dan %56,304’e, F1-skoru ise %55,819’dan %57,748’e yükselmiş ve AUC değeri 0,963’e ulaşmıştır. Ayrımı zor olan konsolidasyon sınıfında F1-skoru %19,636’dan %25,537’ye, kesinlik %14,694’ten %23,709’a, AUC ise 0,821’den 0,859’a çıkarak modelin bu sınıfta daha iyi öğrendiği gözlenmiştir. Ödem sınıfında özellikle kesinlikte %10’luk bir artış (%52,797’den %62,611’e) sağlanmış, AUC değeri de 0,939’dan 0,954’e yükselmiştir. Fibröz sınıfında F1-skoru %36,741’den %38,585’e ulaşırken ve AUC değeri 0,939’a çıkarak modelin ayırım başarısı güçlenmiştir. Kosta kırığı için F1-skorundaki artış (%50,199’dan %53,895’e) ve duyarlılıktaki yükselme (%56,250’den %57,143’e), kayıp fonksiyonu sayesinde modelin bu sınıfta yanlış negatifleri azalttığını ve daha güvenilir sonuçlar verdiğini göstermektedir. İnfiltrasyon sınıfında da benzer şekilde F1-skoru %41,680’den %45,696’ya, duyarlılık ise %46,853’ten %51,049’a yükselmiş ve AUC 0,915’e ulaşmıştır. Akciğer opasitesi sınıfında F1-skoru %94,750’den %95,507’ye yükselerek yüksek performans daha da iyileştirilmiştir. Kitle sınıfında en

belirgin gelişim duyarlılıkta (%38,995'ten %50,000'ye) ve F1-skorunda (%47,941'den %54,215'e) gözlenmiş, bu sınıfta kayıp fonksiyonunun fark edilebilir şekilde iyileşme sağladığı ortaya konmuştur. Normal sınıfında F1-skoru %96,995'ten %97,247'ye yükselerek üst düzey başarıyı korumuştur. Plevral efüzyon sınıfında duyarlılığın %55,778'den %65,562'ye, F1-skorunun ise %58,862'den %64,130'a yükselmesi, önerilen kayıp fonksiyonunun sınıflandırma başarılarını iyileştirdiğini ortaya koymuştur. Pnömotoraks gibi dengesiz bir sınıfta ise duyarlılığın %51,594'ten %68,123'e, F1-skorunun ise %55,527'den %61,514'e çıkması modelin pozitif sınıfları daha iyi tanıdığını göstermiştir. Öte yandan, COVID-19, pnömoni ve tüberküloz gibi zaten yüksek başarıya sahip sınıflarda performans ya sabit kalmış ya da küçük marjlarla değişmiştir. Bu da önerilen kayıp fonksiyonunun özellikle zayıf performansa sahip sınıflarda etkili olduğunu, zaten başarılı olan sınıflarda ise mevcut öğrenmeyi koruduğunu göstermektedir.

Sonuç olarak, önerilen ceza terimi içeren kayıp fonksiyonu, sınıf dengesizliği bulunan tıbbi görüntüleme problemlerinde, ayrımı güç sınıfların öğrenilmesini destekleyerek modelin genel başarılarını ve sınıflar arası dengeyi önemli ölçüde iyileştirmiştir.

Bu başarıda hem ceza teriminin hem de topluluk yöntemlerinin büyük katkısı vardır. Ceza terimi, modelin yalnızca doğru sınıfı öğrenmesini değil, aynı zamanda yanlış sınıflardan uzak durmasını da teşvik edecek şekilde tasarlanmıştır. Bu durum, özellikle nadir sınıflar (örneğin: TB, pnömotoraks, kardiyomegali), ve semantik olarak benzer sınıflar (örneğin: infiltrasyon, ödem, konsolidasyon) gibi zorluk seviyesi yüksek sınıflarda modelin daha dikkatli ve seçici öğrenmesini sağlamaktadır. Önerilen topluluk tabanlı kayıp fonksiyonları, farklı kayıp fonksiyonlarının güçlü yönlerini bir araya getirerek hem sınıf içi hem de sınıf dışı ayrım performansını artırmaktadır. Özellikle doğruluğa göre ağırlıklandırma, modelin her sınıfa eşit önem verirken yüksek performans gösteren bileşenlerden daha fazla yararlanmasını sağlamaktadır.

Tablo 4.10. Sınıf bazında Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5), KÇE ve KH ile elde edilen performansların karşılaştırılması.

Sınıf Sayısı	Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
		Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
6 sınıf	Doğruluğa Göre Ağırlıklı Kayıp Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	94,966	98,332	91,946	92,315	98,963	91,952	0,995
	<i>KÇE</i>	<i>94,471</i>	<i>98,157</i>	<i>91,532</i>	<i>91,062</i>	<i>98,839</i>	<i>91,280</i>	<i>0,992</i>
	<i>KH</i>	<i>94,289</i>	<i>98,096</i>	<i>90,909</i>	<i>90,774</i>	<i>98,821</i>	<i>90,835</i>	<i>0,982</i>
7 sınıf	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	95,097	98,599	92,834	92,473	99,139	92,644	0,995
	<i>KH</i>	<i>94,874</i>	<i>98,536</i>	<i>92,617</i>	<i>92,338</i>	<i>99,107</i>	<i>92,471</i>	<i>0,993</i>
	<i>KÇE</i>	<i>94,259</i>	<i>98,360</i>	<i>91,931</i>	<i>91,249</i>	<i>98,983</i>	<i>91,574</i>	<i>0,994</i>
8 sınıf	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	90,834	97,709	89,492	89,155	98,686	89,315	0,989
	<i>KÇE</i>	<i>89,398</i>	<i>97,350</i>	<i>88,173</i>	<i>87,841</i>	<i>98,478</i>	<i>87,868</i>	<i>0,985</i>
	<i>KH</i>	<i>88,936</i>	<i>97,234</i>	<i>86,986</i>	<i>87,088</i>	<i>98,417</i>	<i>86,924</i>	<i>0,988</i>
9 sınıf	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza Terimi (b=2, b=3, b=5)	86,089	96,909	83,495	82,915	98,243	83,185	0,979
	<i>KÇE</i>	<i>84,943</i>	<i>96,654</i>	<i>82,821</i>	<i>81,222</i>	<i>98,088</i>	<i>81,794</i>	<i>0,979</i>
	<i>KH</i>	<i>84,579</i>	<i>96,573</i>	<i>83,103</i>	<i>79,498</i>	<i>98,043</i>	<i>79,743</i>	<i>0,971</i>
10 sınıf	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	84,274	96,855	81,742	79,599	98,225	80,452	0,979
	<i>KH</i>	<i>82,826</i>	<i>96,565</i>	<i>78,982</i>	<i>79,376</i>	<i>98,087</i>	<i>79,076</i>	<i>0,968</i>
	<i>KÇE</i>	<i>82,774</i>	<i>96,555</i>	<i>79,672</i>	<i>79,047</i>	<i>98,064</i>	<i>79,226</i>	<i>0,964</i>

Tablo 4.10. devam ediyor.


12 sınıf	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	79,404	96,567	73,489	71,672	98,104	72,217	0,967
	<i>KH</i>	76,538	96,090	68,899	68,097	97,849	67,420	0,939
	<i>KÇE</i>	76,175	96,029	69,815	68,339	97,814	68,849	0,948
14 sınıf	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	76,841	96,562	69,416	67,760	98,117	68,121	0,961
	<i>KÇE</i>	74,543	96,218	67,167	66,425	97,939	66,703	0,955
	<i>KH</i>	74,149	96,155	64,473	65,597	97,925	63,899	0,933
15 sınıf	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	74,345	96,579	66,968	66,286	98,164	66,393	0,956
	<i>KH</i>	71,854	96,246	62,706	62,146	97,981	61,579	0,928
	<i>KÇE</i>	71,366	96,182	64,599	63,624	97,961	63,643	0,944

4.2.12. En başarılı kayıp fonksiyonunun modelden bağımsız performans değerlendirmesi

Bu bölümde, önceki bölümde (Bölüm 4.2.11) en başarılı kayıp fonksiyonu olarak belirlenen “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi ($b=2$, $b=3$, $b=5$)”ın Bölüm 3.2’de önerilen farklı model mimarileri üzerindeki performansı değerlendirilmiştir. Buradaki amaç, bu fonksiyonun yalnızca belirli bir modelde değil, farklı modellerde de tutarlı ve yüksek performans sergilediğini göstermektir.

Bu kapsamda, çalışmada kullanılan tüm modeller (Model 1- Model 7), önerilen kayıp fonksiyonu ile eğitilmiş ve test edilmiştir. Elde edilen sonuçlar KÇE ve KH fonksiyonlarıyla karşılaştırılmıştır. Karşılaştırma sonuçları Tablo 4.11’de, tüm modeller için elde edilen genel doğruluk değerleri görsel olarak Şekil 4.16’da sunulmuştur. Sınıf bazında performans değerleri ayrıntılı olarak EK 15’te verilmiştir.

Analizler yalnızca 15 sınıflı veri kümesi kullanılarak gerçekleştirilmiştir. Bunun iki temel sebebi bulunmaktadır. İlk olarak, 15 sınıflı veri kümesi, çalışmadaki en yüksek sınıf sayısına sahip veri kümesidir. Ayrıca bu veri kümesinde sınıflar arası semantik benzerlikler fazla, veri dağılımı ise oldukça dengesizdir, dolayısıyla bu en zorlu sınıflandırma problemidir. İkinci olarak, bu çalışma kapsamında odaklanılan temel problem çok sınıflı sınıflandırmalarda (özellikle tıbbi görüntülerde) önerilen kayıp fonksiyonları ile performans iyileşmesi sağlamaktır. Bu nedenle analizler en karmaşık görev olan 15 sınıflı veri kümesi üzerinde yapılmıştır.



Şekil 4.16. Kayıp fonksiyonlarının farklı modeller için doğruluk değerleri.

Tablo 4.11 ve Şekil 4.16 incelendiğinde önerilen fonksiyonun, tüm modellerde KÇE ve KH fonksiyonlarına göre özellikle genel doğruluk ve AUC gibi kritik metriklerde belirgin iyileşmeler sağladığı görülmektedir. Model 1’de KÇE ve KH ile elde edilen genel doğruluk değerleri sırasıyla %67,694 ve %67,266 iken, önerilen fonksiyonla yaklaşık %5’lik iyileşme sağlanarak bu değer %72,813’e yükselmiştir. Benzer şekilde Model 3’te KÇE ile elde edilen %66,127 genel doğruluk oranı önerilen fonksiyon ile %72,740’a yükselmiştir. Model 4, 5 ve 6’da iyileşme oranı daha sınırlı olsa da genel doğrulukta yaklaşık %1’lik bir performans artışı görülmüştür. Model 7’de ise %69,038 değerindeki genel doğruluk önerilen fonksiyonla %72,898’e çıkmıştır. Bununla birlikte özellikle Model 4 ve 6’da elde edilen genel doğruluk artışı sınırlı olsa da duyarlılık ve F1-skoru gibi sınıf dengesine duyarlı metriklerde önerilen fonksiyon daha üstün sonuçlar sunmuştur. Ayrıca AUC değerleri incelendiğinde, önerilen fonksiyonun her modelde hem KÇE hem de KH’ye kıyasla daha yüksek skorlar ürettiği görülmektedir. Bu durum modelin yalnızca doğru sınıflandırma yapmadığını, aynı zamanda pozitif ve negatif örnekleri daha etkili bir şekilde ayırdığını göstermektedir.

Bunların yanında tüm modeller arasında, 15 sınıflı görev için en yüksek başarıyı gösteren modelin Model 2 olduğu görülmüştür. Bu bulgu, önceki analizlerde daha düşük sınıf sayılarında yapılan değerlendirmelerde Model 2’nin en başarılı model olarak belirlenmesinin yerinde bir karar olduğunu göstermektedir.


Elde edilen tüm sonuçlar, ceza terimi içeren kayıp fonksiyonlarının doğruluk oranlarına göre topluluk yöntemiyle bileştirilmesinin modelden bağımsız olarak güçlü ve kararlı bir performans sunduğunu, farklı mimarilerle de etkili bir şekilde çalıştığını ortaya koymaktadır. Böylelikle bu fonksiyonun, derin öğrenmeye dayalı çok sınıflı tıbbi görüntü sınıflandırma problemlerinde yüksek başarı potansiyeline sahip olduğu sonucuna varılmıştır.

Tablo 4.11. Model bazında kayıp fonksiyonu performans karşılaştırması.

Model	Kayıp Fonksiyonu	Genel		Sınıf Bazında Ortalama				
		Doğruluk (%)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Model 1	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	72,813	96,375	66,150	63,928	98,037	63,882	0,958
	KÇE	67,694	95,692	66,456	55,990	97,647	56,887	0,946
	KH	67,266	95,635	61,358	54,877	97,646	55,381	0,916
Model 2	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	74,345	96,579	66,968	66,286	98,164	66,393	0,956
	KÇE	71,366	96,182	64,599	63,624	97,961	63,643	0,944
	KH	71,854	96,246	62,706	62,146	97,981	61,579	0,928
Model 3	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	72,470	96,329	66,377	62,309	98,005	63,229	0,957
	KÇE	66,127	95,481	62,511	57,903	97,562	59,158	0,935
	KH	65,057	95,340	56,752	52,855	97,499	51,856	0,917
Model 4	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	71,537	96,204	64,418	62,198	97,951	61,368	0,955
	KÇE	71,529	96,203	65,574	60,501	97,936	61,131	0,954
	KH	64,287	95,237	52,937	52,944	97,441	51,643	0,899
Model 5	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	72,890	96,385	67,778	61,472	98,028	62,589	0,957
	KÇE	72,188	96,291	64,873	63,878	98,004	63,395	0,955
	KH	71,443	96,192	62,325	61,432	97,948	60,864	0,930
Model 6	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	71,948	96,259	65,576	62,889	97,983	63,098	0,953
	KÇE	71,349	96,179	65,168	61,475	97,928	62,502	0,954
	KH	70,818	96,109	60,913	60,847	97,909	59,852	0,929
Model 7	Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi (b=2, b=3, b=5)	72,898	96,386	65,988	64,262	98,061	64,200	0,955
	KÇE	69,038	95,871	62,394	59,610	97,759	58,789	0,953
	KH	70,895	96,119	61,916	61,141	97,917	60,949	0,926

4.3. Model Kararının Görselleştirilmesi

Önerilen çalışmada modelin karar verme sürecini daha anlaşılır hale getirmek ve hangi görüntü bölgelerinin sınıflandırma üzerinde etkili olduğunu görselleştirmek amacıyla Grad-CAM algoritması uygulanmıştır. Bu doğrultuda Şekil 4.17’de, “Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu- Ceza terimi ($b=2$, $b=3$, $b=5$)” fonksiyonu ile eğitilmiş Model 2’nin 4 farklı sınıf için verdiği kararların Grad-CAM örnekleri verilmiştir. Burada Grad-CAM görselleri jet renk haritası (jet color scheme) kullanılarak oluşturulmuştur. Bu renk haritasında mavi tonlar sınıflandırma için düşük öneme sahip bölgeleri, sarı ve yeşil tonlar orta derecede katkı sağlayan bölgeleri, kırmızı ve koyu kırmızı alanlar ise hedef sınıf için yüksek öneme sahip kritik bölgeleri temsil etmektedir [176]. Bu sayede, her bir sınıfın karakteristik öz niteliklerinin yoğunlaştığı alanlar açıkça görselleştirilmiş ve modelin karar mekanizması şeffaf bir şekilde ortaya konmuştur.



Şekil 4.17. Dört sınıf için Grad-CAM örnekleri.

5. TARTIŞMA

Akciğer grafileri, invaziv olmamaları, düşük doz iyonlaştırıcı radyasyon kullanmaları, düşük maliyetli ve kolay uygulanabilir olmaları nedeniyle akciğer hastalıklarının taranması ve teşhisi için en yaygın kullanılan görüntüleme yöntemlerden biridir [15], [16]. Ancak, uzman radyolog sayısının yetersizliği ve hastanelerde günlük olarak çekilen yüzlerce grafiden kaynaklanan yüksek görüntü hacmi, akciğer grafilerinin yorumlanmasında günlük yaklaşık %3-5 oranında gerçek zamanlı hata yapılmasına yol açmaktadır [21]. Bu durum, akciğer grafilerinin yorumlanmasında bilgisayar destekli tanı sistemlerine olan ihtiyacı giderek artırmaktadır [17].

Bu tez çalışmasında, atelektazi, COVID-19, kardiyomegali, konsolidasyon, ödem, pulmoner fibröz, kosta kırığı, infiltrasyon, akciğer opasitesi, kitle, plevral efüzyon, pnömoni, pnömotoraks ve TB gibi çeşitli akciğer patolojilerinin ve sağlıklı grafilerin sınıflandırılması amacıyla dikkat mekanizması tabanlı ve transfer öğrenmesine dayalı uçtan uca bir derin öğrenme modeli önerilmiştir. Önerilen model, herhangi bir ön işleme veya manuel öznitelik çıkarma işlemine ihtiyaç duymadan tamamen otomatik bir şekilde çalışmaktadır. Ayrıca, çalışmada çok sınıflı sınıflandırma problemlerinde karşılaşılan sınıf dengesizliği ve görüntüler arasındaki semantik benzerlik problemlerine çözüm getirmek amacıyla çeşitli kayıp fonksiyonları test edilmiş ve literatürde yaygın kullanılan yöntemlere kıyasla anlamlı performans artışı sağlayan özgün bir kayıp fonksiyonu geliştirilmiştir. Önerilen doğruluğa göre ağırlıklandırılmış ve ceza terimi içeren topluluk kaybı hem modelden hem de sınıf sayısından bağımsız olarak yüksek performans göstermiştir.

Yedi farklı model mimarisi ve artan sınıf sayısına sahip (7, 8, 9, 10, 12, 14 ve 15 sınıflı) veri kümeleri ile yapılan analizler sonucunda, önerilen modelin genelleme yeteneğinin yüksek olduğu ve çok sınıflı görevlerde kararlı performans sergilediği kanıtlanmıştır. Tablo 5.1’de literatürdeki benzer veri kümeleriyle yapılan çalışmaların performanslar değerleri ile bu tezde önerilen modelin elde ettiği sonuçlar karşılaştırmalı olarak sunulmuştur. Bu çalışmalarda kullanılan görüntü sayıları, veri kaynakları ve veri kümesi bölünme stratejileri (eğitim-test) farklı olduğundan birebir karşılaştırma yapmak mümkün değildir. Bununla birlikte, tabloda gösterildiği gibi, önerilen yöntem özellikle doğruluk ve AUC gibi metrikler açısından aynı sayıda sınıfa sahip veri kümelerini kullanan diğer yaklaşımlara kıyasla üstün performans sergilemiştir.

Apostolopoulos et al. [40], 7 sınıf için yaptıkları çalışmada, yalnızca 2564 akciğer grafisi kullanılarak %87,66 doğruluk elde etmiştir. 7 sınıf için yapılan başka bir çalışmada Sultana et al. [63], 18564 akciğer grafisi kullanılarak %93,15 doğruluk elde etmiştir. Buna karşılık, bu çalışmada önerilen yöntem 29271 görüntü üzerinde %95,097 doğruluk, %92,834 kesinlik, %92,473 duyarlılık ve 0,995 AUC elde etmiştir. Bu sonuçlar, önerilen yöntemin hem veri kümesi boyutu hem de sınıflandırma performansı açısından üstünlüğünü göstermektedir.

Albahli et al. [42], 8 sınıflı ve 35319 görüntü içeren veri kümesiyle yaptıkları sınıflandırma çalışmasında %81,5 oranında doğruluk elde etmiştir. Önerilen yöntemde ise 38875 görüntü için %90,834 genel doğruluk ve 0,989 AUC elde edilmiş ve dolayısıyla bu çalışmaya göre üstün sonuçlara ulaşılmıştır.

9 sınıf için önerilen yöntem %86,089 doğruluk, 83,185 F1-skoru ve 0,979 AUC ile Mezina ve Burget [92] tarafından bildirilen %73,21 doğruluk, %42,6 F1-skoru ve 0,8119 AUC sonuçlarına kıyasla daha başarılı olmuştur.

10 sınıflı sınıflandırma görevinde, Malik et al. [61], %98,2 doğruluk elde etmiştir. Önerilen yöntemde ise 47662 akciğer grafisi için %84,274 doğruluk ve 0,979 AUC sunulmuştur. Her ne kadar Malik et al. tarafından elde edilen performans değeri üstün görünse de yaptıkları çalışmada, veri artırma yöntemleriyle bazı sınıfların örnek sayısı 10 kata kadar artırılmıştır. Bu da aynı görüntülerin eğitim, doğrulama ve test kümelerinde tekrar kullanılması olasılığını önemli ölçüde artırmaktadır. Bu durum, modelin aşırı uyum (overfitting) eğilimini artırabileceği gibi elde edilen başarımın bilimsel geçerliliğini de zayıflatmaktadır. Buna karşılık, bu tez çalışmasında önerilen yöntemde eğitim ve validasyon kümesinde kullanılan görüntüler test kümesinde yer almadığı için daha güvenilir bir performans elde edildiği açıktır.

14 sınıflı sınıflandırma görevinde, önerilen yöntem %76,841 doğruluk, %68,121 F1-skoru ve 0,961 AUC değeri ile Ge et al. [97] tarafından elde edilen 0,7628 AUC değerine kıyasla daha başarılı sonuçlar vermiştir.

Son olarak, 15 sınıf için, önerilen yöntem artan sınıflandırma karmaşıklığına rağmen dengeli performansını sürdürerek %74,345 doğruluk, %66,393 F1-skoru ve 0,956 AUC elde etmiştir. Literatürde 15 sınıflı sınıflandırma yapan çalışma bulunmadığından, doğrudan karşılaştırma yapmak mümkün olmasa da elde edilen sonuçlar önerilen yöntemin oldukça karmaşık senaryolarda bile sağlam bir performans gösterdiğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, yapılan kapsamlı analizler ve literatür karşılaştırmaları önerilen yöntemin yalnızca yüksek sınıflandırma performansı sağlamakla

kalmayıp aynı zamanda yüksek genelleme yeteneğine de sahip olduğunu göstermektedir. Sınıf sayısı ve veri kümesi boyutu arttıkça bile tutarlı ve dengeli performans sağlaması, önerilen model ve kayıp fonksiyonunun gerçek dünya klinik uygulamaları için umut vadeden bir aday olduğunu göstermektedir.

Tablo 5.1. Literatürdeki çalışmalar ile tezde elde edilen sonuçların karşılaştırılması.

Çalışma	Sınıf Sayısı (Akciğer Grafisi Sayısı)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1- Skoru (%)	AUC
2020. Apostolopoulos et al. [40]	7 (2564)	87.66					
2020. Ge et al. [97]	14 (~30964)						0.7628
2020. Albahli et al. [42]	8 (35319)	81.5					
2023. Malik et al. [61]	10 (41719 artırılarak 181719)	98.20		97.98	97.99		
2023. Sultana et al. [63]	7 (18564)	93.15	93.43	94.43		93.86	
2024. Mezina and Burget [92]	9 (58792)	73.21	32.19	76.785	72.21	42.6	0.8119
Önerilen Yöntem	7 (29271)	95,097	92,834	92,473	99,139	92,644	0,995
	8 (38875)	90,834	89,492	89,155	98,686	89,315	0,989
	9 (45364)	86,089	83,495	82,915	98,243	83,185	0,979
	10 (47662)	84,274	81,742	79,599	98,225	80,452	0,979
	12 (52345)	79,404	73,489	71,672	98,104	72,217	0,967
	14 (55559)	76,841	69,416	67,760	98,117	68,121	0,961
	15 (58418)	74,345	66,968	66,286	98,164	66,393	0,956

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, akciğer hastalığı tespitinin zorluklarının üstesinden gelmek için ümit verici sonuçlar veren dikkat mekanizması tabanlı, transfer öğrenmesine dayalı, uçtan uca çalışan bir derin öğrenme modeli geliştirilmiştir. Önerilen modelde omurga ağı olarak DenseNet201 mimarisi kullanılmıştır. Bu yapıya entegre edilen ConvLSTM katmanı ile öznetelik haritalarındaki uzamsal bağımlılıklar kodlanmış, SE bloğu sayesinde önemli özneteliklerin vurgulanarak önemsiz olanların bastırılması sağlanmıştır. Dönüştürücü kodlayıcı bloğu ise öznetelikler arasındaki uzun menzilli ilişkileri modelleyerek daha anlamlı ve zengin temsiller elde edilmesini sağlamıştır. Bu bileşenlerin bir araya gelmesiyle, yüksek sınıflandırma performansı sağlayan hibrit bir derin öğrenme modeli elde edilmiştir. Ayrıca çalışmada, çok sınıflı sınıflandırma problemlerinde sıklıkla karşılaşılan sınıf dengesizliği ve semantik benzerlik sorunlarına çözüm getirmek amacıyla çeşitli kayıp fonksiyonları değerlendirilmiş ve literatürde yaygın kullanılan yöntemlere kıyasla performans iyileşmesi sağlayan, doğruluğa göre ağırlıklandırılmış ve ceza terimi içeren yeni bir topluluk kayıp fonksiyonu önerilmiştir. Bu fonksiyon, farklı model mimarileri ve farklı sınıf sayısına sahip veri kümeleri (7, 8, 9, 10, 12, 14 ve 15 sınıflı) ile test edilmiş ve fonksiyonun modelden ve veri kümesinden bağımsız olarak tutarlı ve yüksek performans sağladığı gösterilmiştir.

Özellikle yüksek sınıflı (14 ve 15 sınıflı) veri kümelerinde elde edilen sonuçlar, önerilen modelin sınıflandırma karmaşıklığı arttığında bile dengeli ve güvenilir performans sunduğunu göstermektedir. Ayrıca test verileri tamamen eğitim ve validasyon verilerinden bağımsız olarak kullanıldığından, modelin genellenebilirliği objektif olarak değerlendirilmiştir. Dolayısıyla önerilen yöntem, bir bilgisayar destekli tanı sistemine entegre edilmeye uygun olup, klinik ortamlarda radyologlara ikinci bir karar verici olarak destek sağlayabilecek potansiyele sahiptir.

Bu doğrultuda, önerilen yöntemin sunduğu başarıyı daha da geliştirmek ve benzer araştırmalara katkı sunmak amacıyla, gelecekteki çalışmalara yönelik bazı öneriler sunulmaktadır. Derin öğrenme modellerinin başarısı, büyük ölçüde kullanılan veri kümelerine bağlıdır. Bu nedenle, çok sayıda patoloji içeren, sınıf dengesizliğinin en az olduğu ve doğru etiketlenmiş açık erişimli veri kümelerinin artırılması bu bağlamda büyük önem taşımaktadır. Uluslararası iş birlikleriyle oluşturulacak bu tür veri tabanları, model genelleme yeteneğini artıracaktır. Özellikle çoklu patolojilere sahip, semantik açıdan benzer sınıfları barındıran ve yaş, cinsiyet, sigara kullanımı gibi klinik verileri de içeren veri

kümelerinin oluşturulması ve açık erişimli hale getirilmesi, daha güçlü modellerin geliştirilmesine olanak sağlayacaktır. Buna ek olarak, gelecekteki çalışmalarda farklı görüntüleme modalitelerinin (BT, Manyetik Rezonans Görüntüleme) de entegre edilmesi ve klinik verilerle desteklenen yapıların kurulması, tanı süreçlerinde daha kapsamlı ve etkili karar destek sistemlerinin oluşturulmasına katkı sağlayacaktır. Bu doğrultuda, önerilen modelin hastalık evrelemesi, prognoz tahmini veya tedaviye yanıtın izlenmesi gibi ileri düzey klinik görevlerde de test edilmesi, sistemin sağlık hizmetlerinde daha büyük bir rol üstlenmesine imkan tanıyacaktır.

Sonuç olarak, bu tez kapsamında geliştirilen yöntem hem model hem de kayıp fonksiyonu açısından özgün katkılar sunmakta ve literatürdeki mevcut çalışmalara kıyasla çeşitli metriklerde üstün performans göstermektedir. Elde edilen bulgular, önerilen yaklaşımın çok sınıflı tıbbi görüntü sınıflandırması alanında bilgisayar destekli tanı sistemlerinin geliştirilmesine önemli katkı sağlayacağını ortaya koymaktadır.

KAYNAKLAR

- [1] S. Zainab Yousuf Zaidi, M. Usman Akram, A. Jameel, and N. S. Alghamdi, “Lung Segmentation-Based Pulmonary Disease Classification Using Deep Neural Networks,” *IEEE Access*, vol. 9, pp. 125202–125214, 2021, doi: 10.1109/ACCESS.2021.3110904.
- [2] World Health Organization, “WHO Coronavirus (COVID-19) Dashboard.” <https://covid19.who.int/>.
- [3] World Health Organization, *Global Tuberculosis Report*, no. September. 2024.
- [4] B. Oltu, S. Guney, B. Dengiz, and M. Agildere, “Automated Tuberculosis Detection Using Pre-Trained CNN and SVM,” 2021, doi: 10.1109/TSP52935.2021.9522644.
- [5] H. Malik, T. Anees, M. Din, and A. Naeem, “CDC_Net: multi-classification convolutional neural network model for detection of COVID-19, pneumothorax, pneumonia, lung Cancer, and tuberculosis using chest X-rays,” *Multimed. Tools Appl.*, Apr. 2022, doi: 10.1007/s11042-022-13843-7.
- [6] B. Annamalai, P. Saravanan, and I. Varadharajan, “ABOA-CNN: auction-based optimization algorithm with convolutional neural network for pulmonary disease prediction,” *Neural Comput. Appl.*, Apr. 2023, doi: 10.1007/s00521-022-08033-3.
- [7] Y. Chen, X. Hou, Y. Yang, Q. Ge, Y. Zhou, and S. Nie, “A Novel Deep Learning Model Based on Multi-Scale and Multi-View for Detection of Pulmonary Nodules,” *J. Digit. Imaging*, vol. 36, no. 2, pp. 688–699, 2023, doi: 10.1007/s10278-022-00749-x.
- [8] X. Yu *et al.*, “Performance of Lung Ultrasound in Detecting Peri-Operative Atelectasis after General Anesthesia,” *Ultrasound Med. Biol.*, vol. 42, no. 12, pp. 2775–2784, Dec. 2016, doi: 10.1016/j.ultrasmedbio.2016.06.010.
- [9] C. Upasana, A. S. Tewari, and J. P. Singh, “An Attention-based Pneumothorax

- Classification using Modified Xception Model,” *Procedia Comput. Sci.*, vol. 218, pp. 74–82, 2023, doi: 10.1016/j.procs.2022.12.403.
- [10] L. Chen, T. Mao, and Q. Zhang, “Identifying cardiomegaly in chest x-rays using dual attention network,” *Appl. Intell.*, vol. 52, no. 10, pp. 11058–11067, Aug. 2022, doi: 10.1007/s10489-021-02935-w.
 - [11] A. AbuKaraki *et al.*, “Pulmonary Edema and Pleural Effusion Detection Using EfficientNet-V1-B4 Architecture and AdamW Optimizer from Chest X-Rays Images,” *Comput. Mater. Contin.*, vol. 80, no. 1, pp. 1055–1073, 2024, doi: 10.32604/cmc.2024.051420.
 - [12] L. May, C. Hillermann, and S. Patil, “Rib fracture management,” *BJA Educ.*, vol. 16, no. 1, pp. 26–32, Jan. 2016, doi: 10.1093/bjaceaccp/mkv011.
 - [13] A. Iqbal, M. Usman, and Z. Ahmed, “Tuberculosis chest X-ray detection using CNN-based hybrid segmentation and classification approach,” *Biomed. Signal Process. Control*, vol. 84, no. July 2022, p. 104667, 2023, doi: 10.1016/j.bspc.2023.104667.
 - [14] S.-L. Yi, S.-L. Qin, F.-R. She, and T.-W. Wang, “RED-CNN: The Multi-Classification Network for Pulmonary Diseases,” *Electronics*, vol. 11, no. 18, p. 2896, Sep. 2022, doi: 10.3390/electronics11182896.
 - [15] J. Xu, H. Li, and X. Li, “MS-ANet: deep Learning for Automated Multi-label Thoracic Disease Detection and Classification,” *PeerJ Comput. Sci.*, vol. 7, pp. 1–12, 2021, doi: 10.7717/PEERJ-CS.541.
 - [16] U. Hasanah, J. Shiou, L. Cries, and A. Ihsanul, *A systematic review of multilabel chest X - ray classification using deep learning*, no. 0123456789. Springer US, 2024.
 - [17] Y. Li, K. Zhang, W. Shi, and Z. Jiang, “A Novel Method for COVID-19 Detection Based on DCNNs and Hierarchical Structure,” *Comput. Math. Methods Med.*, vol. 2022, 2022, doi: 10.1155/2022/2484435.

- [18] Y. Chen, Y. Wan, and F. Pan, “Enhancing Multi-disease Diagnosis of Chest X-rays with Advanced Deep-learning Networks in Real-world Data,” *J. Digit. Imaging*, vol. 36, no. 4, pp. 1332–1347, Aug. 2023, doi: 10.1007/s10278-023-00801-4.
- [19] X. Ouyang *et al.*, “Learning Hierarchical Attention for Weakly-Supervised Chest X-Ray Abnormality Localization and Diagnosis,” *IEEE Trans. Med. Imaging*, vol. 40, no. 10, pp. 2698–2710, Oct. 2021, doi: 10.1109/TMI.2020.3042773.
- [20] R. Arora, I. Saini, and N. Sood, “Multi-label segmentation and detection of COVID-19 abnormalities from chest radiographs using deep learning,” *Optik (Stuttg.)*, vol. 246, Nov. 2021, doi: 10.1016/j.ijleo.2021.167780.
- [21] A. Brady, R. Ó. Laoide, P. McCarthy, and R. McDermott, “Discrepancy and error in radiology: concepts, causes and consequences,” *Ulster Med. J.*, vol. 81, no. 1, pp. 3–9, Jan. 2012.
- [22] T. Kaya, *Radyoloji Pratiğinde Yanılgı Nedenleri ve Bunlardan Kaçınma Yolları*. Türk Radyoloji Derneği, 2015.
- [23] K. Wang, X. Zhang, S. Huang, F. Chen, X. Zhang, and L. Huangfu, “Learning to Recognize Thoracic Disease in Chest X-Rays with Knowledge-Guided Deep Zoom Neural Networks,” *IEEE Access*, vol. 8, pp. 159790–159805, 2020, doi: 10.1109/ACCESS.2020.3020579.
- [24] J. Fang, Y. Xu, Y. Zhao, Y. Yan, J. Liu, and J. Liu, “Weighing features of lung and heart regions for thoracic disease classification,” *BMC Med. Imaging*, vol. 21, no. 1, Dec. 2021, doi: 10.1186/s12880-021-00627-y.
- [25] A. Gopatoti and P. Vijayalakshmi, “Optimized chest X-ray image semantic segmentation networks for COVID-19 early detection,” *J. Xray. Sci. Technol.*, vol. 30, no. 3, pp. 491–512, 2022, doi: 10.3233/XST-211113.
- [26] T. Iqbal, A. Shaukat, M. U. Akram, Z. Mustansar, and A. Khan, “Automatic Diagnosis of Pneumothorax from Chest Radiographs: A Systematic Literature

- Review,” *IEEE Access*, vol. 9. Institute of Electrical and Electronics Engineers Inc., pp. 145817–145839, 2021, doi: 10.1109/ACCESS.2021.3122998.
- [27] F. Li *et al.*, “Lesion-aware convolutional neural network for chest radiograph classification,” *Clin. Radiol.*, vol. 76, no. 2, pp. 155.e1-155.e14, Feb. 2021, doi: 10.1016/j.crad.2020.08.027.
 - [28] W. Shi, L. Tong, Y. Zhu, and M. D. Wang, “COVID-19 Automatic Diagnosis with Radiographic Imaging: Explainable Attention Transfer Deep Neural Networks,” *IEEE J. Biomed. Heal. Informatics*, vol. 25, no. 7, pp. 2376–2387, Jul. 2021, doi: 10.1109/JBHI.2021.3074893.
 - [29] E. Sogancioglu *et al.*, *Deep learning for chest X-ray analysis: A survey*, vol. 72. Elsevier B.V., 2021, p. 102125.
 - [30] V. Acharya *et al.*, “AI-Assisted Tuberculosis Detection and Classification from Chest X-Rays Using a Deep Learning Normalization-Free Network Model,” *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/2399428.
 - [31] S. Jaeger *et al.*, “Automatic Tuberculosis Screening Using Chest Radiographs,” *IEEE Trans. Med. Imaging*, vol. 33, no. 2, pp. 233–245, Feb. 2014, doi: 10.1109/TMI.2013.2284099.
 - [32] X. Xu, Q. Guo, J. Guo, and Z. Yi, “DeepCXray: Automatically diagnosing diseases on chest x-rays using deep neural networks,” *IEEE Access*, vol. 6, pp. 66972–66982, 2018, doi: 10.1109/ACCESS.2018.2875406.
 - [33] R. Guo, K. Passi, and C. K. Jain, “Tuberculosis Diagnostics and Localization in Chest X-Rays via Deep Learning Models,” *Front. Artif. Intell.*, vol. 3, no. October, pp. 1–17, 2020, doi: 10.3389/frai.2020.583427.
 - [34] M. Ayaz, F. Shaukat, and G. Raja, “Ensemble learning based automatic detection of tuberculosis in chest X-ray images using hybrid feature descriptors,” *Phys. Eng. Sci. Med.*, vol. 44, no. 1, pp. 183–194, 2021, doi: 10.1007/s13246-020-00966-0.

- [35] S. Dey, R. Roychoudhury, S. Malakar, and R. Sarkar, “An optimized fuzzy ensemble of convolutional neural networks for detecting tuberculosis from Chest X-ray images,” *Appl. Soft Comput.*, vol. 114, p. 108094, 2022, doi: 10.1016/j.asoc.2021.108094.
- [36] E. Kesim, Z. Dokur, and T. Olmez, “X-Ray Chest Image Classification by A Small-Sized Convolutional Neural Network,” in *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*, Apr. 2019, pp. 1–5, doi: 10.1109/EBBT.2019.8742050.
- [37] A. Chaudhary, A. Hazra, and P. Chaudhary, “Diagnosis of Chest Diseases in X-Ray images using Deep Convolutional Neural Network,” in *2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, Jul. 2019, pp. 1–6, doi: 10.1109/ICCCNT45670.2019.8944762.
- [38] Y. Oh, S. Park, and J. C. Ye, “Deep Learning COVID-19 Features on CXR Using Limited Training Data Sets,” *IEEE Trans. Med. Imaging*, vol. 39, no. 8, pp. 2688–2700, Aug. 2020, doi: 10.1109/TMI.2020.2993291.
- [39] T. Mahmud, M. A. Rahman, and S. A. Fattah, “CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization,” *Comput. Biol. Med.*, vol. 122, Jul. 2020, doi: 10.1016/j.compbimed.2020.103869.
- [40] I. D. Apostolopoulos, S. I. Aznaouridis, and M. A. Tzani, “Extracting Possibly Representative COVID-19 Biomarkers from X-ray Images with Deep Learning Approach and Image Data Related to Pulmonary Diseases,” *J. Med. Biol. Eng.*, vol. 40, no. 3, pp. 462–469, Jun. 2020, doi: 10.1007/s40846-020-00529-4.
- [41] M. M. A. Monshi, J. Poon, V. Chung, and F. M. Monshi, “CovidXrayNet: Optimizing data augmentation and CNN hyperparameters for improved COVID-19 detection from CXR,” *Comput. Biol. Med.*, vol. 133, Jun. 2021, doi: 10.1016/j.compbimed.2021.104375.

- [42] S. Albahli, “A Deep Neural Network to Distinguish COVID-19 from other Chest Diseases Using X-ray Images,” *Curr. Med. imaging*, vol. 17, no. 1, pp. 109–119, Mar. 2021, doi: 10.2174/1573405616666200604163954.
- [43] S. Bekhet, M. H. Alkinani, R. Tabares-Soto, and M. Hassaballah, “An efficient method for covid-19 detection using light weight convolutional neural network,” *Comput. Mater. Contin.*, vol. 69, no. 2, pp. 2475–2491, 2021, doi: 10.32604/cmc.2021.018514.
- [44] M. Chakraborty, S. V. Dhavale, and J. Ingole, “Corona-Nidaan: lightweight deep convolutional neural network for chest X-Ray based COVID-19 infection detection,” *Appl. Intell.*, vol. 51, no. 5, pp. 3026–3043, May 2021, doi: 10.1007/s10489-020-01978-9.
- [45] S. Hamida, O. El Gannour, B. Cherradi, A. Raihani, H. Moujahid, and H. Ouajji, “A novel covid-19 diagnosis support system using the stacking approach and transfer learning technique on chest X-ray images,” *J. Healthc. Eng.*, vol. 2021, 2021, doi: 10.1155/2021/9437538.
- [46] M. Mamalakis *et al.*, “DenResCov-19: A deep transfer learning network for robust automatic classification of COVID-19, pneumonia, and tuberculosis from X-rays,” *Comput. Med. Imaging Graph.*, vol. 94, no. September, p. 102008, Dec. 2021, doi: 10.1016/j.compmedimag.2021.102008.
- [47] Y. Xu, H. K. Lam, and G. Jia, “MANet: A two-stage deep learning method for classification of COVID-19 from Chest X-ray images,” *Neurocomputing*, vol. 443, pp. 96–105, Jul. 2021, doi: 10.1016/j.neucom.2021.03.034.
- [48] N. Kumar, M. Gupta, D. Gupta, and S. Tiwari, “Novel deep transfer learning model for COVID-19 patient detection using X-ray chest images,” *J. Ambient Intell. Humaniz. Comput.*, vol. 14, no. 1, pp. 469–478, Jan. 2021, doi: 10.1007/s12652-021-03306-6.
- [49] M. Hong, B. Rim, H. Lee, H. Jang, J. Oh, and S. Choi, “Multi-Class Classification of

- Lung Diseases Using CNN Models,” *Appl. Sci.*, vol. 11, no. 19, p. 9289, Oct. 2021, doi: 10.3390/app11199289.
- [50] L. Hassanlou, S. Meshgini, R. Afrouzian, A. Farzamnia, and E. G. Mounq, “FirecovNet: A Novel, Lightweight, and Fast Deep Learning-Based Network for Detecting COVID-19 Patients Using Chest X-rays,” *Electron.*, vol. 11, no. 19, Oct. 2022, doi: 10.3390/electronics11193068.
- [51] M. L. Huang and Y. C. Liao, “A lightweight CNN-based network on COVID-19 detection using X-ray and CT images,” *Comput. Biol. Med.*, vol. 146, Jul. 2022, doi: 10.1016/j.combiomed.2022.105604.
- [52] S. Kumar *et al.*, “LiteCovidNet: A lightweight deep neural network model for detection of COVID-19 using X-ray images,” *Int. J. Imaging Syst. Technol.*, vol. 32, no. 5, pp. 1464–1480, Sep. 2022, doi: 10.1002/ima.22770.
- [53] S. Kim, B. Rim, S. Choi, A. Lee, S. Min, and M. Hong, “Deep Learning in Multi-Class Lung Diseases’ Classification on Chest X-ray Images,” *Diagnostics*, vol. 12, no. 4, Apr. 2022, doi: 10.3390/diagnostics12040915.
- [54] M. T. Naseem, T. Hussain, C. S. Lee, and M. A. Khan, “Classification and Detection of COVID-19 and Other Chest-Related Diseases Using Transfer Learning,” *Sensors*, vol. 22, no. 20, Oct. 2022, doi: 10.3390/s22207977.
- [55] A. Sharma and P. K. Mishra, “Covid-MANet: Multi-task attention network for explainable diagnosis and severity assessment of COVID-19 from CXR images,” *Pattern Recognit.*, vol. 131, Nov. 2022, doi: 10.1016/j.patcog.2022.108826.
- [56] M. Bhandari, T. B. Shahi, B. Siku, and A. Neupane, “Explanatory classification of CXR images into COVID-19, Pneumonia and Tuberculosis using deep learning and XAI,” *Comput. Biol. Med.*, vol. 150, no. June, p. 106156, 2022, doi: 10.1016/j.combiomed.2022.106156.
- [57] M. S. Ahmed *et al.*, “Joint Diagnosis of Pneumonia, COVID-19, and Tuberculosis

- from Chest X-ray Images: A Deep Learning Approach,” *Diagnostics*, vol. 13, no. 15, 2023, doi: 10.3390/diagnostics13152562.
- [58] H. M. Emara *et al.*, “Simultaneous Super-Resolution and Classification of Lung Disease Scans,” *Diagnostics*, vol. 13, no. 7, pp. 1–28, 2023, doi: 10.3390/diagnostics13071319.
- [59] V. Indumathi and R. Siva, “An efficient lung disease classification from X-ray images using hybrid Mask-RCNN and BiDLSTM,” *Biomed. Signal Process. Control*, vol. 81, Mar. 2023, doi: 10.1016/j.bspc.2022.104340.
- [60] M. R. Islam Bhuiyan *et al.*, “Deep learning-based analysis of COVID-19 X-ray images: Incorporating clinical significance and assessing misinterpretation,” *Digit. Heal.*, vol. 9, 2023, doi: 10.1177/20552076231215915.
- [61] H. Malik *et al.*, “A Novel Fusion Model of Hand-Crafted Features With Deep Convolutional Neural Networks for Classification of Several Chest Diseases Using X-Ray Images,” *IEEE Access*, vol. 11, no. March, pp. 39243–39268, 2023, doi: 10.1109/ACCESS.2023.3267492.
- [62] J. Oh *et al.*, “OView-AI Supporter for Classifying Pneumonia, Pneumothorax, Tuberculosis, Lung Cancer Chest X-ray Images Using Multi-Stage Superpixels Classification,” *Diagnostics*, vol. 13, no. 9, pp. 1–16, 2023, doi: 10.3390/diagnostics13091519.
- [63] A. Sultana *et al.*, “A Real Time Method for Distinguishing COVID-19 Utilizing 2D-CNN and Transfer Learning,” *Sensors*, vol. 23, no. 9, 2023, doi: 10.3390/s23094458.
- [64] D. Soydaner, “Attention mechanism in neural networks: where it comes and where it goes,” *Neural Computing and Applications*, vol. 34, no. 16. Springer Science and Business Media Deutschland GmbH, pp. 13371–13385, Aug. 01, 2022, doi: 10.1007/s00521-022-07366-3.
- [65] A. Afifi, N. E. Hafsa, M. A. S. Ali, A. Alhumam, and S. Alsalman, “An ensemble of

- global and local-attention based convolutional neural networks for COVID-19 diagnosis on chest X-ray images,” *Symmetry (Basel)*., vol. 13, no. 1, pp. 1–25, Jan. 2021, doi: 10.3390/sym13010113.
- [66] S. Woo, J. Park, J.-Y. Lee, and I. S. Kweon, “CBAM: Convolutional Block Attention Module,” Jul. 2018, [Online]. Available: <http://arxiv.org/abs/1807.06521>.
- [67] Y. Fan, J. Liu, R. Yao, and X. Yuan, “COVID-19 Detection from X-ray Images using Multi-Kernel-Size Spatial-Channel Attention Network,” *Pattern Recognit.*, vol. 119, Nov. 2021, doi: 10.1016/j.patcog.2021.108055.
- [68] J. Li *et al.*, “Multiscale Attention Guided Network for COVID-19 Diagnosis Using Chest X-Ray Images,” *IEEE J. Biomed. Heal. Informatics*, vol. 25, no. 5, pp. 1336–1346, May 2021, doi: 10.1109/JBHI.2021.3058293.
- [69] Z. Lin *et al.*, “AANet: Adaptive Attention Network for COVID-19 Detection from Chest X-Ray Images,” *IEEE Trans. Neural Networks Learn. Syst.*, vol. 32, no. 11, pp. 4781–4792, Nov. 2021, doi: 10.1109/TNNLS.2021.3114747.
- [70] L. T. Duong, N. H. Le, T. B. Tran, V. M. Ngo, and P. T. Nguyen, “Detection of tuberculosis from chest X-ray images: Boosting the performance with vision transformer and transfer learning,” *Expert Syst. Appl.*, vol. 184, no. January, p. 115519, Dec. 2021, doi: 10.1016/j.eswa.2021.115519.
- [71] D. Shome *et al.*, “Covid-transformer: Interpretable covid-19 detection using vision transformer for healthcare,” *Int. J. Environ. Res. Public Health*, vol. 18, no. 21, Nov. 2021, doi: 10.3390/ijerph182111086.
- [72] L. Kong and J. Cheng, “Classification and detection of COVID-19 X-Ray images based on DenseNet and VGG16 feature fusion,” *Biomed. Signal Process. Control*, vol. 77, Aug. 2022, doi: 10.1016/j.bspc.2022.103772.
- [73] J. Liu, W. Sun, X. Zhao, J. Zhao, and Z. Jiang, “Deep feature fusion classification network (DFFCNet): Towards accurate diagnosis of COVID-19 using chest X-rays

- images,” *Biomed. Signal Process. Control*, vol. 76, Jul. 2022, doi: 10.1016/j.bspc.2022.103677.
- [74] M. Chetoui and M. A. Akhloufi, “Explainable Vision Transformers and Radiomics for COVID-19 Detection in Chest X-rays,” *J. Clin. Med.*, vol. 11, no. 11, Jun. 2022, doi: 10.3390/jcm11113013.
- [75] G. I. Okolo, S. Katsigiannis, and N. Ramzan, “IEViT: An enhanced vision transformer architecture for chest X-ray image classification,” *Comput. Methods Programs Biomed.*, vol. 226, Nov. 2022, doi: 10.1016/j.cmpb.2022.107141.
- [76] M. Usman, T. Zia, and A. Tariq, “Analyzing Transfer Learning of Vision Transformers for Interpreting Chest Radiography,” *J. Digit. Imaging*, vol. 35, no. 6, pp. 1445–1462, Dec. 2022, doi: 10.1007/s10278-022-00666-z.
- [77] F. Li *et al.*, “Modeling long-range dependencies for weakly supervised disease classification and localization on chest X-ray,” *Quant. Imaging Med. Surg.*, vol. 12, no. 6, pp. 3364–3378, Jun. 2022, doi: 10.21037/qims-21-1117.
- [78] A. Mabrouk, R. P. D. Redondo, A. Dahou, M. A. Elaziz, and M. Kayed, “Pneumonia Detection on Chest X-ray Images Using Ensemble of Deep Convolutional Neural Networks,” *Appl. Sci.*, vol. 12, no. 13, Jul. 2022, doi: 10.3390/app12136448.
- [79] S. Cannata, A. Paviglianiti, E. Pasero, G. Cirrincione, and M. Cirrincione, “Deep Learning Algorithms for Automatic COVID-19 Detection on Chest X-Ray Images,” *IEEE Access*, vol. 10, pp. 119905–119913, 2022, doi: 10.1109/ACCESS.2022.3221531.
- [80] K. Cao, T. Deng, C. Zhang, L. Lu, and L. Li, “A CNN-transformer fusion network for COVID-19 CXR image classification,” *PLoS One*, vol. 17, no. 10 October, Oct. 2022, doi: 10.1371/journal.pone.0276758.
- [81] S. Park *et al.*, “Multi-task vision transformer using low-level chest X-ray feature corpus for COVID-19 diagnosis and severity quantification,” *Med. Image Anal.*, vol.

75, 2022, doi: 10.1016/j.media.2021.102299.

- [82] C. C. Ukwuoma *et al.*, “Automated Lung-Related Pneumonia and COVID-19 Detection Based on Novel Feature Extraction Framework and Vision Transformer Approaches Using Chest X-ray Images,” *Bioengineering*, vol. 9, no. 11, Nov. 2022, doi: 10.3390/bioengineering9110709.
- [83] A. K. Mondal, A. Bhattacharjee, P. Singla, and A. P. Prathosh, “XViTCOS: Explainable Vision Transformer Based COVID-19 Screening Using Radiography,” *IEEE J. Transl. Eng. Heal. Med.*, vol. 10, 2022, doi: 10.1109/JTEHM.2021.3134096.
- [84] S. Rajaraman, G. Zamzmi, L. R. Folio, and S. Antani, “Detecting Tuberculosis-Consistent Findings in Lateral Chest X-Rays Using an Ensemble of CNNs and Vision Transformers,” *Front. Genet.*, vol. 13, Feb. 2022, doi: 10.3389/fgene.2022.864724.
- [85] T. Le Dinh, S. H. Lee, S. G. Kwon, and K. R. Kwon, “COVID-19 Chest X-ray Classification and Severity Assessment Using Convolutional and Transformer Neural Networks,” *Appl. Sci.*, vol. 12, no. 10, May 2022, doi: 10.3390/app12104861.
- [86] S. I. Nafisah, G. Muhammad, M. S. Hossain, and S. A. AlQahtani, “A Comparative Evaluation between Convolutional Neural Networks and Vision Transformers for COVID-19 Detection,” *Mathematics*, vol. 11, no. 6, Mar. 2023, doi: 10.3390/math11061489.
- [87] H. Yang, L. Wang, Y. Xu, and X. Liu, “CovidViT: a novel neural network with self-attention mechanism to detect Covid-19 through X-ray images,” *Int. J. Mach. Learn. Cybern.*, vol. 14, no. 3, pp. 973–987, Mar. 2023, doi: 10.1007/s13042-022-01676-7.
- [88] H. Chen, T. Zhang, R. Chen, Z. Zhu, and X. Wang, “A Novel COVID-19 Image Classification Method Based on the Improved Residual Network,” *Electron.*, vol. 12, no. 1, Jan. 2023, doi: 10.3390/electronics12010080.
- [89] Y. E. Almalki *et al.*, “A Novel-based Swin Transfer Based Diagnosis of COVID-19 Patients,” *Intell. Autom. Soft Comput.*, vol. 35, no. 1, pp. 163–180, 2023, doi:

10.32604/iasc.2023.025580.

- [90] A. Marefat, M. Marefat, J. Hassannataj Joloudari, M. A. Nematollahi, and R. Lashgari, "CCTCOVID: COVID-19 detection from chest X-ray images using Compact Convolutional Transformers," *Front. Public Heal.*, vol. 11, Feb. 2023, doi: 10.3389/fpubh.2023.1025746.
- [91] T. Wang *et al.*, "PneuNet: deep learning for COVID-19 pneumonia diagnosis on chest X-ray image analysis using Vision Transformer," *Med. Biol. Eng. Comput.*, 2023, doi: 10.1007/s11517-022-02746-2.
- [92] A. Mezina and R. Burget, "Detection of post-COVID-19-related pulmonary diseases in X-ray images using Vision Transformer-based neural network," *Biomed. Signal Process. Control*, vol. 87, no. PA, p. 105380, 2024, doi: 10.1016/j.bspc.2023.105380.
- [93] A. Dhere and J. Sivaswamy, "COVID Detection from Chest X-Ray Images Using Multi-Scale Attention," *IEEE J. Biomed. Heal. Informatics*, vol. 26, no. 4, pp. 1496–1505, Apr. 2022, doi: 10.1109/JBHI.2022.3151171.
- [94] R. Qin, K. Qiao, L. Wang, L. Zeng, J. Chen, and B. Yan, "Weighted Focal Loss: An Effective Loss Function to Overcome Unbalance Problem of Chest X-ray14," in *IOP Conference Series: Materials Science and Engineering*, Oct. 2018, vol. 428, no. 1, doi: 10.1088/1757-899X/428/1/012022.
- [95] B. Chen, J. Li, X. Guo, and G. Lu, "DualCheXNet: dual asymmetric feature learning for thoracic disease classification in chest X-rays," *Biomed. Signal Process. Control*, vol. 53, Aug. 2019, doi: 10.1016/j.bspc.2019.04.031.
- [96] S. Xu, H. Wu, and R. Bie, "CXNet-m1: Anomaly Detection on Chest X-Rays with Image-Based Deep Learning," *IEEE Access*, vol. 7, pp. 4466–4477, 2019, doi: 10.1109/ACCESS.2018.2885997.
- [97] Z. Ge, D. Mahapatra, X. Chang, Z. Chen, L. Chi, and H. Lu, "Improving multi-label chest X-ray disease diagnosis by exploiting disease and health labels dependencies,"

- Multimed. Tools Appl.*, vol. 79, no. 21–22, pp. 14889–14902, Jun. 2020, doi: 10.1007/s11042-019-08260-2.
- [98] S. Rajaraman, G. Zamzmi, and S. K. Antani, “Novel loss functions for ensemble-based medical image classification,” *PLoS One*, vol. 16, no. 12 December, Dec. 2021, doi: 10.1371/journal.pone.0261307.
 - [99] M. M. Taresh, N. Zhu, T. A. A. Ali, M. Alghaili, A. S. Hameed, and M. L. Mutar, “KL-MOB: automated COVID-19 recognition using a novel approach based on image enhancement and a modified MobileNet CNN,” *PeerJ Comput. Sci.*, vol. 7, pp. 1–23, 2021, doi: 10.7717/PEERJ-CS.694.
 - [100] Z. Qiao, A. Bae, L. M. Glass, C. Xiao, and J. Sun, “FLANNEL (Focal Loss bAsed Neural Network EnsembLe) for COVID-19 detection,” *J. Am. Med. Informatics Assoc.*, vol. 28, no. 3, pp. 444–452, Mar. 2021, doi: 10.1093/jamia/ocaa280.
 - [101] P. Bhowal, S. Sen, J. H. Yoon, Z. W. Geem, and R. Sarkar, “Choquet Integral and Coalition Game-Based Ensemble of Deep Learning Models for COVID-19 Screening from Chest X-Ray Images,” *IEEE J. Biomed. Heal. Informatics*, vol. 25, no. 12, pp. 4328–4339, Dec. 2021, doi: 10.1109/JBHI.2021.3111415.
 - [102] S. Roy, M. Tyagi, V. Bansal, and V. Jain, “SVD-CLAHE boosting and balanced loss function for Covid-19 detection from an imbalanced Chest X-Ray dataset,” *Comput. Biol. Med.*, vol. 150, Nov. 2022, doi: 10.1016/j.compbiomed.2022.106092.
 - [103] T. Katona, G. Tóth, M. Petró, and B. Harangi, “Advanced Multi-Label Image Classification Techniques Using Ensemble Methods,” *Mach. Learn. Knowl. Extr.*, vol. 6, no. 2, pp. 1281–1297, 2024, doi: 10.3390/make6020060.
 - [104] Z. Tang and Y. Yang, “CheXDouble: Dual-Supervised interpretable disease diagnosis model,” *Biomed. Signal Process. Control*, vol. 100, no. PB, p. 107026, 2025, doi: 10.1016/j.bspc.2024.107026.
 - [105] J. E. Hall and M. E. H. Hall, *Guyton and Hall Textbook of Medical Physiology*, 14th

ed. Philadelphia: Elsevier, 2021.

- [106] G. J. Tortora, *Principles of anatomy and physiology*, 1st ed. New York: John Willy & Sons, 2016.
- [107] J. B. West and A. M. Luks, *West's respiratory physiology: the essentials*, 10th ed. Philadelphia: Wolters Kluwer, 2012.
- [108] T. Agrawal and P. Choudhary, "Segmentation and classification on chest radiography: a systematic survey," *Vis. Comput.*, 2022, doi: 10.1007/s00371-021-02352-7.
- [109] F. Munawar, S. Azmat, T. Iqbal, C. Gronlund, and H. Ali, "Segmentation of Lungs in Chest X-Ray Image Using Generative Adversarial Networks," *IEEE Access*, vol. 8, pp. 153535–153545, 2020, doi: 10.1109/ACCESS.2020.3017915.
- [110] A. Zotin, Y. Hamad, K. Simonov, and M. Kurako, "Lung boundary detection for chest X-ray images classification based on GLCM and probabilistic neural networks," in *Procedia Computer Science*, 2019, vol. 159, pp. 1439–1448, doi: 10.1016/j.procs.2019.09.314.
- [111] W. Li, X. Deng, H. Shao, and X. Wang, "Deep learning applications for COVID-19 analysis: A state-of-the-art survey," *CMES - Computer Modeling in Engineering and Sciences*, vol. 129, no. 1. Tech Science Press, pp. 65–98, 2021, doi: 10.32604/cmes.2021.016981.
- [112] M. A. Al-Antari, C.-H. Hua, J. Bang, and S. Lee, "Fast deep learning computer-aided diagnosis of COVID-19 based on digital chest x-ray images," 2021, doi: 10.1007/s10489-020-02076-6/Published.
- [113] M. Ahmad, U. I. Bajwa, Y. Mehmood, and M. W. Anwar, "Lightweight ResGRU: a deep learning-based prediction of SARS-CoV-2 (COVID-19) and its severity classification using multimodal chest radiography images," *Neural Comput. Appl.*, 2023, doi: 10.1007/s00521-023-08200-0.

- [114] S. Minaee, R. Kafieh, M. Sonka, S. Yazdani, and G. Jamalipour Soufi, “Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning,” *Med. Image Anal.*, vol. 65, Oct. 2020, doi: 10.1016/j.media.2020.101794.
- [115] Y. Brima, M. Atemkeng, S. T. Djioke, J. Ebiele, and F. Tchakounté, “Transfer learning for the detection and diagnosis of types of pneumonia including pneumonia induced by COVID-19 from chest X-ray images,” *Diagnostics*, vol. 11, no. 8, 2021, doi: 10.3390/diagnostics11081480.
- [116] S. S. COMERT, “Radiological findings of COVID-19 pneumonia,” *South. Clin. Istanbul Eurasia*, vol. 31, pp. 16–22, 2020, doi: 10.14744/scie.2020.96158.
- [117] S. Metintaş, “COVID-19’un Epidemiyolojisi,” *Coronavirus Hast. 2019 ve Akciğer Göğüs Hast. Uzm. Bilmesi Gerekenler*, pp. 4–15, 2020.
- [118] U. K. Lopes and J. F. Valiati, “Pre-trained convolutional neural networks as feature extractors for tuberculosis detection,” *Comput. Biol. Med.*, vol. 89, no. February, pp. 135–143, 2017, doi: 10.1016/j.combiomed.2017.08.001.
- [119] Z. Ul Abideen *et al.*, “Uncertainty assisted robust tuberculosis identification with bayesian convolutional neural networks,” *IEEE Access*, vol. 8, pp. 22812–22825, 2020, doi: 10.1109/ACCESS.2020.2970023.
- [120] T. K. K. Ho, J. Gwak, O. Prakash, J. I. Song, and C. M. Park, “Utilizing Pretrained Deep Learning Models for Automated Pulmonary Tuberculosis Detection Using Chest Radiography,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2019, vol. 11432 LNAI, pp. 395–403, doi: 10.1007/978-3-030-14802-7_34.
- [121] M. Pai *et al.*, “Tuberculosis,” *Nat. Rev. Dis. Prim.*, 2016, doi: 10.1038/nrdp.2016.76.
- [122] Z. Kılıçaslan, “Tüberküloz,” in *Temel Akciğer Sağlığı ve Hastalıkları Ders Kitabı*, 2nd ed., O. Arseven, Ed. İstanbul: Nobel Tıp Kitabevleri, 2015, pp. 187–197.

- [123] A. Sayner, “Pnömoniler,” in *Temel Akciğer Sağlığı ve Hastalıkları Ders Kitabı*, 2nd ed., O. Arseven, Ed. İstanbul: Nobel Tıp Kitabevleri, 2015, pp. 173–184.
- [124] A. Mittal *et al.*, “Detecting pneumonia using convolutions and dynamic capsule routing for chest X-ray images,” *Sensors (Switzerland)*, vol. 20, no. 4, Feb. 2020, doi: 10.3390/s20041068.
- [125] E. Kıyan, “Pnömotoraks,” in *Temel Akciğer Sağlığı ve Hastalıkları Ders Kitabı*, 2nd ed., O. Arseven, Ed. İstanbul: Nobel Tıp Kitabevleri, 2015, pp. 291–296.
- [126] G. Altınışık, “Pnömotraks,” in *Göğüs Hastalıkları*, L. Dalar, M. Süerdem, C. Öztürk, and A. Saygı, Eds. İstanbul: İstanbul Tıp Kitabevi, 2015, pp. 547–556.
- [127] K. H. Carlsen, S. Crowley, and B. Smevik, “Atelectasis,” in *Kendig’s Disorders of the Respiratory Tract in Children (Ninth Edition)*, Ninth Edit., R. W. Wilmott, R. Deterding, A. Li, F. Ratjen, P. Sly, H. J. Zar, and A. Bush, Eds. Philadelphia: Elsevier, 2019, pp. 1027-1033.e1.
- [128] L. Hsu, D. Green, J. Chusid, A. Talwar, and R. Shah, “Imaging of Atelectasis,” *Contemp. Diagnostic Radiol.*, vol. 36, no. 25, pp. 1–7, 2013, doi: 10.1097/01.cdr.0000438281.94975.2d.
- [129] S. S. Alghamdi, I. Abdelaziz, M. Albadri, S. Alyanbaawi, R. Aljondi, and A. Tajaldeen, “Study of cardiomegaly using chest x-ray,” *J. Radiat. Res. Appl. Sci.*, vol. 13, no. 1, pp. 460–467, 2020, doi: 10.1080/16878507.2020.1756187.
- [130] G. Çelik, “Akciğer Ödemi,” in *Temel Akciğer Sağlığı ve Hastalıkları Ders Kitabı*, 2nd ed., O. Arseven, Ed. İstanbul: Nobel Tıp Kitabevleri, 2015, pp. 255–259.
- [131] Z. Ahmad, R. Krishnadas, and P. Froeschle, “Pleural effusion: Diagnosis and management,” *J. Perioper. Pract.*, vol. 19, no. 8, pp. 242–247, 2009, doi: 10.1177/175045890901900802.
- [132] J. M. Porcel and R. W. Light, “Diagnostic approach to pleural effusion in adults,” *Am.*

Fam. Physician, vol. 73, no. 7, pp. 1211–1220, 2006.

- [133] M. Arıyürek, “Akciğer Grafisi ve Diğer Görüntüleme Yöntemleri,” in *Temel Akciğer Sağlığı ve Hastalıkları Ders Kitabı*, 2nd ed., O. Arseven, Ed. İstanbul: Nobel Tıp Kitabevleri, 2015, pp. 65–84.
- [134] C. de Margerie-Mellon and G. Chassagnon, “Artificial intelligence: A critical review of applications for lung nodule and lung cancer,” *Diagnostic and Interventional Imaging*, vol. 104, no. 1. Elsevier Masson s.r.l., pp. 11–17, Jan. 01, 2023, doi: 10.1016/j.diii.2022.11.007.
- [135] Ö. Özdemir Kumbasar, “İnterstisyel Akciger Hastalıkları,” in *Temel Akciğer Sağlığı ve Hastalıkları Ders Kitabı*, 3rd ed., O. Arseven, Ed. İstanbul: Nobel Tıp Kitabevleri, 2020, pp. 255–262.
- [136] D. M. Hansell, A. A. Bankier, H. MacMahon, T. C. McLoud, N. L. Müller, and J. Remy, “Fleischner Society: Glossary of terms for thoracic imaging,” *Radiology*, vol. 246, no. 3, pp. 697–722, 2008, doi: 10.1148/radiol.2462070712.
- [137] L. Zhang, C. J. McMahon, S. Shah, J. S. Wu, R. L. Eisenberg, and J. W. Kung, “Clinical and Radiologic Predictive Factors of Rib Fractures in Outpatients With Chest Pain,” *Curr. Probl. Diagn. Radiol.*, vol. 47, no. 2, pp. 94–97, 2018, doi: 10.1067/j.cpradiol.2017.05.011.
- [138] G. Zhao, S. Shao, and M. Yu, “Key techniques for classification of thorax diseases based on deep learning,” *Int. J. Imaging Syst. Technol.*, vol. 32, no. 6, pp. 2184–2197, Nov. 2022, doi: 10.1002/ima.22773.
- [139] S. Bhalla, *Diseases of the Chest Wall and Diaphragm*. 2019.
- [140] M. N. Islam *et al.*, “Interpretable Differential Diagnosis of Non-COVID Viral Pneumonia, Lung Opacity and COVID-19 Using Tuned Transfer Learning and Explainable AI,” *Healthc.*, vol. 11, no. 3, Feb. 2023, doi: 10.3390/healthcare11030410.

- [141] H. I. Hussein, A. O. Mohammed, M. M. Hassan, and R. J. Mstafa, "Lightweight deep CNN-based models for early detection of COVID-19 patients from chest X-ray images," *Expert Syst. Appl.*, vol. 223, p. 119900, Aug. 2023, doi: 10.1016/j.eswa.2023.119900.
- [142] B. Oltu, S. Güney, S. E. Yuksel, and B. Dengiz, "Automated classification of chest X-rays: a deep learning approach with attention mechanisms," *BMC Med. Imaging*, vol. 25, no. 1, p. 71, Mar. 2025, doi: 10.1186/s12880-025-01604-5.
- [143] S. R. Nayak, J. Nayak, U. Sinha, V. Arora, U. Ghosh, and S. C. Satapathy, "An Automated Lightweight Deep Neural Network for Diagnosis of COVID-19 from Chest X-ray Images," *Arab. J. Sci. Eng.*, vol. 48, no. 8, pp. 11085–11102, Aug. 2023, doi: 10.1007/s13369-021-05956-2.
- [144] A. S. Pillai, "Multi-Label Chest X-Ray Classification via Deep Learning," *J. Intell. Learn. Syst. Appl.*, vol. 14, no. 04, pp. 43–56, 2022, doi: 10.4236/jilsa.2022.144004.
- [145] R. Hooda, A. Mittal, and S. Sofat, "Automated TB classification using ensemble of deep architectures," *Multimed. Tools Appl.*, vol. 78, no. 22, pp. 31515–31532, 2019, doi: 10.1007/s11042-019-07984-5.
- [146] I. Kandel and M. Castelli, "Transfer Learning with Convolutional Neural Networks for Diabetic Retinopathy Image Classification. A Review," *Appl. Sci.*, vol. 10, no. 6, p. 2021, Mar. 2020, doi: 10.3390/app10062021.
- [147] I. A. L. Alablani and M. J. F. Alenazi, "COVID-ConvNet: A Convolutional Neural Network Classifier for Diagnosing COVID-19 Infection," *Diagnostics*, vol. 13, no. 10, May 2023, doi: 10.3390/diagnostics13101675.
- [148] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," Aug. 2016, [Online]. Available: <http://arxiv.org/abs/1608.06993>.
- [149] C. P. Lee and K. M. Lim, "COVID-19 Diagnosis on Chest Radiographs with

- Enhanced Deep Neural Networks,” *Diagnostics*, vol. 12, no. 8, Aug. 2022, doi: 10.3390/diagnostics12081828.
- [150] J. Hu, L. Shen, S. Albanie, G. Sun, and E. Wu, “Squeeze-and-Excitation Networks,” Sep. 2017, [Online]. Available: <http://arxiv.org/abs/1709.01507>.
- [151] S. Dey, R. Bhattacharya, S. Malakar, F. Schwenker, and R. Sarkar, “CovidConvLSTM: A fuzzy ensemble model for COVID-19 detection from chest X-rays,” *Expert Syst. Appl.*, vol. 206, p. 117812, Nov. 2022, doi: 10.1016/j.eswa.2022.117812.
- [152] A. Vaswani *et al.*, “Attention Is All You Need,” 2017.
- [153] A. Dosovitskiy *et al.*, “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” Oct. 2020, [Online]. Available: <http://arxiv.org/abs/2010.11929>.
- [154] X. Shi, Z. Chen, H. Wang, D.-Y. Y. Yeung, W. K. Wong, and W. C. Woo, “Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting,” *Adv. Neural Inf. Process. Syst.*, vol. 2015-Janua, pp. 802–810, Jun. 2015, [Online]. Available: <http://arxiv.org/abs/1506.04214>.
- [155] Y. Tian, D. Su, S. Lauria, and X. Liu, “Recent advances on loss functions in deep learning for computer vision,” *Neurocomputing*, vol. 497, Elsevier B.V., pp. 129–158, Aug. 01, 2022, doi: 10.1016/j.neucom.2022.04.127.
- [156] J. Terven, D. M. Cordova-Esparza, A. Ramirez-Pedraza, E. A. Chavez-Urbiola, and J. A. Romero-Gonzalez, “Loss Functions and Metrics in Deep Learning,” 2023, [Online]. Available: <http://arxiv.org/abs/2307.02694>.
- [157] Q. Wang, Y. Ma, K. Zhao, and Y. Tian, “A Comprehensive Survey of Loss Functions in Machine Learning,” *Ann. Data Sci.*, vol. 9, no. 2, pp. 187–212, Apr. 2022, doi: 10.1007/s40745-020-00253-5.

- [158] B. Oltu, M. F. Akşahin, and S. Kibaroglu, “A novel electroencephalography based approach for Alzheimer’s disease and mild cognitive impairment detection,” *Biomed. Signal Process. Control*, vol. 63, 2021, doi: 10.1016/j.bspc.2020.102223.
- [159] B. Wang and W. Zhang, “MARnet: Multi-scale adaptive residual neural network for chest X-ray images recognition of lung diseases,” *Math. Biosci. Eng.*, vol. 19, no. 1, pp. 331–350, 2022, doi: 10.3934/mbe.2022017.
- [160] P. Choudhary and A. Hazra, “Chest disease radiography in twofold: using convolutional neural networks and transfer learning,” *Evol. Syst.*, vol. 12, no. 2, pp. 567–579, Jun. 2021, doi: 10.1007/s12530-019-09316-2.
- [161] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, and R. M. Summers, “ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases,” in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, Nov. 2017, vol. 2017-January, pp. 3462–3471, doi: 10.1109/CVPR.2017.369.
- [162] J. Irvin *et al.*, “CheXpert: A Large Chest Radiograph Dataset with Uncertainty Labels and Expert Comparison,” 2019. [Online]. Available: www.aaii.org.
- [163] M. E. H. Chowdhury *et al.*, “Can AI Help in Screening Viral and COVID-19 Pneumonia?,” *IEEE Access*, vol. 8, pp. 132665–132676, 2020, doi: 10.1109/ACCESS.2020.3010287.
- [164] T. Rahman *et al.*, “Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images,” *Comput. Biol. Med.*, vol. 132, no. November, p. 104319, May 2021, doi: 10.1016/j.compbiomed.2021.104319.
- [165] T. Rahman *et al.*, “Reliable tuberculosis detection using chest X-ray with deep learning, segmentation and visualization,” *IEEE Access*, vol. 8, pp. 191586–191601, 2020, doi: 10.1109/ACCESS.2020.3031384.
- [166] N. I. of H. (NIH), “Tuberculosis (TB) data science for public health impact.”

<https://tbportals.niaid.nih.gov/download-data>.

- [167] P. Mooney, “Chest X-Ray Images (Pneumonia).”
<https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia/data>.
- [168] DONJON00, “Covid19 Detection.”
<https://www.kaggle.com/datasets/donjon00/covid19-detection>.
- [169] Japanese Society of Radiological Technology, “JSRT Database.”
<http://db.jsrt.or.jp/eng.php>.
- [170] C. C. Ukwuoma *et al.*, “LCSB-inception: Reliable and effective light-chroma separated branches for Covid-19 detection from chest X-ray images,” *Comput. Biol. Med.*, vol. 150, Nov. 2022, doi: 10.1016/j.compbiomed.2022.106195.
- [171] U. Chutia, A. Shanker, T. Jyoti, P. Singh, and V. Kumar, “Classification of Lung Diseases Using an Attention - Based Modified DenseNet Model,” no. 0123456789, 2024, doi: 10.1007/s10278-024-01005-0.
- [172] M. Kaya and Y. Çetin-Kaya, “A novel ensemble learning framework based on a genetic algorithm for the classification of pneumonia,” *Eng. Appl. Artif. Intell.*, vol. 133, no. PE, p. 108494, 2024, doi: 10.1016/j.engappai.2024.108494.
- [173] K. Y. Win, N. Maneerat, S. Sreng, and K. Hamamoto, “Ensemble deep learning for the detection of COVID-19 in unbalanced chest X-ray dataset,” *Appl. Sci.*, vol. 11, no. 22, Nov. 2021, doi: 10.3390/app112210528.
- [174] M. Riaz, M. Bashir, and I. Younas, “Metaheuristics based COVID-19 detection using medical images: A review,” *Computers in Biology and Medicine*, vol. 144. Elsevier Ltd, May 01, 2022, doi: 10.1016/j.compbiomed.2022.105344.
- [175] P. Qiu, *The Statistical Evaluation of Medical Tests for Classification and Prediction*, vol. 100, no. 470. 2005.

- [176] M. Umair *et al.*, “Detection of COVID-19 using transfer learning and grad-cam visualization on indigenously collected X-ray dataset,” *Sensors*, vol. 21, no. 17, Sep. 2021, doi: 10.3390/s21175813.

EKLER

EK 1: Dört Sınıf için Model Test Sonuçları

Tablo 1. Dört Sınıf için Model 1 Test Sonuçları- Genel Doğruluk: %99,681

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,734	99,721	98,893	99,934	99,306	0,9995
Normal	99,734	99,657	99,853	99,593	99,755	0,9996
TB	99,973	100,000	99,857	100,000	99,929	1,0000
Viral pnömoni	99,920	99,007	100,000	99,913	99,501	1,0000
Ortalama	99,840	99,596	99,651	99,860	99,622	0,9998

Tablo 2. Dört Sınıf için Model 2 Test Sonuçları- Genel Doğruluk: %99,734

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,761	99,583	99,170	99,901	99,376	0,9999
Normal	99,787	99,755	99,853	99,710	99,804	0,9999
TB	99,973	100,000	99,857	100,000	99,929	1,0000
Viral pnömoni	99,947	99,336	100,000	99,942	99,667	1,0000
Ortalama	99,867	99,668	99,720	99,888	99,694	1,0000

Tablo 3. Dört Sınıf için Model 3 Test Sonuçları- Genel Doğruluk: %99,734

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,734	99,037	99,585	99,770	99,310	0,9999
Normal	99,761	99,902	99,657	99,884	99,779	1,0000
TB	99,973	99,857	100,000	99,967	99,929	1,0000
Viral pnömoni	100,000	100,000	100,000	100,000	100,000	1,0000
Ortalama	99,867	99,699	99,810	99,905	99,754	1,0000

Tablo 4. Dört Sınıf için Model 4 Test Sonuçları- Genel Doğruluk: %99,707

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,734	99,721	98,893	99,934	99,306	0,9999
Normal	99,707	99,608	99,853	99,535	99,730	1,0000
TB	100,000	100,000	100,000	100,000	100,000	1,0000
Viral pnömoni	99,973	99,667	100,000	99,971	99,833	1,0000
Ortalama	99,854	99,749	99,687	99,860	99,717	1,0000

Tablo 5. Dört Sınıf için Model 5 Test Sonuçları- Genel Doğruluk %99,734

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,761	100,000	98,755	100,000	99,374	0,9999
Normal	99,761	99,609	99,951	99,535	99,780	0,9999
TB	100,000	100,000	100,000	100,000	100,000	1,0000
Viral pnömoni	99,947	99,336	100,000	99,942	99,667	1,0000
Ortalama	99,867	99,736	99,677	99,869	99,705	1,0000

Tablo 6. Dört Sınıf için Model 6 Test Sonuçları- Genel Doğruluk %99,814

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,840	100,000	99,170	100,000	99,583	0,9998
Normal	99,840	99,706	100,000	99,652	99,853	0,9990
TB	99,973	100,000	99,857	100,000	99,929	1,0000
Viral pnömoni	99,973	99,667	100,000	99,971	99,833	1,0000
Ortalama	99,907	99,843	99,757	99,906	99,799	0,9997

Tablo 7. Dört Sınıf için Model 7 Test Sonuçları- Genel Doğruluk %99,814

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,894	100,000	99,447	100,000	99,723	1,0000
Normal	99,894	99,902	99,902	99,884	99,902	1,0000
TB	99,973	100,000	99,857	100,000	99,929	1,0000
Viral pnömoni	99,867	98,355	100,000	99,856	99,171	1,0000
Ortalama	99,907	99,564	99,801	99,935	99,681	1,0000

EK 2: Beş Sınıf için Model Test Sonuçları

Beş sınıflı sınıflandırma sonuçları-1

Tablo 8. Beş Sınıf-1 için Model 1 Test Sonuçları- Genel Doğruluk: %99,609

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,732	99,582	98,893	99,911	99,237	0,9999
Fibröz	99,902	99,407	99,407	99,947	99,407	1,0000
Normal	99,732	99,608	99,853	99,611	99,730	1,0000
TB	99,927	100,000	99,571	100,000	99,785	1,0000
Viral pnömoni	99,927	99,007	100,000	99,921	99,501	1,0000
Ortalama	99,844	99,521	99,545	99,878	99,532	1,0000

Tablo 9. Beş Sınıf-1 için Model 2 Test Sonuçları- Genel Doğruluk: %99,854

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,854	99,723	99,447	99,941	99,584	0,9999
Fibröz	100,000	100,000	100,000	100,000	100,000	1,0000
Normal	99,854	99,804	99,902	99,806	99,853	1,0000
TB	100,000	100,000	100,000	100,000	100,000	1,0000
Viral pnömoni	100,000	100,000	100,000	100,000	100,000	1,0000
Ortalama	99,941	99,905	99,870	99,949	99,887	1,0000

Tablo 10. Beş Sınıf-1 için Model 3 Test Sonuçları- Genel Doğruluk: %99,634

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,658	99,442	98,617	99,881	99,028	0,9999
Fibröz	100,000	100,000	100,000	100,000	100,000	1,0000
Normal	99,658	99,511	99,804	99,514	99,657	1,0000
TB	99,976	99,857	100,000	99,971	99,929	1,0000
Viral pnömoni	99,976	100,000	99,666	100,000	99,832	1,0000
Ortalama	99,854	99,762	99,617	99,873	99,689	1,0000

Tablo 11. Beş Sınıf-1 için Model 4 Test Sonuçları- Genel Doğruluk: %99,756

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,805	99,722	99,170	99,941	99,445	0,9998
Fibröz	99,951	99,410	100,000	99,947	99,704	1,0000
Normal	99,805	99,706	99,902	99,709	99,804	0,9999
TB	99,976	100,000	99,857	100,000	99,929	1,0000
Viral pnömoni	99,976	100,000	99,666	100,000	99,832	1,0000
Ortalama	99,902	99,768	99,719	99,919	99,743	0,9999

Tablo 12. Beş Sınıf-1 için Model 5 Test Sonuçları- Genel Doğruluk: %98,950

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,268	100,000	95,851	100,000	97,881	0,9999
Fibröz	99,707	96,562	100,000	99,681	98,251	1,0000
Normal	99,146	98,640	99,657	98,640	99,146	0,9994
TB	99,854	100,000	99,143	100,000	99,570	1,0000
Viral pnömoni	99,927	99,007	100,000	99,921	99,501	1,0000
Ortalama	99,580	98,842	98,930	99,648	98,870	0,9999

Tablo 13. Beş Sınıf-1 için Model 6 Test Sonuçları- Genel Doğruluk: %99,732

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,805	99,310	99,585	99,852	99,448	1,0000
Fibröz	99,951	99,410	100,000	99,947	99,704	1,0000
Normal	99,805	99,804	99,804	99,806	99,804	1,0000
TB	99,902	100,000	99,429	100,000	99,713	1,0000
Viral pnömoni	100,000	100,000	100,000	100,000	100,000	1,0000
Ortalama	99,893	99,705	99,763	99,921	99,734	1,0000

Tablo 14. Beş Sınıf-1 için Model 7 Test Sonuçları- Genel Doğruluk: %99,561

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,683	99,581	98,617	99,911	99,097	1,0000
Fibröz	99,854	98,251	100,000	99,840	99,118	1,0000
Normal	99,658	99,559	99,755	99,563	99,657	1,0000
TB	99,927	100,000	99,571	100,000	99,785	1,0000
Viral pnömoni	100,000	100,000	100,000	100,000	100,000	1,0000
Ortalama	99,824	99,478	99,589	99,863	99,531	1,0000

Beş sınıflı sınıflandırma sonuçları-2

Tablo 15. Beş Sınıf-2 için Model 1 Test Sonuçları- Genel Doğruluk: %97,098

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,577	99,717	97,372	99,953	98,530	0,9999
Akciğer Opasitesi	97,441	95,435	93,927	98,564	94,675	0,9905
Normal	97,239	95,851	97,498	97,059	96,667	0,9943
TB	99,960	99,857	99,857	99,977	99,857	1,0000
Viral pnömoni	99,980	99,667	100,000	99,979	99,833	1,0000
Ortalama	98,839	98,105	97,731	99,106	97,913	0,9969

Tablo 16. Beş Sınıf-2 için Model 2 Test Sonuçları- Genel Doğruluk: %97,239

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,678	99,029	98,755	99,835	98,892	0,9999
Akciğer Opasitesi	97,461	95,059	94,426	98,431	94,741	0,9903
Normal	97,420	96,540	97,203	97,572	96,870	0,9945
TB	99,919	100,000	99,429	100,000	99,713	1,0000
Viral pnömoni	100,000	100,000	100,000	100,000	100,000	1,0000
Ortalama	98,896	98,126	97,963	99,168	98,043	0,9969

Tablo 17. Beş Sınıf-2 için Model 3 Test Sonuçları- Genel Doğruluk: %97,118

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,617	99,438	97,925	99,906	98,676	0,9999
Akciğer Opasitesi	97,441	95,667	93,677	98,644	94,662	0,9911
Normal	97,239	95,896	97,448	97,093	96,666	0,9940
TB	100,000	100,000	100,000	100,000	100,000	1,0000
Viral pnömoni	99,940	99,007	100,000	99,936	99,501	1,0000
Ortalama	98,847	98,001	97,810	99,116	97,901	0,9970

Tablo 18. Beş Sınıf-2 için Model 4 Test Sonuçları- Genel Doğruluk: %96,655

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,496	97,162	99,447	99,505	98,291	0,9998
Akciğer Opasitesi	97,017	97,477	90,017	99,255	93,599	0,9929
Normal	96,876	94,515	98,086	96,033	96,268	0,9948
TB	99,940	100,000	99,571	100,000	99,785	1,0000
Viral pnömoni	99,980	99,667	100,000	99,979	99,833	1,0000
Ortalama	98,662	97,764	97,424	98,954	97,555	0,9975

Tablo 19. Beş Sınıf-2 için Model 5 Test Sonuçları- Genel Doğruluk: %97,138

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,617	99,577	97,787	99,929	98,674	0,9999
Akciğer Opasitesi	97,360	94,887	94,176	98,378	94,530	0,9928
Normal	97,340	96,307	97,252	97,401	96,777	0,9952
TB	100,000	100,000	100,000	100,000	100,000	1,0000
Viral pnömoni	99,960	99,336	100,000	99,957	99,667	1,0000
Ortalama	98,855	98,021	97,843	99,133	97,930	0,9976

Tablo 20. Beş Sınıf-2 için Model 6 Test Sonuçları- Genel Doğruluk: %97,138

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,536	99,575	97,234	99,929	98,390	0,9990
Akciğer Opasitesi	97,461	95,134	94,343	98,457	94,737	0,9925
Normal	97,340	96,128	97,448	97,264	96,784	0,9949
TB	99,960	100,000	99,714	100,000	99,857	1,0000
Viral pnömoni	99,980	99,667	100,000	99,979	99,833	1,0000
Ortalama	98,855	98,101	97,748	99,126	97,920	0,9973

Tablo 21. Beş Sınıf-2 için Model 7 Test Sonuçları- Genel Doğruluk: %97,259

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
COVID-19	99,698	99,580	98,340	99,929	98,956	0,9998
Akciğer Opasitesi	97,461	95,671	93,760	98,644	94,706	0,9920
Normal	97,360	96,041	97,596	97,196	96,812	0,9946
TB	100,000	100,000	100,000	100,000	100,000	1,0000
Viral pnömoni	100,000	100,000	100,000	100,000	100,000	1,0000
Ortalama	98,904	98,258	97,939	99,154	98,095	0,9973

Beş sınıflı sınıflandırma sonuçları-3

Tablo 22. Beş Sınıf-3 için Model 1 Test Sonuçları- Genel Doğruluk: %96,129

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,384	85,536	86,462	97,846	85,996	0,9813
COVID-19	99,768	99,583	99,032	99,916	99,307	0,9999
Normal	99,791	99,657	99,902	99,692	99,779	0,9999
TB	99,977	100,000	99,857	100,000	99,929	1,0000
Viral Pnömoni	96,338	74,061	72,575	98,107	73,311	0,9607
Ortalama	98,452	91,767	91,566	99,112	91,664	0,9884

Tablo 23. Beş Sınıf-3 için Model 2 Test Sonuçları- Genel Doğruluk: %95,318

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	95,781	84,962	81,588	97,872	83,241	0,9850
COVID-19	99,490	99,716	97,234	99,944	98,459	1,0000
Normal	99,606	99,269	99,902	99,341	99,584	1,0000
TB	99,977	100,000	99,857	100,000	99,929	1,0000
Viral Pnömoni	95,781	67,890	74,247	97,385	70,927	0,9750
Ortalama	98,127	90,367	90,566	98,908	90,428	0,9920

Tablo 24. Beş Sınıf-3 için Model 3 Test Sonuçları- Genel Doğruluk: %94,715

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	95,851	83,422	84,477	97,527	83,946	0,9845
COVID-19	99,026	99,419	94,744	99,889	97,025	0,9998
Normal	99,073	98,495	99,558	98,638	99,024	0,9996
TB	99,907	99,857	99,571	99,972	99,714	1,0000
Viral Pnömoni	95,573	67,647	69,231	97,534	68,430	0,9602
Ortalama	97,886	89,768	89,516	98,712	89,628	0,9888

Tablo 25. Beş Sınıf-3 için Model 4 Test Sonuçları- Genel Doğruluk: %95,202

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	95,897	82,669	86,101	97,340	84,350	0,9878
COVID-19	99,444	97,551	99,170	99,499	98,354	0,9997
Normal	99,560	99,461	99,607	99,517	99,534	0,9999
TB	99,560	100,000	97,286	100,000	98,624	1,0000
Viral Pnömoni	95,943	72,143	67,559	98,057	69,775	0,9788
Ortalama	98,081	90,365	89,945	98,883	90,128	0,9932

Tablo 26. Beş Sınıf-3 için Model 5 Test Sonuçları- Genel Doğruluk: %95,086

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,036	81,864	88,809	97,101	85,195	0,9888
COVID-19	99,073	99,421	95,021	99,889	97,171	0,9999
Normal	99,119	98,216	99,951	98,374	99,076	1,0000
TB	99,930	100,000	99,571	100,000	99,785	1,0000
Viral Pnömoni	96,013	75,299	63,211	98,456	68,727	0,9782
Ortalama	98,034	90,960	89,312	98,764	89,991	0,9934

Tablo 27. Beş Sınıf-3 için Model 6 Test Sonuçları- Genel Doğruluk: %94,900

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	95,781	79,712	90,072	96,622	84,576	0,9879
COVID-19	99,513	99,160	97,925	99,833	98,539	0,9998
Normal	99,374	99,753	98,921	99,780	99,335	0,9999
TB	99,328	96,022	100,000	99,198	97,971	1,0000
Viral Pnömoni	95,804	76,339	57,191	98,680	65,392	0,9789
Ortalama	97,960	90,197	88,822	98,823	89,162	0,9933

Tablo 28. Beş Sınıf-3 için Model 7 Test Sonuçları- Genel Doğruluk: %94,692

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	95,688	80,976	86,823	96,995	83,798	0,9876
COVID-19	98,957	95,442	98,479	99,053	96,937	0,9995
Normal	99,119	99,407	98,724	99,473	99,065	0,9998
TB	99,791	99,007	99,714	99,806	99,359	1,0000
Viral Pnömoni	95,828	74,286	60,870	98,431	66,912	0,9797
Ortalama	97,877	89,824	88,922	98,752	89,214	0,9933

EK 3: Altı Sınıf için Model Test Sonuçları

Tablo 29. Altı Sınıf için Model 1 Test Sonuçları- Genel Doğruluk: %93,927

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	96,664	83,154	83,755	98,106	83,453	0,9850
COVID-19	99,583	99,435	97,372	99,917	98,393	0,9998
Akciğer Opasitesi	97,553	95,250	93,428	98,702	94,330	0,9909
Normal	97,389	95,705	97,301	97,441	96,496	0,9940
TB	99,964	100,000	99,714	100,000	99,857	1,0000
Viral pnömoni	96,701	69,435	69,900	98,237	69,667	0,9752
Ortalama	97,976	90,497	90,245	98,734	90,366	0,9908

Tablo 30. Altı Sınıf için Model 2 Test Sonuçları- Genel Doğruluk: %94,471

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	97,045	84,119	87,004	98,166	85,537	0,9894
COVID-19	99,674	99,026	98,479	99,854	98,752	0,9999
Akciğer Opasitesi	97,679	95,897	93,344	98,887	94,604	0,9925
Normal	97,534	95,853	97,547	97,527	96,693	0,9948
TB	99,927	100,000	99,429	100,000	99,713	1,0000
Viral pnömoni	97,081	74,296	70,569	98,601	72,384	0,9730
Ortalama	98,157	91,532	91,062	98,839	91,280	0,9916

Tablo 31. Altı Sınıf için Model 3 Test Sonuçları- Genel Doğruluk: %94,380

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	96,610	82,709	83,755	98,045	83,229	0,9898
COVID-19	99,710	99,719	98,064	99,958	98,884	0,9998
Akciğer Opasitesi	98,006	96,429	94,343	99,026	95,374	0,9929
Normal	97,843	96,241	97,988	97,757	97,107	0,9949
TB	100,000	100,000	100,000	100,000	100,000	1,0000
Viral pnömoni	96,592	68,942	67,559	98,256	68,243	0,9808
Ortalama	98,127	90,673	90,285	98,840	90,473	0,9930

Tablo 32. Altı Sınıf için Model 4 Test Sonuçları- Genel Doğruluk: %94,289

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	96,809	84,743	83,213	98,327	83,971	0,9902
COVID-19	99,764	99,581	98,617	99,937	99,097	1,0000
Akciğer Opasitesi	97,643	95,890	93,178	98,887	94,515	0,9933
Normal	97,589	95,815	97,743	97,499	96,769	0,9955
TB	99,964	100,000	99,714	100,000	99,857	1,0000
Viral pnömoni	96,809	69,775	72,575	98,198	71,148	0,9824
Ortalama	98,096	90,967	90,840	98,808	90,893	0,9936

Tablo 33. Altı Sınıf için Model 5 Test Sonuçları- Genel Doğruluk: %93,002

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	96,574	81,304	85,560	97,803	83,377	0,9900
COVID-19	98,767	99,848	90,733	99,979	95,072	0,9998
Akciğer Opasitesi	97,226	92,539	94,925	97,867	93,717	0,9938
Normal	97,027	95,485	96,516	97,326	95,998	0,9951
TB	99,837	98,731	100,000	99,813	99,361	1,0000
Viral pnömoni	96,574	70,073	64,214	98,428	67,016	0,9794
Ortalama	97,667	89,663	88,658	98,536	89,090	0,9930

Tablo 34. Altı Sınıf için Model 6 Test Sonuçları- Genel Doğruluk: %94,017

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	96,646	83,124	83,574	98,106	83,348	0,9883
COVID-19	99,656	99,162	98,202	99,875	98,680	0,9999
Akciğer Opasitesi	97,571	96,194	92,512	98,980	94,317	0,9920
Normal	97,480	95,583	97,694	97,355	96,627	0,9946
TB	99,946	100,000	99,571	100,000	99,785	1,0000
Viral pnömoni	96,737	69,381	71,237	98,198	70,297	0,9745
Ortalama	98,006	90,574	90,465	98,752	90,509	0,9916

Tablo 35. Altı Sınıf için Model 7 Test Sonuçları- Genel Doğruluk: %93,582

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,664	83,154	83,755	98,106	83,453	0,9879
COVID-19	99,293	99,422	95,159	99,917	97,244	0,9997
Akciğer Opasitesi	97,534	93,832	94,925	98,261	94,376	0,9935
Normal	97,335	96,144	96,663	97,729	96,403	0,9948
TB	99,746	100,000	98,000	100,000	98,990	1,0000
Viral pnömoni	96,592	67,619	71,237	98,045	69,381	0,9783
Ortalama	97,861	90,029	89,957	98,676	89,974	0,9924

EK 4: Yedi Sınıf için Model Test Sonuçları

Tablo 36. Yedi Sınıf için Model 1 Test Sonuçları- Genel Doğruluk: %93,918

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,651	82,310	82,310	98,151	82,310	0,9909
COVID-19	99,351	99,139	95,574	99,883	97,324	0,9997
Fibröz	99,983	99,704	100,000	99,982	99,852	1,0000
Akciğer Opasitesi	97,745	95,493	93,428	98,860	94,449	0,9937
Normal	97,540	95,268	97,792	97,405	96,513	0,9960
TB	99,932	100,000	99,429	100,000	99,713	1,0000
Viral pnömoni	96,634	67,000	67,224	98,218	67,112	0,9830
Ortalama	98,262	91,274	90,822	98,928	91,039	0,9948

Tablo 37. Yedi Sınıf için Model 2 Test Sonuçları- Genel Doğruluk: %94,259

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,908	82,662	85,199	98,132	83,911	0,9902
COVID-19	99,624	99,297	97,649	99,903	98,466	0,9998
Fibröz	99,932	100,000	98,813	100,000	99,403	1,0000
Akciğer Opasitesi	97,711	95,486	93,261	98,860	94,360	0,9914
Normal	97,540	95,398	97,645	97,484	96,508	0,9947
TB	99,915	100,000	99,286	100,000	99,642	1,0000
Viral pnömoni	96,890	70,671	66,890	98,506	68,729	0,9814
Ortalama	98,360	91,931	91,249	98,983	91,574	0,9939

Tablo 38. Yedi Sınıf için Model 3 Test Sonuçları- Genel Doğruluk: %93,166

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,805	84,952	80,505	98,509	82,669	0,9912
COVID-19	99,334	99,422	95,159	99,922	97,244	0,9993
Fibröz	99,897	100,000	98,220	100,000	99,102	1,0000
Akciğer Opasitesi	96,993	97,412	87,687	99,398	92,294	0,9929
Normal	96,788	92,587	98,675	95,780	95,534	0,9952
TB	99,692	97,493	100,000	99,651	98,731	1,0000
Viral pnömoni	96,822	66,967	74,582	98,019	70,570	0,9844
Ortalama	98,047	91,262	90,690	98,754	90,878	0,9947

Tablo 39. Yedi Sınıf için Model 4 Test Sonuçları- Genel Doğruluk: %93,969

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,822	85,659	79,783	98,604	82,617	0,9913
COVID-19	99,539	99,714	96,542	99,961	98,103	0,9999
Fibröz	99,692	94,930	100,000	99,674	97,399	1,0000
Akciğer Opasitesi	97,540	95,920	91,930	98,989	93,883	0,9930
Normal	97,625	95,322	97,988	97,431	96,637	0,9960
TB	99,897	99,856	99,286	99,981	99,570	1,0000
Viral pnömoni	96,822	66,667	75,585	97,965	70,846	0,9848
Ortalama	98,277	91,153	91,588	98,944	91,293	0,9950

Tablo 40. Yedi Sınıf için Model 5 Test Sonuçları- Genel Doğruluk: %94,379

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,215	87,380	82,491	98,754	84,865	0,9925
COVID-19	99,436	99,855	95,574	99,981	97,668	0,9999
Fibröz	99,949	99,118	100,000	99,946	99,557	1,0000
Akciğer Opasitesi	97,642	96,667	91,681	99,183	94,108	0,9908
Normal	97,318	94,134	98,430	96,723	96,234	0,9953
TB	99,983	100,000	99,857	100,000	99,929	1,0000
Viral pnömoni	97,215	70,732	77,592	98,272	74,003	0,9852
Ortalama	98,394	92,555	92,232	98,980	92,338	0,9948

Tablo 41. Yedi Sınıf için Model 6 Test Sonuçları- Genel Doğruluk: %93,986

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,078	82,513	87,726	98,056	85,039	0,9921
COVID-19	99,094	94,079	98,893	99,123	96,426	0,9997
Fibröz	99,983	100,000	99,703	100,000	99,851	1,0000
Akciğer Opasitesi	97,676	95,556	93,012	98,882	94,266	0,9940
Normal	97,078	96,008	95,584	97,877	95,795	0,9950
TB	99,949	99,573	100,000	99,942	99,786	1,0000
Viral pnömoni	97,113	74,436	66,221	98,776	70,088	0,9855
Ortalama	98,282	91,738	91,591	98,951	91,608	0,9952

Tablo 42. Yedi Sınıf için Model 7 Test Sonuçları- Genel Doğruluk: %93,781

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,925	79,872	90,253	97,622	84,746	0,9918
COVID-19	99,197	94,125	99,723	99,123	96,844	0,9998
Fibröz	99,846	100,000	97,329	100,000	98,647	1,0000
Akciğer Opasitesi	97,454	94,656	92,845	98,645	93,742	0,9932
Normal	97,283	96,349	95,829	98,060	96,089	0,9951
TB	99,949	99,715	99,857	99,961	99,786	1,0000
Viral pnömoni	96,908	76,106	57,525	99,028	65,524	0,9832
Ortalama	98,223	91,546	90,480	98,920	90,768	0,9947

EK 5: Sekiz Sınıf için Model Test Sonuçları

Tablo 43. Sekiz Sınıf için Model 1 Test Sonuçları- Genel Doğruluk: %91,060

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,433	71,198	95,487	96,518	81,573	0,9926
COVID-19	99,373	99,563	94,606	99,950	97,021	0,9998
Fibröz	97,343	74,766	71,217	98,727	72,948	0,9828
Akciğer Opasitesi	97,612	95,383	91,098	99,036	93,191	0,9943
Normal	97,731	94,948	97,743	97,726	96,325	0,9963
Pnömotoraks	97,075	86,863	90,555	98,018	88,671	0,9922
TB	99,925	100,000	99,286	100,000	99,642	1,0000
Viral pnömoni	96,627	79,200	33,110	99,594	46,698	0,9787
Ortalama	97,765	87,740	84,138	98,696	84,509	0,9921

Tablo 44. Sekiz Sınıf için Model 2 Test Sonuçları- Genel Doğruluk: %92,791

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,627	84,956	86,643	98,617	85,791	0,9906
COVID-19	99,567	99,430	96,542	99,933	97,965	0,9998
Fibröz	97,627	76,023	77,151	98,711	76,583	0,9753
Akciğer Opasitesi	97,896	95,072	93,095	98,945	94,073	0,9914
Normal	97,970	96,526	96,811	98,477	96,668	0,9955
Pnömotoraks	97,284	87,571	91,499	98,121	89,492	0,9816
TB	99,925	100,000	99,286	100,000	99,642	1,0000
Viral pnömoni	97,687	74,828	72,575	98,860	73,684	0,9793
Ortalama	98,198	89,301	89,200	98,958	89,237	0,9892

Tablo 45. Sekiz Sınıf için Model 3 Test Sonuçları- Genel Doğruluk: %92,433

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,373	86,346	81,047	98,845	83,613	0,9917
COVID-19	99,507	98,867	96,542	99,866	97,691	0,9996
Fibröz	97,463	82,745	62,611	99,309	71,284	0,9863
Akciğer Opasitesi	98,060	94,444	94,759	98,781	94,601	0,9930
Normal	97,866	96,062	96,958	98,263	96,508	0,9958
Pnömotoraks	97,403	85,989	94,923	97,762	90,236	0,9951
TB	99,821	100,000	98,286	100,000	99,135	1,0000
Viral pnömoni	97,373	68,468	76,254	98,360	72,152	0,9854
Ortalama	98,108	89,115	87,673	98,898	88,152	0,9934

Tablo 46. Sekiz Sınıf için Model 4 Test Sonuçları- Genel Doğruluk: %92,463

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,478	82,462	88,267	98,308	85,266	0,9925
COVID-19	99,746	99,579	98,064	99,950	98,815	0,9999
Fibröz	97,343	76,589	67,953	98,900	72,013	0,9828
Akciğer Opasitesi	97,925	97,244	91,015	99,436	94,027	0,9929
Normal	97,896	95,059	98,184	97,769	96,597	0,9957
Pnömotoraks	97,134	85,950	92,444	97,813	89,078	0,9926
TB	99,866	100,000	98,714	100,000	99,353	0,9998
Viral pnömoni	97,537	75,379	66,555	98,985	70,693	0,9860
Ortalama	98,116	89,033	87,650	98,895	88,230	0,9928

Tablo 47. Sekiz Sınıf için Model 5 Test Sonuçları- Genel Doğruluk: %92,776

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,537	82,149	89,711	98,243	85,764	0,9930
COVID-19	99,597	100,000	96,266	100,000	98,097	0,9999
Fibröz	97,642	75,499	78,635	98,648	77,035	0,9865
Akciğer Opasitesi	97,836	95,917	91,847	99,145	93,838	0,9944
Normal	97,910	95,019	98,283	97,748	96,623	0,9968
Pnömotoraks	97,567	90,426	90,319	98,616	90,372	0,9915
TB	99,866	100,000	98,714	100,000	99,353	1,0000
Viral pnömoni	97,597	77,381	65,217	99,110	70,780	0,9815
Ortalama	98,194	89,549	88,624	98,939	88,983	0,9930

Tablo 48. Sekiz Sınıf için Model 6 Test Sonuçları- Genel Doğruluk: %91,985

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,254	88,542	76,715	99,105	82,205	0,9934
COVID-19	99,030	99,548	91,425	99,950	95,314	0,9998
Fibröz	97,597	75,882	76,558	98,711	76,219	0,9890
Akciğer Opasitesi	97,731	92,892	94,592	98,418	93,735	0,9943
Normal	97,567	95,181	96,909	97,855	96,037	0,9959
Pnömotoraks	97,552	90,510	90,083	98,633	90,296	0,9948
TB	99,955	99,715	99,857	99,967	99,786	1,0000
Viral pnömoni	97,284	65,684	81,940	98,000	72,917	0,9882
Ortalama	97,996	88,494	88,510	98,830	88,313	0,9944

Tablo 49. Sekiz Sınıf için Model 7 Test Sonuçları- Genel Doğruluk: %91,925

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,985	89,819	71,661	99,268	79,719	0,9934
COVID-19	99,537	97,658	98,064	99,716	97,861	0,9998
Fibröz	97,388	80,224	63,798	99,167	71,074	0,9875
Akciğer Opasitesi	97,940	95,238	93,178	98,981	94,197	0,9951
Normal	97,776	95,872	96,860	98,177	96,363	0,9962
Pnömotoraks	97,299	86,196	93,625	97,830	89,757	0,9948
TB	99,896	99,713	99,286	99,967	99,499	1,0000
Viral pnömoni	97,030	62,136	85,619	97,563	72,011	0,9888
Ortalama	97,981	88,357	87,761	98,834	87,560	0,9945

EK 6: Model 2 ile Yapılan Kayıp Fonksiyonları Test Sonuçları

Tablo 50. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %99,854

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)
COVID-19	99,854	99,723	99,447	99,941	99,584
Fibröz	100,000	100,000	100,000	100,000	100,000
Normal	99,854	99,804	99,902	99,806	99,853
TB	100,000	100,000	100,000	100,000	100,000
Viral pnömoni	100,000	100,000	100,000	100,000	100,000
Ortalama	99,941	99,905	99,870	99,949	99,887

Tablo 51. Kategorik Hinge Test Sonuçları- Genel Doğruluk %99,658

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)
COVID-19	99,683	99,169	99,032	99,822	99,100
Fibröz	99,927	99,118	100,000	99,920	99,557
Normal	99,707	99,754	99,657	99,757	99,705
TB	100,000	100,000	100,000	100,000	100,000
Viral pnömoni	100,000	100,000	100,000	100,000	100,000
Ortalama	99,863	99,608	99,738	99,900	99,673

Tablo 52. Logcosh Test Sonuçları- Genel Doğruluk %97,754

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)
COVID-19	98,682	99,409	93,084	99,881	96,143
Fibröz	98,902	88,220	100,000	98,803	93,741
Normal	98,731	98,629	98,822	98,640	98,725
TB	99,536	99,708	97,571	99,941	98,628
Viral pnömoni	99,658	95,820	99,666	99,658	97,705
Ortalama	99,102	96,357	97,829	99,385	96,989

Tablo 53. Poisson Test Sonuçları- Genel Doğruluk %99,414

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)
COVID-19	99,536	99,438	97,925	99,881	98,676
Fibröz	99,902	98,827	100,000	99,894	99,410
Normal	99,585	99,269	99,902	99,271	99,584
TB	99,854	100,000	99,143	100,000	99,570
Viral pnömoni	99,951	99,666	99,666	99,974	99,666
Ortalama	99,766	99,440	99,327	99,804	99,381

Tablo 54. Karesel Hinge Test Sonuçları- Genel Doğruluk %99,609

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)
COVID-19	99,756	99,721	98,893	99,941	99,306
Fibröz	99,854	98,251	100,000	99,840	99,118
Normal	99,780	99,657	99,902	99,660	99,779
TB	99,854	100,000	99,143	100,000	99,570
Viral pnömoni	99,976	99,667	100,000	99,974	99,833
Ortalama	99,844	99,459	99,588	99,883	99,521

Tablo 55. Kosinüs Benzerliği Test Sonuçları- Genel Doğruluk %99,317

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)
COVID-19	99,609	99,719	98,064	99,941	98,884
Fibröz	99,658	96,011	100,000	99,628	97,965
Normal	99,683	99,414	99,951	99,417	99,682
TB	99,683	100,000	98,143	100,000	99,063
Viral pnömoni	100,000	100,000	100,000	100,000	100,000
Ortalama	99,727	99,029	99,231	99,797	99,119

Tablo 56. KL Sapma Test Sonuçları- Genel Doğruluk %99,561

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)
COVID-19	99,756	99,721	98,893	99,941	99,306
Fibröz	99,854	98,251	100,000	99,840	99,118
Normal	99,732	99,511	99,951	99,514	99,731
TB	99,780	100,000	98,714	100,000	99,353
Viral pnömoni	100,000	100,000	100,000	100,000	100,000
Ortalama	99,824	99,497	99,512	99,859	99,501

EK 7: Altı Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları

Tablo 57. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %94,471

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,045	84,119	87,004	98,166	85,537	0,9894
COVID-19	99,674	99,026	98,479	99,854	98,752	0,9999
Akciğer Opasitesi	97,679	95,897	93,344	98,887	94,604	0,9925
Normal	97,534	95,853	97,547	97,527	96,693	0,9948
TB	99,927	100,000	99,429	100,000	99,713	1,0000
Viral pnömoni	97,081	74,296	70,569	98,601	72,384	0,9730
Ortalama	98,157	91,532	91,062	98,839	91,280	0,9916

Tablo 58. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %94,289

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,791	83,012	85,560	98,045	84,267	0,980
COVID-19	99,637	99,024	98,202	99,854	98,611	1,000
Akciğer Opasitesi	97,770	95,451	94,260	98,748	94,851	0,980
Normal	97,553	96,392	97,007	97,872	96,698	0,990
TB	99,964	100,000	99,714	100,000	99,857	1,000
Viral pnömoni	96,864	71,575	69,900	98,409	70,728	0,940
Ortalama	98,096	90,909	90,774	98,821	90,835	0,982

Tablo 59. Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)- Genel Doğruluk: %94,652

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,063	85,252	85,560	98,347	85,405	0,980
COVID-19	99,746	99,580	98,479	99,937	99,026	1,000
Akciğer Opasitesi	97,806	96,395	93,428	99,026	94,888	0,990
Normal	97,625	95,908	97,743	97,556	96,817	0,990
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,063	72,607	73,579	98,409	73,090	0,960
Ortalama	98,217	91,624	91,465	98,879	91,538	0,987

Tablo 60. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %94,616

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,154	86,025	85,560	98,448	85,792	0,980
COVID-19	99,619	99,717	97,372	99,958	98,530	1,000
Akciğer Opasitesi	97,661	95,046	94,176	98,632	94,609	0,990
Normal	97,679	96,225	97,547	97,757	96,881	0,990
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,117	73,179	73,913	98,447	73,544	0,970
Ortalama	98,205	91,699	91,428	98,874	91,559	0,988

Tablo 61. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,344

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,045	85,225	85,379	98,347	85,302	0,980
COVID-19	99,601	99,297	97,649	99,896	98,466	1,000
Akciğer Opasitesi	97,698	95,823	93,511	98,864	94,653	0,990
Normal	97,426	95,753	97,350	97,470	96,545	0,990
TB	99,964	100,000	99,714	100,000	99,857	1,000
Viral pnömoni	96,954	71,336	73,244	98,313	72,277	0,970
Ortalama	98,115	91,239	91,141	98,815	91,183	0,988

Tablo 62. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,217

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,719	84,601	82,310	98,327	83,440	0,990
COVID-19	99,529	99,433	96,957	99,917	98,179	1,000
Akciğer Opasitesi	97,752	95,990	93,594	98,911	94,777	0,990
Normal	97,788	96,013	98,086	97,614	97,039	0,990
TB	99,982	100,000	99,857	100,000	99,929	1,000
Viral pnömoni	96,664	68,025	72,575	98,045	70,227	0,980
Ortalama	98,072	90,677	90,563	98,802	90,598	0,992

Tablo 63. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %94,797

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,081	86,729	83,755	98,569	85,216	0,990
COVID-19	99,801	99,444	99,032	99,917	99,238	1,000
Akciğer Opasitesi	97,879	96,328	93,844	99,003	95,070	0,990
Normal	97,770	96,189	97,841	97,729	97,008	1,000
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,063	71,609	75,920	98,275	73,701	0,980
Ortalama	98,266	91,717	91,732	98,915	91,705	0,993

Tablo 64. Dinamik En Büyük Kayıp Fonksiyonu ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %94,815

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,172	86,852	84,657	98,569	85,740	0,980
COVID-19	99,710	99,579	98,202	99,937	98,886	1,000
Akciğer Opasitesi	97,788	96,713	93,012	99,119	94,826	0,990
Normal	97,770	95,748	98,332	97,441	97,023	1,000
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,190	72,930	76,589	98,371	74,715	0,980
Ortalama	98,272	91,970	91,798	98,906	91,865	0,992

Tablo 65. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %93,945

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,429	85,207	77,978	98,489	81,433	0,990
COVID-19	99,547	99,715	96,819	99,958	98,246	1,000
Akciğer Opasitesi	97,843	96,243	93,760	98,980	94,985	0,990
Normal	97,643	95,646	98,086	97,384	96,851	1,000
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	96,429	64,740	74,916	97,661	69,457	0,980
Ortalama	97,982	90,258	90,260	98,745	90,162	0,993

Tablo 66. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %93,981

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	96,338	89,640	71,841	99,073	79,760	0,980
COVID-19	99,656	99,438	97,925	99,917	98,676	1,000
Akciğer Opasitesi	97,915	96,020	94,343	98,911	95,174	0,990
Normal	97,788	96,460	97,596	97,901	97,024	0,990
TB	99,946	99,573	100,000	99,938	99,786	1,000
Viral pnömoni	96,320	61,594	85,284	96,952	71,529	0,980
Ortalama	97,994	90,454	91,165	98,782	90,325	0,990

Tablo 67. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %93,328

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	96,755	81,942	86,823	97,864	84,312	0,990
COVID-19	99,456	99,856	95,989	99,979	97,884	1,000
Akciğer Opasitesi	96,972	95,118	90,765	98,702	92,891	0,990
Normal	96,791	93,871	97,694	96,262	95,744	0,990
TB	99,946	100,000	99,571	100,000	99,785	1,000
Viral pnömoni	96,737	72,119	64,883	98,562	68,310	0,980
Ortalama	97,776	90,484	89,288	98,562	89,821	0,992

Tablo 68. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %95.015

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	97,136	86,264	85,018	98,489	85,636	0,989
COVID-19	99,746	99,719	98,340	99,958	99,025	1,000
Akciğer Opasitesi	98,024	96,196	94,676	98,957	95,430	0,992
Normal	98,006	96,615	98,037	97,987	97,321	0,996
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,117	72,876	74,582	98,409	73,719	0,975
Ortalama	98,338	91,945	91,776	98,967	91,855	0,992

Tablo 69. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %95,051

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,190	86,472	85,379	98,509	85,922	0,989
COVID-19	99,746	99,719	98,340	99,958	99,025	1,000
Akciğer Opasitesi	98,006	96,271	94,509	98,980	95,382	0,992
Normal	97,988	96,523	98,086	97,930	97,299	0,996
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,172	73,443	74,916	98,447	74,172	0,975
Ortalama	98,350	92,071	91,872	98,971	91,967	0,992

Tablo 70. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %95,033

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,154	86,289	85,199	98,489	85,740	0,989
COVID-19	99,746	99,719	98,340	99,958	99,025	1,000
Akciğer Opasitesi	98,024	96,196	94,676	98,957	95,430	0,992
Normal	98,006	96,615	98,037	97,987	97,321	0,996
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,136	73,115	74,582	98,428	73,841	0,975
Ortalama	98,344	91,989	91,806	98,970	91,893	0,992

Tablo 71. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,471

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,954	85,091	84,477	98,347	84,783	0,988
COVID-19	99,619	99,298	97,787	99,896	98,537	1,000
Akciğer Opasitesi	97,825	96,318	93,594	99,003	94,937	0,990
Normal	97,661	95,911	97,841	97,556	96,867	0,995
TB	99,982	100,000	99,857	100,000	99,929	1,000
Viral pnömoni	96,900	70,779	72,910	98,275	71,829	0,979
Ortalama	98,157	91,233	91,078	98,846	91,147	0,992

Tablo 72. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,561

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	97,045	85,610	84,838	98,408	85,222	0,988
COVID-19	99,637	99,299	97,925	99,896	98,607	1,000
Akciğer Opasitesi	97,806	96,315	93,511	99,003	94,892	0,990
Normal	97,643	95,910	97,792	97,556	96,842	0,995
TB	99,982	100,000	99,857	100,000	99,929	1,000
Viral pnömoni	97,009	71,613	74,247	98,313	72,906	0,979
Ortalama	98,187	91,458	91,362	98,863	91,400	0,992

Tablo 73. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,471

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	96,954	85,091	84,477	98,347	84,783	0,988
COVID-19	99,619	99,298	97,787	99,896	98,537	1,000
Akciğer Opasitesi	97,825	96,318	93,594	99,003	94,937	0,990
Normal	97,661	95,911	97,841	97,556	96,867	0,995
TB	99,982	100,000	99,857	100,000	99,929	1,000
Viral pnömoni	96,900	70,779	72,910	98,275	71,829	0,979
Ortalama	98,157	91,233	91,078	98,846	91,147	0,992

Tablo 74. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %94,996

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	97,009	89,613	79,422	98,972	84,211	0,992
COVID-19	99,801	99,860	98,617	99,979	99,235	1,000
Akciğer Opasitesi	98,133	97,248	94,093	99,258	95,645	0,995
Normal	98,042	96,261	98,528	97,757	97,381	0,997
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,009	68,508	82,943	97,815	75,038	0,986
Ortalama	98,332	91,915	92,267	98,964	91,918	0,995

Tablo 75. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %94,888

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,954	90,208	78,159	99,053	83,752	0,992
COVID-19	99,764	99,581	98,617	99,937	99,097	1,000
Akciğer Opasitesi	98,096	96,920	94,260	99,166	95,571	0,995
Normal	98,024	96,437	98,283	97,872	97,351	0,996
TB	99,982	99,857	100,000	99,979	99,929	1,000
Viral pnömoni	96,954	67,560	84,281	97,681	75,000	0,986
Ortalama	98,296	91,761	92,266	98,948	91,783	0,995

Tablo 76. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %94,996

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,027	89,796	79,422	98,992	84,291	0,992
COVID-19	99,801	99,860	98,617	99,979	99,235	1,000
Akciğer Opasitesi	98,115	97,165	94,093	99,235	95,604	0,995
Normal	98,024	96,259	98,479	97,757	97,356	0,997
TB	100,000	100,000	100,000	100,000	100,000	1,000
Viral pnömoni	97,027	68,595	83,278	97,815	75,227	0,986
Ortalama	98,332	91,946	92,315	98,963	91,952	0,995

EK 8: Yedi Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları

Tablo 77. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %94,259

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,908	82,662	85,199	98,132	83,911	0,9902
COVID-19	99,624	99,297	97,649	99,903	98,466	0,9998
Fibröz	99,932	100,000	98,813	100,000	99,403	1,0000
Akciğer Opasitesi	97,711	95,486	93,261	98,860	94,360	0,9914
Normal	97,540	95,398	97,645	97,484	96,508	0,9947
TB	99,915	100,000	99,286	100,000	99,642	1,0000
Viral pnömoni	96,890	70,671	66,890	98,506	68,729	0,9814
Ortalama	98,360	91,931	91,249	98,983	91,574	0,9939

Tablo 78. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %94,874

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,181	84,303	86,282	98,320	85,281	0,990
COVID-19	99,692	99,026	98,479	99,864	98,752	1,000
Fibröz	99,915	99,405	99,110	99,964	99,257	1,000
Akciğer Opasitesi	97,881	94,992	94,676	98,710	94,833	0,990
Normal	97,881	96,729	97,203	98,244	96,965	0,990
TB	99,966	100,000	99,714	100,000	99,857	1,000
Viral pnömoni	97,232	73,868	70,903	98,650	72,355	0,980
Ortalama	98,536	92,617	92,338	99,107	92,471	0,993

Tablo 79. Ağırlıklandırılmış Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)- Genel Doğruluk: %94,328

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,822	80,976	86,823	97,868	83,798	0,990
COVID-19	99,710	99,302	98,340	99,903	98,819	1,000
Fibröz	99,897	98,251	100,000	99,891	99,118	1,000
Akciğer Opasitesi	97,796	96,210	92,928	99,054	94,541	0,990
Normal	97,676	95,633	97,792	97,615	96,701	1,000
TB	99,932	100,000	99,429	100,000	99,713	1,000
Viral pnömoni	96,822	71,815	62,207	98,686	66,667	0,980
Ortalama	98,379	91,741	91,074	99,002	91,337	0,994

Tablo 80. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %95,216

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,266	83,966	87,906	98,245	85,891	0,990
COVID-19	99,761	99,168	98,893	99,883	99,030	1,000
Fibröz	99,983	99,704	100,000	99,982	99,852	1,000
Akciğer Opasitesi	98,104	96,824	93,844	99,204	95,311	0,990
Normal	98,069	96,341	98,184	98,008	97,254	1,000
TB	99,983	100,000	99,857	100,000	99,929	1,000
Viral pnömoni	97,266	75,458	68,896	98,794	72,028	0,970
Ortalama	98,633	93,066	92,512	99,159	92,756	0,993

Tablo 81. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,892

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,266	88,780	81,408	98,924	84,934	0,990
COVID-19	99,641	99,576	97,510	99,942	98,532	1,000
Fibröz	99,897	98,251	100,000	99,891	99,118	1,000
Akciğer Opasitesi	97,950	96,799	93,095	99,204	94,911	0,990
Normal	97,881	95,615	98,430	97,588	97,002	0,990
TB	99,897	100,000	99,143	100,000	99,570	1,000
Viral pnömoni	97,249	69,942	80,936	98,127	75,039	0,980
Ortalama	98,540	92,709	92,932	99,097	92,729	0,993

Tablo 82. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi+ Kategorik Hinge)- Genel Doğruluk: %94,721

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,266	84,683	86,823	98,358	85,740	0,980
COVID-19	99,522	99,013	97,095	99,864	98,045	1,000
Fibröz	99,624	94,118	99,703	99,619	96,830	1,000
Akciğer Opasitesi	97,916	95,455	94,343	98,839	94,895	0,990
Normal	97,933	96,733	97,350	98,244	97,041	0,990
TB	99,829	100,000	98,571	100,000	99,281	1,000
Viral pnömoni	97,352	74,828	72,575	98,686	73,684	0,960
Ortalama	98,492	92,118	92,352	99,087	92,216	0,989

Tablo 83. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,874

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,181	84,303	86,282	98,320	85,281	0,990
COVID-19	99,692	99,026	98,479	99,864	98,752	1,000
Fibröz	99,915	99,405	99,110	99,964	99,257	1,000
Akciğer Opasitesi	97,881	94,992	94,676	98,710	94,833	0,990
Normal	97,881	96,729	97,203	98,244	96,965	0,990
TB	99,966	100,000	99,714	100,000	99,857	1,000
Viral pnömoni	97,232	73,868	70,903	98,650	72,355	0,980
Ortalama	98,536	92,617	92,338	99,107	92,471	0,993

Tablo 84. Dinamik En Büyük Kayıp ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %94,567

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,027	86,538	81,227	98,679	83,799	0,990
COVID-19	99,505	99,713	96,266	99,961	97,959	1,000
Fibröz	99,983	99,704	100,000	99,982	99,852	1,000
Akciğer Opasitesi	97,847	94,833	94,676	98,667	94,754	0,990
Normal	97,779	96,221	97,448	97,955	96,831	0,990
TB	99,983	99,857	100,000	99,981	99,929	1,000
Viral pnömoni	97,010	68,675	76,254	98,127	72,266	0,980
Ortalama	98,448	92,220	92,267	99,050	92,199	0,993

Tablo 85. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %94,447

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	96,856	79,839	89,350	97,641	84,327	0,990
COVID-19	99,658	99,717	97,510	99,961	98,601	1,000
Fibröz	99,932	99,115	99,703	99,946	99,408	1,000
Akciğer Opasitesi	97,847	95,826	93,594	98,946	94,697	0,990
Normal	97,728	95,815	97,743	97,720	96,769	1,000
TB	99,983	100,000	99,857	100,000	99,929	1,000
Viral pnömoni	96,890	74,894	58,863	98,938	65,918	0,980
Ortalama	98,414	92,172	90,946	99,022	91,378	0,989

Tablo 86. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %93,354

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,096	84,043	85,560	98,302	84,794	0,990
COVID-19	99,470	99,148	96,542	99,883	97,828	1,000
Fibröz	98,872	83,791	99,703	98,822	91,057	1,000
Akciğer Opasitesi	96,908	96,367	88,270	99,140	92,141	0,990
Normal	97,471	95,129	97,743	97,326	96,418	0,990
TB	99,863	99,856	99,000	99,981	99,426	1,000
Viral pnömoni	97,027	71,186	70,234	98,470	70,707	0,960
Ortalama	98,101	89,931	91,007	98,846	90,339	0,989

Tablo 87. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %94,789

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,096	87,209	81,227	98,754	84,112	0,990
COVID-19	99,692	99,439	98,064	99,922	98,747	1,000
Fibröz	99,932	99,115	99,703	99,946	99,408	1,000
Akciğer Opasitesi	98,001	95,322	94,925	98,796	95,123	0,990
Normal	97,762	96,444	97,154	98,087	96,798	1,000
TB	99,966	100,000	99,714	100,000	99,857	1,000
Viral pnömoni	97,130	69,436	78,261	98,145	73,585	0,980
Ortalama	98,511	92,424	92,721	99,093	92,519	0,989

Tablo 88. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %95,267

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,335	84,429	88,087	98,302	86,219	0,985
COVID-19	99,675	99,162	98,202	99,883	98,680	1,000
Fibröz	99,949	99,408	99,703	99,964	99,556	1,000
Akciğer Opasitesi	98,155	96,752	94,176	99,183	95,447	0,992
Normal	98,104	96,389	98,234	98,034	97,303	0,996
TB	99,949	100,000	99,571	100,000	99,785	1,000
Viral pnömoni	97,369	76,173	70,569	98,812	73,264	0,972
Ortalama	98,648	93,188	92,649	99,168	92,893	0,992

Tablo 89. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %95,319

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	97,335	84,669	87,726	98,339	86,170	0,985
COVID-19	99,675	99,162	98,202	99,883	98,680	1,000
Fibröz	99,932	99,115	99,703	99,946	99,408	1,000
Akciğer Opasitesi	98,206	96,760	94,426	99,183	95,579	0,992
Normal	98,172	96,575	98,234	98,139	97,397	0,996
TB	99,949	100,000	99,571	100,000	99,785	1,000
Viral pnömoni	97,369	75,801	71,237	98,776	73,448	0,972
Ortalama	98,662	93,155	92,728	99,181	92,924	0,992

Tablo 90. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %95,284

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	97,335	84,429	88,087	98,302	86,219	0,985
COVID-19	99,675	99,162	98,202	99,883	98,680	1,000
Fibröz	99,949	99,408	99,703	99,964	99,556	1,000
Akciğer Opasitesi	98,172	96,755	94,260	99,183	95,491	0,992
Normal	98,121	96,435	98,234	98,060	97,326	0,996
TB	99,949	100,000	99,571	100,000	99,785	1,000
Viral pnömoni	97,369	76,173	70,569	98,812	73,264	0,972
Ortalama	98,653	93,195	92,661	99,172	92,903	0,992

Tablo 91. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge +Kategorik Çapraz Entropi, Kategorik Hinge +Kategorik Çapraz Entropi)- Genel Doğruluk: %87,801

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Bakteriyel pnömoni	97,232	87,262	82,852	98,736	85,000	0,970
COVID-19	99,368	99,710	95,159	99,961	97,381	1,000
Fibröz	91,577	40,602	100,000	91,062	57,755	1,000
Akciğer Opasitesi	94,447	98,134	74,376	99,634	84,619	0,989
Normal	95,934	98,128	90,039	99,083	93,910	0,994
TB	99,812	100,000	98,429	100,000	99,208	1,000
Viral pnömoni	97,232	70,326	79,264	98,199	74,528	0,962
Ortalama	96,515	84,881	88,588	98,097	84,629	0,988

Tablo 92. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,857

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,318	88,544	82,310	98,887	85,313	0,972
COVID-19	99,675	99,577	97,787	99,942	98,674	1,000
Fibröz	99,658	94,398	100,000	99,637	97,118	1,000
Akciğer Opasitesi	97,933	97,123	92,679	99,290	94,849	0,990
Normal	97,933	95,839	98,332	97,720	97,070	0,994
TB	99,897	100,000	99,143	100,000	99,570	1,000
Viral pnömoni	97,301	70,796	80,268	98,218	75,235	0,965
Ortalama	98,531	92,325	92,931	99,099	92,547	0,989

Tablo 93. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %94,806

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,318	88,544	82,310	98,887	85,313	0,972
COVID-19	99,675	99,577	97,787	99,942	98,674	1,000
Fibröz	99,590	93,352	100,000	99,565	96,562	1,000
Akciğer Opasitesi	97,950	97,208	92,679	99,312	94,889	0,990
Normal	97,881	95,833	98,184	97,720	96,995	0,994
TB	99,897	100,000	99,143	100,000	99,570	1,000
Viral pnömoni	97,301	70,796	80,268	98,218	75,235	0,964
Ortalama	98,516	92,187	92,910	99,092	92,463	0,989

Tablo 94. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %95,131

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,249	84,779	86,462	98,377	85,612	0,992
COVID-19	99,744	99,580	98,340	99,942	98,956	1,000
Fibröz	99,932	99,115	99,703	99,946	99,408	1,000
Akciğer Opasitesi	98,138	96,511	94,343	99,118	95,414	0,995
Normal	97,984	96,287	97,988	97,982	97,130	0,996
TB	99,949	100,000	99,571	100,000	99,785	1,000
Viral pnömoni	97,266	74,048	71,572	98,650	72,789	0,984
Ortalama	98,609	92,903	92,569	99,145	92,728	0,995

Tablo 95. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %94,943

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,215	83,765	87,545	98,226	85,613	0,992
COVID-19	99,727	99,441	98,340	99,922	98,887	1,000
Fibröz	99,880	98,246	99,703	99,891	98,969	1,000
Akciğer Opasitesi	97,967	96,802	93,178	99,204	94,955	0,994
Normal	97,916	95,881	98,234	97,746	97,043	0,996
TB	99,949	100,000	99,571	100,000	99,785	1,000
Viral pnömoni	97,232	74,909	68,896	98,758	71,777	0,983
Ortalama	98,555	92,721	92,210	99,107	92,433	0,995

Tablo 96. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %95,097

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Bakteriyel pnömoni	97,215	84,480	86,462	98,339	85,459	0,992
COVID-19	99,744	99,580	98,340	99,942	98,956	1,000
Fibröz	99,932	99,115	99,703	99,946	99,408	1,000
Akciğer Opasitesi	98,138	96,511	94,343	99,118	95,414	0,995
Normal	97,984	96,287	97,988	97,982	97,130	0,996
TB	99,949	100,000	99,571	100,000	99,785	1,000
Viral pnömoni	97,232	73,868	70,903	98,650	72,355	0,984
Ortalama	98,599	92,834	92,473	99,139	92,644	0,995

EK 9: Sekiz Sınıf İçin Önerilen Kayıp Fonksiyonları Test Sonuçları

Sekiz Sınıf için Önerilen Kayıp Fonksiyonlarıyla Elde Edilen Test Sonuçları-1

Tablo 97. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %89,398

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atektazi	93,207	73,960	76,164	95,847	75,046	0,970
COVID-19	99,638	100,000	95,989	100,000	97,953	1,000
Akciğer Opasitesi	98,252	96,254	91,930	99,368	94,043	0,970
Nodül	94,918	62,166	73,380	96,571	67,309	0,970
Normal	98,239	95,059	98,184	98,258	96,597	1,000
Pnömoni	99,925	99,302	100,000	99,916	99,650	1,000
Pnömotoraks	94,780	79,916	67,651	97,989	73,274	0,970
TB	99,838	98,723	99,429	99,877	99,075	1,000
Ortalama	97,350	88,173	87,841	98,478	87,868	0,985

Tablo 98. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %88,936

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atektazi	93,244	75,405	73,650	96,279	74,517	0,970
COVID-19	98,951	90,392	98,893	98,957	94,452	1,000
Akciğer Opasitesi	98,014	93,934	92,762	98,942	93,344	1,000
Nodül	95,042	68,511	56,392	98,010	61,864	0,960
Normal	98,002	96,165	95,976	98,693	96,071	1,000
Pnömoni	99,938	99,765	99,648	99,972	99,707	1,000
Pnömotoraks	94,955	74,367	79,811	96,746	76,993	0,970
TB	99,725	97,346	99,571	99,740	98,446	1,000
Ortalama	97,234	86,986	87,088	98,417	86,924	0,988

Tablo 99. Ağırlıklandırılmış Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)- Genel Doğruluk: %88,149

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atektazi	92,495	70,911	74,674	95,255	72,744	0,970
COVID-19	98,851	89,586	98,755	98,861	93,947	1,000
Akciğer Opasitesi	98,464	97,701	91,930	99,618	94,728	1,000
Nodül	95,067	72,222	50,088	98,521	59,152	0,970
Normal	97,665	95,257	95,584	98,375	95,420	1,000
Pnömoni	99,950	99,649	99,883	99,958	99,766	1,000
Pnömotoraks	93,944	69,174	77,096	95,936	72,920	0,970
TB	99,863	98,590	99,857	99,863	99,219	1,000
Ortalama	97,037	86,636	85,983	98,298	85,987	0,989

Tablo 100. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %89,273

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,957	81,022	62,011	97,750	70,253	0,970
COVID-19	99,750	99,299	97,925	99,931	98,607	1,000
Akciğer Opasitesi	98,264	93,459	95,092	98,825	94,268	1,000
Nodül	94,343	58,127	73,905	95,912	65,073	0,970
Normal	98,314	96,849	96,516	98,928	96,682	1,000
Pnömoni	99,975	99,766	100,000	99,972	99,883	1,000
Pnömotoraks	94,980	73,645	81,818	96,537	77,517	0,980
TB	99,963	100,000	99,571	100,000	99,785	1,000
Ortalama	97,318	87,771	88,355	98,482	87,759	0,990

Tablo 101. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %90,310

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,656	74,956	79,143	95,904	76,993	0,970
COVID-19	99,775	99,301	98,202	99,931	98,748	1,000
Akciğer Opasitesi	98,489	96,797	93,012	99,456	94,866	1,000
Nodül	95,417	70,158	62,172	97,970	65,924	0,960
Normal	98,414	95,652	98,234	98,476	96,926	1,000
Pnömoni	99,938	99,417	100,000	99,930	99,708	1,000
Pnömotoraks	95,017	76,230	76,860	97,165	76,543	0,970
TB	99,913	100,000	99,000	100,000	99,497	1,000
Ortalama	97,577	89,064	88,328	98,604	88,651	0,988

Tablo 102. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %89,660

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,357	74,240	77,281	95,847	75,730	0,970
COVID-19	99,675	99,015	97,372	99,904	98,187	1,000
Akciğer Opasitesi	98,239	95,536	92,596	99,236	94,043	0,990
Nodül	95,167	69,492	57,443	98,064	62,895	0,960
Normal	98,314	95,548	97,939	98,442	96,729	1,000
Pnömoni	99,975	99,766	100,000	99,972	99,883	1,000
Pnömotoraks	94,705	73,370	78,394	96,635	75,799	0,970
TB	99,888	99,856	98,857	99,986	99,354	1,000
Ortalama	97,415	88,353	87,485	98,511	87,828	0,986

Tablo 103. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %89,660

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,082	74,857	72,905	96,207	73,868	0,950
COVID-19	99,738	98,750	98,340	99,876	98,545	1,000
Akciğer Opasitesi	98,526	96,010	94,093	99,309	95,042	1,000
Nodül	95,105	66,483	63,222	97,553	64,811	0,950
Normal	98,427	96,817	97,007	98,911	96,912	1,000
Pnömoni	99,925	99,302	100,000	99,916	99,650	1,000
Pnömotoraks	94,630	72,443	79,457	96,425	75,788	0,960
TB	99,888	100,000	98,714	100,000	99,353	1,000
Ortalama	97,415	88,083	87,967	98,525	87,996	0,983

Tablo 104. Dinamik En Büyük Kayıp ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %88,249

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,244	73,522	77,561	95,673	75,487	0,970
COVID-19	98,851	99,374	87,828	99,945	93,245	1,000
Akciğer Opasitesi	97,490	94,175	88,769	99,030	91,392	0,990
Nodül	94,780	62,124	68,651	96,786	65,225	0,970
Normal	97,390	91,101	99,460	96,683	95,097	1,000
Pnömoni	99,950	100,000	99,531	100,000	99,765	1,000
Pnömotoraks	94,955	81,598	67,532	98,199	73,902	0,980
TB	99,838	99,283	98,857	99,932	99,069	1,000
Ortalama	97,062	87,647	86,024	98,281	86,648	0,989

Tablo 105. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %89,710

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,244	72,007	81,192	95,111	76,324	0,960
COVID-19	99,663	99,432	96,819	99,945	98,108	1,000
Akciğer Opasitesi	98,339	95,723	93,095	99,265	94,391	1,000
Nodül	95,105	67,793	59,720	97,822	63,501	0,950
Normal	98,339	96,081	97,448	98,643	96,760	1,000
Pnömoni	99,913	99,301	99,883	99,916	99,591	1,000
Pnömotoraks	94,943	77,419	73,672	97,458	75,499	0,960
TB	99,875	100,000	98,571	100,000	99,281	1,000
Ortalama	97,428	88,469	87,550	98,520	87,932	0,984

Tablo 106. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %89,523

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,082	74,209	74,209	96,005	74,209	0,970
COVID-19	99,663	99,714	96,542	99,973	98,103	1,000
Akciğer Opasitesi	98,377	95,424	93,677	99,207	94,542	1,000
Nodül	94,755	61,286	71,804	96,517	66,129	0,960
Normal	98,364	95,996	97,645	98,610	96,813	1,000
Pnömoni	99,950	99,649	99,883	99,958	99,766	1,000
Pnömotoraks	94,980	79,009	71,547	97,752	75,093	0,970
TB	99,875	100,000	98,571	100,000	99,281	1,000
Ortalama	97,381	88,161	87,985	98,503	87,992	0,988

Tablo 107. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %89,510

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,282	80,180	66,294	97,462	72,579	0,970
COVID-19	99,775	98,487	99,032	99,849	98,759	1,000
Akciğer Opasitesi	98,314	97,254	91,348	99,545	94,208	1,000
Nodül	95,342	67,247	67,601	97,472	67,424	0,970
Normal	98,139	94,657	98,234	98,107	96,412	1,000
Pnömoni	99,963	99,883	99,766	99,986	99,824	1,000
Pnömotoraks	94,243	68,848	83,235	95,545	75,361	0,980
TB	99,963	99,857	99,714	99,986	99,786	1,000
Ortalama	97,378	88,302	88,153	98,494	88,044	0,990

Tablo 108. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %90,485

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,681	78,745	72,439	96,971	75,461	0,970
COVID-19	99,800	99,441	98,340	99,945	98,887	1,000
Akciğer Opasitesi	98,526	95,854	94,260	99,280	95,050	0,996
Nodül	95,392	67,354	68,651	97,445	67,997	0,969
Normal	98,564	96,517	97,890	98,794	97,199	0,998
Pnömoni	99,975	99,766	100,000	99,972	99,883	1,000
Pnömotoraks	95,092	74,620	81,228	96,732	77,784	0,976
TB	99,938	99,857	99,429	99,986	99,642	1,000
Ortalama	97,621	89,019	89,030	98,641	88,988	0,989

Tablo 109. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %90,485

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,681	78,745	72,439	96,971	75,461	0,970
COVID-19	99,800	99,441	98,340	99,945	98,887	1,000
Akciğer Opasitesi	98,526	95,854	94,260	99,280	95,050	0,996
Nodül	95,392	67,354	68,651	97,445	67,997	0,969
Normal	98,564	96,517	97,890	98,794	97,199	0,998
Pnömoni	99,975	99,766	100,000	99,972	99,883	1,000
Pnömotoraks	95,092	74,620	81,228	96,732	77,784	0,976
TB	99,938	99,857	99,429	99,986	99,642	1,000
Ortalama	97,621	89,019	89,030	98,641	88,988	0,989

Tablo 110. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %90,485

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,669	78,723	72,346	96,971	75,400	0,970
COVID-19	99,800	99,441	98,340	99,945	98,887	1,000
Akciğer Opasitesi	98,539	95,858	94,343	99,280	95,094	0,996
Nodül	95,380	67,238	68,651	97,432	67,938	0,969
Normal	98,576	96,563	97,890	98,811	97,222	0,998
Pnömoni	99,975	99,766	100,000	99,972	99,883	0,998
Pnömotoraks	95,092	74,620	81,228	96,732	77,784	1,000
TB	99,938	99,857	99,429	99,986	99,642	0,976
Ortalama	97,621	89,008	89,028	98,641	88,981	0,988

Tablo 111. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %90,472

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,519	75,389	76,723	96,121	76,050	0,964
COVID-19	99,800	99,303	98,479	99,931	98,889	1,000
Akciğer Opasitesi	98,689	97,001	94,176	99,486	95,568	0,996
Nodül	95,455	70,334	62,697	97,970	66,296	0,960
Normal	98,614	96,434	98,184	98,760	97,301	0,997
Pnömoni	99,938	99,417	100,000	99,930	99,708	1,000
Pnömotoraks	95,005	74,972	79,221	96,872	77,038	0,972
TB	99,925	100,000	99,143	100,000	99,570	1,000
Ortalama	97,618	89,106	88,578	98,634	88,802	0,986

Tablo 112. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %90,509

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,556	75,643	76,629	96,178	76,133	0,964
COVID-19	99,813	99,304	98,617	99,931	98,959	1,000
Akciğer Opasitesi	98,689	97,001	94,176	99,486	95,568	0,996
Nodül	95,430	69,981	62,872	97,929	66,236	0,960
Normal	98,626	96,480	98,184	98,777	97,325	0,997
Pnömoni	99,938	99,417	100,000	99,930	99,708	1,000
Pnömotoraks	95,042	75,112	79,457	96,886	77,223	0,972
TB	99,925	100,000	99,143	100,000	99,570	1,000
Ortalama	97,627	89,117	88,635	98,640	88,840	0,986

Tablo 113. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %90,472

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,519	75,389	76,723	96,121	76,050	0,964
COVID-19	99,800	99,303	98,479	99,931	98,889	1,000
Akciğer Opasitesi	98,689	97,001	94,176	99,486	95,568	0,996
Nodül	95,455	70,334	62,697	97,970	66,296	0,960
Normal	98,614	96,434	98,184	98,760	97,301	0,997
Pnömoni	99,938	99,417	100,000	99,930	99,708	1,000
Pnömotoraks	95,005	74,972	79,221	96,872	77,038	0,972
TB	99,925	100,000	99,143	100,000	99,570	1,000
Ortalama	97,618	89,106	88,578	98,634	88,802	0,986

Tablo 114. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %90,872

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,856	76,796	77,654	96,366	77,222	0,972
COVID-19	99,825	99,580	98,479	99,959	99,026	1,000
Akciğer Opasitesi	98,651	97,074	93,844	99,500	95,431	0,997
Nodül	95,492	68,293	68,651	97,553	68,472	0,972
Normal	98,614	96,211	98,430	98,677	97,308	0,998
Pnömoni	99,975	99,766	100,000	99,972	99,883	1,000
Pnömotoraks	95,417	78,708	77,686	97,514	78,194	0,977
TB	99,913	99,856	99,143	99,986	99,498	1,000
Ortalama	97,718	89,536	89,236	98,691	89,379	0,989

Tablo 115. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %90,460

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,644	74,978	78,957	95,919	76,916	0,971
COVID-19	99,775	99,578	97,925	99,959	98,745	1,000
Akciğer Opasitesi	98,589	96,499	94,010	99,398	95,238	0,996
Nodül	95,180	65,921	67,075	97,338	66,493	0,970
Normal	98,589	96,296	98,234	98,710	97,255	0,998
Pnömoni	99,975	99,766	100,000	99,972	99,883	1,000
Pnömotoraks	95,267	79,695	74,144	97,766	76,820	0,974
TB	99,900	100,000	98,857	100,000	99,425	1,000
Ortalama	97,615	89,092	88,650	98,633	88,847	0,988

Tablo 116. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %90,834

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,831	76,412	78,119	96,265	77,256	0,972
COVID-19	99,813	99,580	98,340	99,959	98,956	1,000
Akciğer Opasitesi	98,651	96,993	93,927	99,486	95,435	0,997
Nodül	95,442	67,944	68,301	97,526	68,122	0,972
Normal	98,626	96,257	98,430	98,693	97,331	0,998
Pnömoni	99,975	99,766	100,000	99,972	99,883	1,000
Pnömotoraks	95,417	79,126	76,978	97,598	78,037	0,976
TB	99,913	99,856	99,143	99,986	99,498	1,000
Ortalama	97,709	89,492	89,155	98,686	89,315	0,989

Sekiz Sınıf için Önerilen Kayıp Fonksiyonlarıyla Elde Edilen Test Sonuçları-2

Tablo 117. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %89,220

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,465	84,179	64,898	98,045	73,291	0,980
COVID-19	99,408	94,716	99,170	99,433	96,892	1,000
Fibröz	95,639	49,763	62,315	97,149	55,336	0,970
Akciğer Opasitesi	98,019	92,671	94,676	98,631	93,663	1,000
Normal	97,903	97,325	94,603	99,076	95,944	1,000
Pnömoni	99,974	99,766	100,000	99,971	99,883	1,000
Pnömotoraks	94,186	69,458	83,235	95,525	75,725	0,980
TB	99,846	100,000	98,286	100,000	99,135	1,000
Ortalama	97,305	85,985	87,148	98,479	86,234	0,991

Tablo 118. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %90,160

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	93,954	82,196	71,788	97,507	76,640	0,950
COVID-19	99,730	98,214	98,893	99,816	98,553	1,000
Fibröz	96,231	59,483	40,950	98,736	48,506	0,930
Akciğer Opasitesi	98,405	95,067	94,592	99,102	94,829	0,990
Normal	98,276	96,621	96,811	98,797	96,716	1,000
Pnömoni	99,936	99,533	99,883	99,942	99,707	1,000
Pnömotoraks	93,903	67,094	86,423	94,817	75,542	0,960
TB	99,884	100,000	98,714	100,000	99,353	1,000
Ortalama	97,540	87,276	86,007	98,590	86,231	0,979

Tablo 119. Ağırlıklandırılmış Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)- Genel Doğruluk: %90,391

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	93,890	79,801	74,674	96,970	77,152	0,980
COVID-19	99,781	99,164	98,479	99,915	98,820	1,000
Fibröz	95,652	49,893	69,436	96,840	58,065	0,970
Akciğer Opasitesi	98,353	93,944	95,507	98,874	94,719	1,000
Normal	98,315	97,180	96,369	99,006	96,773	1,000
Pnömoni	99,936	99,882	99,531	99,986	99,706	1,000
Pnömotoraks	94,906	78,653	73,081	97,575	75,765	0,980
TB	99,949	99,573	99,857	99,958	99,715	1,000
Ortalama	97,598	87,261	88,367	98,640	87,589	0,991

Tablo 120. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %90,069

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	94,006	79,921	75,605	96,955	77,703	0,970
COVID-19	99,614	97,531	98,340	99,745	97,934	1,000
Fibröz	96,180	59,091	38,576	98,790	46,679	0,960
Akciğer Opasitesi	98,070	96,466	90,849	99,391	93,573	0,990
Normal	97,903	94,410	97,792	97,943	96,071	1,000
Pnömoni	99,949	99,649	99,883	99,957	99,766	1,000
Pnömotoraks	94,572	70,772	85,478	95,684	77,433	0,980
TB	99,846	100,000	98,286	100,000	99,135	1,000
Ortalama	97,517	87,230	85,601	98,558	86,037	0,988

Tablo 121. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %90,803

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,890	77,706	78,212	96,403	77,958	0,970
COVID-19	99,691	99,574	97,095	99,957	98,319	1,000
Fibröz	96,244	57,377	51,929	98,252	54,517	0,960
Akciğer Opasitesi	98,444	95,766	94,093	99,239	94,922	0,990
Normal	98,405	96,143	97,841	98,605	96,984	1,000
Pnömoni	99,974	99,766	100,000	99,971	99,883	1,000
Pnömotoraks	95,022	76,196	78,985	96,983	77,565	0,970
TB	99,936	100,000	99,286	100,000	99,642	1,000
Ortalama	97,701	87,816	87,180	98,676	87,474	0,986

Tablo 122. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %90,391

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,980	80,300	74,767	97,060	77,435	0,970
COVID-19	99,640	97,668	98,479	99,759	98,072	1,000
Fibröz	96,154	55,938	53,116	98,104	54,490	0,970
Akciğer Opasitesi	98,122	95,913	91,764	99,285	93,793	0,990
Normal	98,148	94,924	98,184	98,135	96,527	1,000
Pnömoni	99,961	99,766	99,883	99,971	99,824	1,000
Pnömotoraks	94,855	74,373	80,519	96,607	77,324	0,980
TB	99,923	99,856	99,286	99,986	99,570	1,000
Ortalama	97,598	87,342	87,000	98,613	87,129	0,989

Tablo 123. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %90,468

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,620	77,682	75,512	96,522	76,582	0,960
COVID-19	99,678	99,433	97,095	99,943	98,251	1,000
Fibröz	96,231	57,143	52,226	98,225	54,574	0,940
Akciğer Opasitesi	98,353	95,586	93,677	99,209	94,622	0,990
Normal	98,341	96,403	97,301	98,710	96,850	1,000
Pnömoni	99,974	99,766	100,000	99,971	99,883	1,000
Pnömotoraks	94,868	73,932	81,700	96,478	77,622	0,960
TB	99,871	100,000	98,571	100,000	99,281	1,000
Ortalama	97,617	87,493	87,010	98,632	87,208	0,981

Tablo 124. Dinamik En Büyük Kayıp ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %88,835

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,530	79,044	72,346	96,925	75,547	0,970
COVID-19	98,598	87,167	99,585	98,497	92,963	1,000
Fibröz	96,360	61,250	43,620	98,749	50,953	0,970
Akciğer Opasitesi	98,045	97,043	90,100	99,498	93,443	0,990
Normal	97,427	94,482	95,780	98,013	95,127	0,990
Pnömoni	99,961	99,766	99,883	99,971	99,824	1,000
Pnömotoraks	94,083	69,177	82,409	95,510	75,216	0,980
TB	99,666	99,559	96,714	99,958	98,116	1,000
Ortalama	97,209	85,936	85,055	98,390	85,149	0,988

Tablo 125. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %89,992

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,620	79,979	71,788	97,119	75,662	0,970
COVID-19	99,614	99,571	96,266	99,957	97,890	1,000
Fibröz	95,897	52,528	55,490	97,728	53,968	0,970
Akciğer Opasitesi	98,302	94,883	94,093	99,072	94,486	1,000
Normal	98,199	95,801	97,399	98,483	96,594	1,000
Pnömoni	99,961	99,650	100,000	99,957	99,824	1,000
Pnömotoraks	94,430	72,068	79,811	96,218	75,742	0,970
TB	99,961	100,000	99,571	100,000	99,785	1,000
Ortalama	97,498	86,810	86,802	98,567	86,744	0,989

Tablo 126. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %90,147

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,440	75,134	78,492	95,836	76,776	0,970
COVID-19	99,473	99,854	94,467	99,986	97,086	1,000
Fibröz	96,180	58,850	39,466	98,749	47,247	0,950
Akciğer Opasitesi	98,482	96,010	94,093	99,285	95,042	0,990
Normal	98,379	96,095	97,792	98,588	96,936	1,000
Pnömoni	99,949	99,766	99,766	99,971	99,766	1,000
Pnömotoraks	94,572	72,392	81,110	96,218	76,503	0,970
TB	99,820	99,855	98,143	99,986	98,991	1,000
Ortalama	97,537	87,244	85,416	98,577	86,043	0,985

Tablo 127. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %90,095

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	93,543	77,660	74,767	96,552	76,186	0,970
COVID-19	99,550	99,711	95,436	99,972	97,527	1,000
Fibröz	96,218	56,782	53,412	98,158	55,046	0,960
Akciğer Opasitesi	98,251	94,050	94,676	98,904	94,362	1,000
Normal	98,199	96,068	97,105	98,588	96,584	1,000
Pnömoni	99,923	99,302	100,000	99,913	99,650	1,000
Pnömotoraks	94,649	73,655	79,221	96,535	76,337	0,980
TB	99,859	99,855	98,571	99,986	99,209	1,000
Ortalama	97,524	87,135	86,649	98,576	86,862	0,989

Tablo 128. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %90,880

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	94,353	81,281	76,816	97,164	78,985	0,974
COVID-19	99,717	98,212	98,755	99,816	98,483	1,000
Fibröz	96,411	60,662	48,961	98,561	54,187	0,967
Akciğer Opasitesi	98,263	96,757	91,847	99,437	94,238	0,994
Normal	98,199	95,105	98,184	98,204	96,620	0,997
Pnömoni	99,949	99,533	100,000	99,942	99,766	1,000
Pnömotoraks	94,945	73,548	83,707	96,319	78,299	0,979
TB	99,923	100,000	99,143	100,000	99,570	1,000
Ortalama	97,720	88,137	87,177	98,680	87,519	0,989

Tablo 129. Ağırlıklı Topluluk Kayıp Fonksiyonu (En iyi Kategorik çapraz entropi + Kategorik Hinge, Kategorik çapraz entropi + Kategorik Hinge)- Genel Doğruluk: %90,147

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	94,006	79,862	75,698	96,940	77,725	0,971
COVID-19	99,614	97,531	98,340	99,745	97,934	1,000
Fibröz	96,192	59,276	38,872	98,790	46,953	0,965
Akciğer Opasitesi	98,122	96,726	90,932	99,437	93,739	0,994
Normal	97,955	94,463	97,939	97,960	96,170	0,997
Pnömoni	99,949	99,649	99,883	99,957	99,766	1,000
Pnömotoraks	94,610	70,980	85,478	95,727	77,558	0,978
TB	99,846	100,000	98,286	100,000	99,135	1,000
Ortalama	97,537	87,311	85,679	98,569	86,122	0,988

Tablo 130. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %90,816

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	94,327	81,060	76,909	97,119	78,930	0,974
COVID-19	99,743	98,483	98,755	99,844	98,619	1,000
Fibröz	96,373	60,956	45,401	98,682	52,041	0,967
Akciğer Opasitesi	98,251	97,085	91,431	99,498	94,173	0,994
Normal	98,161	94,841	98,332	98,100	96,555	0,997
Pnömoni	99,949	99,533	100,000	99,942	99,766	1,000
Pnömotoraks	94,919	72,967	84,770	96,160	78,427	0,979
TB	99,910	100,000	99,000	100,000	99,497	1,000
Ortalama	97,704	88,116	86,825	98,668	87,251	0,989

Tablo 131. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %91,008

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	93,993	78,551	77,747	96,597	78,147	0,967
COVID-19	99,678	99,433	97,095	99,943	98,251	1,000
Fibröz	96,360	58,654	54,303	98,265	56,394	0,950
Akciğer Opasitesi	98,508	95,861	94,426	99,254	95,138	0,996
Normal	98,469	96,375	97,841	98,692	97,103	0,997
Pnömoni	99,974	99,766	100,000	99,971	99,883	1,000
Pnömotoraks	95,112	76,207	80,165	96,940	78,136	0,969
TB	99,923	100,000	99,143	100,000	99,570	1,000
Ortalama	97,752	88,106	87,590	98,708	87,828	0,985

Tablo 132. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %90,957

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	93,954	78,437	77,561	96,582	77,996	0,997
COVID-19	99,666	99,433	96,957	99,943	98,179	1,000
Fibröz	96,411	59,416	54,303	98,319	56,744	0,950
Akciğer Opasitesi	98,495	95,781	94,426	99,239	95,098	0,996
Normal	98,444	96,327	97,792	98,675	97,054	0,997
Pnömoni	99,974	99,766	100,000	99,971	99,883	1,000
Pnömotoraks	95,048	75,781	80,165	96,867	77,912	0,969
TB	99,923	100,000	99,143	100,000	99,570	1,000
Ortalama	97,739	88,117	87,543	98,700	87,805	0,988

Tablo 133. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %90,996

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,980	78,531	77,654	96,597	78,090	0,967
COVID-19	99,678	99,433	97,095	99,943	98,251	1,000
Fibröz	96,360	58,654	54,303	98,265	56,394	0,950
Akciğer Opasitesi	98,508	95,861	94,426	99,254	95,138	0,996
Normal	98,469	96,375	97,841	98,692	97,103	0,997
Pnömoni	99,974	99,766	100,000	99,971	99,883	1,000
Pnömotoraks	95,099	76,121	80,165	96,925	78,091	0,969
TB	99,923	100,000	99,143	100,000	99,570	1,000
Ortalama	97,749	88,093	87,578	98,706	87,815	0,985

Tablo 134. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %90,751

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	94,006	82,548	71,788	97,567	76,793	0,923
COVID-19	99,717	99,858	97,095	99,986	98,457	1,000
Fibröz	96,038	54,252	54,896	97,902	54,572	0,915
Akciğer Opasitesi	98,534	95,946	94,509	99,270	95,222	0,996
Normal	98,444	96,237	97,890	98,640	97,057	0,997
Pnömoni	99,936	99,417	100,000	99,928	99,708	1,000
Pnömotoraks	94,932	72,948	85,006	96,146	78,517	0,954
TB	99,897	99,856	99,000	99,986	99,426	1,000
Ortalama	97,688	87,633	87,523	98,678	87,469	0,973

Tablo 135. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %90,648

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	94,083	82,316	72,812	97,493	77,273	0,918
COVID-19	99,563	99,855	95,436	99,986	97,595	1,000
Fibröz	96,038	54,179	55,786	97,862	54,971	0,908
Akciğer Opasitesi	98,418	95,146	94,592	99,117	94,869	0,996
Normal	98,405	96,456	97,498	98,727	96,974	0,997
Pnömoni	99,949	99,533	100,000	99,942	99,766	1,000
Pnömotoraks	94,996	73,272	85,124	96,203	78,755	0,952
TB	99,846	99,855	98,429	99,986	99,137	1,000
Ortalama	97,662	87,577	87,460	98,665	87,417	0,971

Tablo 136. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %90,790

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	93,993	82,049	72,346	97,463	76,893	0,931
COVID-19	99,717	99,858	97,095	99,986	98,457	1,000
Fibröz	96,128	55,389	54,896	97,997	55,142	0,921
Akciğer Opasitesi	98,521	95,788	94,592	99,239	95,186	0,996
Normal	98,418	96,234	97,792	98,640	97,007	0,997
Pnömoni	99,949	99,533	100,000	99,942	99,766	1,000
Pnömotoraks	94,945	73,163	84,652	96,203	78,489	0,956
TB	99,910	99,856	99,143	99,986	99,498	1,000
Ortalama	97,697	87,734	87,565	98,682	87,555	0,975

EK 10: Dokuz Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları

Tablo 137. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %94,943

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,108	68,685	61,266	96,249	64,764	0,950
COVID-19	99,735	99,295	97,372	99,940	98,324	1,000
Fibröz	96,583	55,696	39,169	98,798	45,993	0,950
Akciğer Opasitesi	98,501	96,429	92,097	99,479	94,213	1,000
Normal	98,391	94,877	98,135	98,465	96,479	1,000
Plevral Efüzyon	91,369	67,820	75,501	94,019	71,455	0,950
Pnömoni	99,967	99,883	99,766	99,988	99,824	1,000
Pnömotoraks	93,287	62,991	68,123	95,878	65,457	0,960
TB	99,945	99,714	99,571	99,976	99,643	1,000
Ortalama	96,654	82,821	81,222	98,088	81,794	0,979

Tablo 138. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %84,579

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,975	65,149	69,274	95,024	67,148	0,950
COVID-19	99,537	98,573	95,574	99,880	97,051	1,000
Fibröz	96,583	64,516	17,804	99,622	27,907	0,920
Akciğer Opasitesi	98,424	94,608	93,428	99,187	94,014	0,980
Normal	98,258	95,279	97,056	98,607	96,159	0,990
Plevral Efüzyon	91,722	71,317	70,493	95,266	70,903	0,950
Pnömoni	99,934	99,648	99,648	99,963	99,648	1,000
Pnömotoraks	92,780	59,266	72,491	94,869	65,215	0,950
TB	99,945	99,572	99,714	99,964	99,643	1,000
Ortalama	96,573	83,103	79,498	98,043	79,743	0,971

Tablo 139. Ağırlıklandırılmış Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)- Genel Doğruluk: %85,086

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,295	68,620	64,339	96,049	66,410	0,950
COVID-19	99,537	100,000	94,191	100,000	97,009	1,000
Fibröz	96,396	51,748	43,917	98,420	47,512	0,940
Akciğer Opasitesi	98,468	94,108	94,343	99,098	94,225	1,000
Normal	98,578	96,178	97,547	98,877	96,857	1,000
Plevral Efüzyon	91,612	69,933	72,573	94,790	71,229	0,950
Pnömoni	99,956	99,766	99,766	99,976	99,766	1,000
Pnömotoraks	93,408	63,402	69,540	95,866	66,329	0,950
TB	99,923	99,713	99,286	99,976	99,499	1,000
Ortalama	96,686	82,607	81,722	98,117	82,093	0,977

Tablo 140. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %85,317

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,008	66,827	64,525	95,699	65,656	0,940
COVID-19	99,691	99,151	96,957	99,928	98,042	1,000
Fibröz	96,274	49,833	44,214	98,283	46,855	0,930
Akciğer Opasitesi	98,743	96,416	94,010	99,466	95,198	0,990
Normal	98,611	95,962	97,939	98,806	96,940	1,000
Plevral Efüzyon	91,733	69,516	75,193	94,494	72,243	0,950
Pnömoni	99,934	99,532	99,766	99,951	99,649	1,000
Pnömotoraks	93,706	66,912	64,463	96,717	65,664	0,950
TB	99,934	99,430	99,714	99,952	99,572	1,000
Ortalama	96,737	82,620	81,864	98,144	82,202	0,976

Tablo 141. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %84,866

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,152	70,901	57,169	96,849	63,299	0,950
COVID-19	99,724	99,017	97,510	99,916	98,258	1,000
Fibröz	96,087	47,458	49,852	97,871	48,625	0,950
Akciğer Opasitesi	98,567	95,347	93,760	99,301	94,547	0,990
Normal	98,435	95,797	97,301	98,763	96,543	1,000
Plevral Efüzyon	91,369	67,919	75,193	94,070	71,371	0,950
Pnömoni	99,934	99,417	99,883	99,939	99,649	1,000
Pnömotoraks	93,519	64,437	68,241	96,122	66,284	0,950
TB	99,945	99,857	99,429	99,988	99,642	1,000
Ortalama	96,637	82,239	82,038	98,091	82,024	0,976

Tablo 142. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %84,788

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,008	71,895	53,352	97,199	61,251	0,930
COVID-19	99,757	99,576	97,372	99,964	98,462	1,000
Fibröz	95,910	45,251	48,071	97,756	46,619	0,940
Akciğer Opasitesi	98,633	95,678	93,927	99,352	94,794	0,990
Normal	98,556	95,996	97,645	98,820	96,813	1,000
Plevral Efüzyon	91,601	69,253	74,268	94,494	71,673	0,950
Pnömoni	99,967	99,650	100,000	99,963	99,824	1,000
Pnömotoraks	93,254	61,531	74,026	95,234	67,203	0,950
TB	99,890	100,000	98,571	100,000	99,281	1,000
Ortalama	96,620	82,092	81,915	98,087	81,769	0,973

Tablo 143. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %85,284

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,019	66,417	65,922	95,524	66,168	0,950
COVID-19	99,658	97,397	98,340	99,772	97,866	1,000
Fibröz	96,506	54,237	37,982	98,764	44,677	0,940
Akciğer Opasitesi	98,600	95,901	93,428	99,390	94,648	0,990
Normal	98,501	95,898	97,498	98,792	96,691	1,000
Plevral Efüzyon	91,755	69,956	74,268	94,675	72,048	0,950
Pnömoni	99,978	99,883	99,883	99,988	99,883	1,000
Pnömotoraks	93,618	65,581	66,588	96,401	66,081	0,950
TB	99,934	99,150	100,000	99,928	99,573	1,000
Ortalama	96,730	82,713	81,545	98,137	81,960	0,976

Tablo 144. Dinamik En Büyük Kayıp ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %93,973

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,402	66,297	55,680	96,199	60,526	0,940
COVID-19	99,570	99,138	95,436	99,928	97,252	1,000
Fibröz	95,470	42,026	57,864	96,920	48,689	0,950
Akciğer Opasitesi	98,247	93,860	92,845	99,072	93,350	0,990
Normal	98,170	94,957	97,007	98,507	95,971	1,000
Plevral Efüzyon	91,281	67,616	74,961	94,006	71,100	0,950
Pnömoni	99,967	99,766	99,883	99,976	99,824	1,000
Pnömotoraks	93,959	69,801	62,220	97,228	65,793	0,950
TB	99,879	99,855	98,571	99,988	99,209	1,000
Ortalama	96,438	81,480	81,607	97,981	81,302	0,976

Tablo 145. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %84,226

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,446	63,093	66,853	94,749	64,919	0,920
COVID-19	99,328	99,700	91,840	99,976	95,608	1,000
Fibröz	95,844	44,681	49,852	97,619	47,125	0,940
Akciğer Opasitesi	98,369	95,986	91,514	99,416	93,697	1,000
Normal	98,181	94,405	97,694	98,322	96,021	1,000
Plevral Efüzyon	91,920	71,747	71,803	95,279	71,775	0,930
Pnömoni	99,967	99,766	99,883	99,976	99,824	1,000
Pnömotoraks	93,541	66,456	62,220	96,766	64,268	0,930
TB	99,857	99,711	98,429	99,976	99,065	1,000
Ortalama	96,495	81,727	81,121	98,009	81,367	0,976

Tablo 146. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %84,557

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,777	66,599	61,266	95,874	63,822	0,950
COVID-19	99,702	98,199	98,064	99,844	98,131	1,000
Fibröz	96,120	47,541	43,027	98,168	45,171	0,950
Akciğer Opasitesi	98,413	97,064	90,765	99,581	93,809	1,000
Normal	98,402	94,752	98,332	98,422	96,509	1,000
Plevral Efüzyon	91,237	68,107	72,881	94,302	70,413	0,950
Pnömoni	99,967	99,766	99,883	99,976	99,824	1,000
Pnömotoraks	93,574	65,000	67,532	96,255	66,242	0,950
TB	99,923	99,856	99,143	99,988	99,498	1,000
Ortalama	96,568	81,876	81,210	98,046	81,491	0,976

Tablo 147. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %84,954

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	92,075	66,604	66,294	95,536	66,449	0,950
COVID-19	99,757	99,297	97,649	99,940	98,466	1,000
Fibröz	96,087	47,368	48,071	97,939	47,717	0,940
Akciğer Opasitesi	98,435	94,093	94,093	99,098	94,093	0,990
Normal	98,413	96,559	96,369	99,005	96,464	1,000
Plevral Efüzyon	91,325	67,855	74,807	94,083	71,162	0,950
Pnömoni	99,912	99,300	99,766	99,927	99,532	1,000
Pnömotoraks	94,004	70,725	61,039	97,398	65,526	0,950
TB	99,901	99,712	99,000	99,976	99,355	1,000
Ortalama	96,656	82,390	81,899	98,100	82,085	0,976

Tablo 148. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %86,034

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	92,350	68,130	66,480	95,824	67,295	0,952
COVID-19	99,813	99,164	98,479	99,928	98,820	1,000
Fibröz	96,550	54,651	41,840	98,661	47,395	0,940
Akciğer Opasitesi	98,832	96,599	94,509	99,492	95,542	0,995
Normal	98,732	96,382	98,037	98,934	97,203	0,998
Plevral Efüzyon	92,030	70,580	75,963	94,713	73,173	0,953
Pnömoni	99,945	99,533	99,883	99,951	99,707	1,000
Pnömotoraks	93,882	67,340	66,942	96,657	67,140	0,951
TB	99,934	99,290	99,857	99,940	99,573	1,000
Ortalama	96,896	83,519	82,443	98,233	82,872	0,977

Tablo 149. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %85,328

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,008	66,827	64,525	95,699	65,656	0,948
COVID-19	99,702	99,153	97,095	99,928	98,113	1,000
Fibröz	96,274	49,833	44,214	98,283	46,855	0,936
Akciğer Opasitesi	98,754	96,499	94,010	99,479	95,238	0,994
Normal	98,611	95,962	97,939	98,806	96,940	0,997
Plevral Efüzyon	91,733	69,516	75,193	94,494	72,243	0,950
Pnömoni	99,934	99,532	99,766	99,951	99,649	1,000
Pnömotoraks	93,706	66,912	64,463	96,717	65,664	0,948
TB	99,934	99,430	99,714	99,952	99,572	1,000
Ortalama	96,740	82,629	81,880	98,146	82,215	0,975

Tablo 150. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %85,736

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,251	67,785	65,829	95,799	66,793	0,952
COVID-19	99,769	99,022	98,064	99,916	98,541	1,000
Fibröz	96,473	53,114	43,027	98,535	47,541	0,940
Akciğer Opasitesi	98,810	96,752	94,176	99,517	95,447	0,995
Normal	98,666	96,148	97,988	98,863	97,060	0,998
Plevral Efüzyon	91,876	69,851	76,040	94,520	72,814	0,953
Pnömoni	99,945	99,533	99,883	99,951	99,707	1,000
Pnömotoraks	93,750	67,032	65,053	96,705	66,028	0,951
TB	99,934	99,430	99,714	99,952	99,572	1,000
Ortalama	96,830	83,185	82,197	98,195	82,611	0,976

Tablo 151. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %85,582

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,339	72,426	56,983	97,087	63,783	0,946
COVID-19	99,780	99,437	97,787	99,952	98,605	1,000
Fibröz	96,208	48,961	48,961	98,031	48,961	0,953
Akciğer Opasitesi	98,688	95,851	94,176	99,377	95,006	0,996
Normal	98,633	96,232	97,743	98,891	96,981	0,997
Plevral Efüzyon	91,843	69,620	76,271	94,443	72,794	0,957
Pnömoni	99,956	99,533	100,000	99,951	99,766	1,000
Pnömotoraks	93,805	64,890	73,318	95,915	68,847	0,956
TB	99,912	100,000	98,857	100,000	99,425	1,000
Ortalama	96,796	82,995	82,677	98,183	82,686	0,978

Tablo 152. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %84,888

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,097	72,340	53,818	97,237	61,719	0,942
COVID-19	99,780	99,577	97,649	99,964	98,603	1,000
Fibröz	95,933	45,580	48,961	97,745	47,210	0,949
Akciğer Opasitesi	98,622	95,674	93,844	99,352	94,750	0,995
Normal	98,545	95,994	97,596	98,820	96,788	0,997
Plevral Efüzyon	91,634	69,291	74,576	94,482	71,837	0,955
Pnömoni	99,967	99,650	100,000	99,963	99,824	1,000
Pnömotoraks	93,298	61,867	73,554	95,331	67,206	0,954
TB	99,901	100,000	98,714	100,000	99,353	1,000
Ortalama	96,642	82,219	82,079	98,099	81,921	0,977

Tablo 153. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %85,549

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,317	72,684	56,238	97,162	63,412	0,945
COVID-19	99,769	99,437	97,649	99,952	98,535	1,000
Fibröz	96,241	49,401	48,961	98,065	49,180	0,953
Akciğer Opasitesi	98,655	95,840	93,927	99,377	94,874	0,996
Normal	98,589	96,046	97,743	98,834	96,887	0,997
Plevral Efüzyon	91,909	69,859	76,425	94,494	72,995	0,957
Pnömoni	99,956	99,533	100,000	99,951	99,766	1,000
Pnömotoraks	93,750	64,344	74,144	95,769	68,897	0,956
TB	99,912	100,000	98,857	100,000	99,425	1,000
Ortalama	96,789	83,016	82,661	98,178	82,664	0,978

Tablo 154. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %86,078

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	92,339	67,694	67,505	95,674	67,599	0,949
COVID-19	99,791	99,577	97,787	99,964	98,674	1,000
Fibröz	96,263	49,697	48,665	98,100	49,175	0,958
Akciğer Opasitesi	98,743	96,978	93,428	99,555	95,169	0,997
Normal	98,666	95,839	98,332	98,763	97,070	0,998
Plevral Efüzyon	92,174	71,523	75,270	94,996	73,348	0,956
Pnömoni	99,956	99,649	99,883	99,963	99,766	1,000
Pnömotoraks	94,301	70,729	66,470	97,167	68,533	0,957
TB	99,923	99,856	99,143	99,988	99,498	1,000
Ortalama	96,906	83,505	82,942	98,241	83,204	0,979

Tablo 155. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %85,692

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	92,086	66,300	67,412	95,399	66,851	0,944
COVID-19	99,769	99,717	97,372	99,976	98,530	1,000
Fibröz	96,120	47,851	49,555	97,916	48,688	0,955
Akciğer Opasitesi	98,688	96,401	93,594	99,466	94,977	0,997
Normal	98,666	96,193	97,939	98,877	97,058	0,998
Plevral Efüzyon	92,086	71,168	75,116	94,919	73,088	0,953
Pnömoni	99,956	99,649	99,883	99,963	99,766	1,000
Pnömotoraks	94,114	70,458	63,636	97,252	66,873	0,953
TB	99,901	99,856	98,857	99,988	99,354	1,000
Ortalama	96,820	83,066	82,596	98,195	82,798	0,978

Tablo 156. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %86,089

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	92,295	67,474	67,412	95,636	67,443	0,949
COVID-19	99,802	99,718	97,787	99,976	98,743	1,000
Fibröz	96,252	49,544	48,368	98,100	48,949	0,957
Akciğer Opasitesi	98,776	97,066	93,594	99,568	95,299	0,997
Normal	98,710	95,935	98,430	98,792	97,166	0,998
Plevral Efüzyon	92,174	71,523	75,270	94,996	73,348	0,956
Pnömoni	99,956	99,649	99,883	99,963	99,766	1,000
Pnömotoraks	94,290	70,692	66,352	97,167	68,453	0,957
TB	99,923	99,856	99,143	99,988	99,498	1,000
Ortalama	96,909	83,495	82,915	98,243	83,185	0,979

EK 11: On Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları

Tablo 157. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %82,774

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,534	65,017	53,818	96,323	58,889	0,912
COVID-19	99,654	99,569	95,851	99,966	97,674	1,000
Kardiyomegali	96,590	63,419	69,348	97,972	66,251	0,954
Fibröz	96,370	48,598	46,291	98,206	47,416	0,923
Akciğer Opasitesi	98,468	96,397	91,265	99,508	93,761	0,996
Normal	98,416	94,907	97,841	98,572	96,352	0,997
Plevral Efüzyon	91,135	64,794	76,425	93,454	70,131	0,938
Pnömoni	99,948	99,533	99,883	99,954	99,707	1,000
Pnömotoraks	93,580	64,488	61,747	96,684	63,088	0,923
TB	99,853	100,000	98,000	100,000	98,990	1,000
Ortalama	96,555	79,672	79,047	98,064	79,226	0,964

Tablo 158. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %82,826

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,439	61,749	63,128	95,034	62,431	0,935
COVID-19	99,475	99,852	93,223	99,989	96,423	1,000
Kardiyomegali	96,548	62,620	70,652	97,862	66,394	0,958
Fibröz	95,541	39,320	48,071	97,281	43,258	0,926
Akciğer Opasitesi	98,458	93,559	94,260	99,064	93,908	0,992
Normal	98,563	95,807	97,547	98,839	96,669	0,996
Plevral Efüzyon	92,184	72,870	67,874	96,017	70,283	0,944
Pnömoni	99,906	99,070	99,883	99,908	99,475	1,000
Pnömotoraks	93,642	65,548	59,976	96,926	62,639	0,931
TB	99,895	99,427	99,143	99,955	99,285	1,000
Ortalama	96,565	78,982	79,376	98,087	79,076	0,968

Tablo 159. Ağırlıklandırılmış Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$, $w_{KH} = 0,2$)- Genel Doğruluk: %82,459

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,502	64,442	54,842	96,157	59,256	0,936
COVID-19	99,717	98,199	98,064	99,852	98,131	1,000
Kardiyomegali	95,825	55,167	71,957	97,035	62,453	0,968
Fibröz	96,181	46,041	46,588	97,999	46,313	0,945
Akciğer Opasitesi	98,468	95,913	91,764	99,436	93,793	0,994
Normal	98,395	94,988	97,645	98,599	96,298	0,997
Plevral Efüzyon	90,988	64,263	76,194	93,320	69,722	0,950
Pnömoni	99,948	99,649	99,766	99,965	99,707	1,000
Pnömotoraks	93,968	71,865	52,774	97,985	60,858	0,945
TB	99,927	99,856	99,143	99,989	99,498	1,000
Ortalama	96,492	79,038	78,873	98,034	78,603	0,973

Tablo 160. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %83,256

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,873	57,822	70,205	93,497	63,415	0,928
COVID-19	99,738	99,715	96,819	99,977	98,246	1,000
Kardiyomegali	96,412	63,470	60,435	98,236	61,915	0,952
Fibröz	96,758	57,143	33,234	99,086	42,026	0,907
Akciğer Opasitesi	98,552	96,914	91,431	99,580	94,092	0,996
Normal	98,584	95,116	98,430	98,626	96,745	0,997
Plevral Efüzyon	91,523	67,351	73,267	94,401	70,185	0,941
Pnömoni	99,937	99,417	99,883	99,942	99,649	1,000
Pnömotoraks	94,209	71,470	57,969	97,743	64,016	0,933
TB	99,927	100,000	99,000	100,000	99,497	1,000
Ortalama	96,651	80,842	78,067	98,109	78,979	0,965

Tablo 161. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %82,889

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,597	65,050	54,935	96,252	59,566	0,932
COVID-19	99,664	98,322	97,234	99,864	97,775	1,000
Kardiyomegali	96,790	71,508	55,652	98,876	62,592	0,954
Fibröz	95,992	43,516	44,807	97,868	44,152	0,941
Akciğer Opasitesi	98,468	97,059	90,599	99,604	93,718	0,993
Normal	98,363	94,178	98,430	98,345	96,257	0,997
Plevral Efüzyon	91,565	66,445	76,888	93,879	71,286	0,948
Pnömoni	99,916	99,300	99,766	99,931	99,532	1,000
Pnömotoraks	93,464	62,472	66,234	96,120	64,298	0,951
TB	99,958	100,000	99,429	100,000	99,713	1,000
Ortalama	96,578	79,785	78,397	98,074	78,889	0,972

Tablo 162. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %82,816

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,492	61,689	64,618	94,904	63,120	0,926
COVID-19	99,266	99,696	90,595	99,977	94,928	1,000
Kardiyomegali	96,213	59,252	68,913	97,597	63,719	0,949
Fibröz	96,402	48,936	40,950	98,434	44,588	0,920
Akciğer Opasitesi	98,552	95,783	92,596	99,412	94,162	0,996
Normal	98,510	94,886	98,332	98,559	96,578	0,997
Plevral Efüzyon	91,691	69,372	69,800	95,142	69,585	0,939
Pnömoni	99,927	99,648	99,531	99,965	99,589	1,000
Pnömotoraks	93,695	65,148	62,456	96,742	63,773	0,943
TB	99,885	100,000	98,429	100,000	99,208	1,000
Ortalama	96,563	79,441	78,622	98,073	78,925	0,967

Tablo 163. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %83,256

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,873	57,822	70,205	93,497	63,415	0,928
COVID-19	99,738	99,715	96,819	99,977	98,246	1,000
Kardiyomegali	96,412	63,470	60,435	98,236	61,915	0,952
Fibröz	96,758	57,143	33,234	99,086	42,026	0,907
Akciğer Opasitesi	98,552	96,914	91,431	99,580	94,092	0,996
Normal	98,584	95,116	98,430	98,626	96,745	0,997
Plevral Efüzyon	91,523	67,351	73,267	94,401	70,185	0,941
Pnömoni	99,937	99,417	99,883	99,942	99,649	1,000
Pnömotoraks	94,209	71,470	57,969	97,743	64,016	0,933
TB	99,927	100,000	99,000	100,000	99,497	1,000
Ortalama	96,651	80,842	78,067	98,109	78,979	0,965

Tablo 164. Dinamik En Büyük Kayıp ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %82,721

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,104	60,310	61,546	94,857	60,922	0,938
COVID-19	99,696	99,430	96,542	99,955	97,965	1,000
Kardiyomegali	96,695	66,979	62,174	98,446	64,487	0,965
Fibröz	96,632	53,810	33,531	98,945	41,316	0,945
Akciğer Opasitesi	98,563	97,502	90,932	99,664	94,102	0,995
Normal	98,416	94,068	98,822	98,305	96,387	0,998
Plevral Efüzyon	90,390	61,675	77,735	92,385	68,780	0,949
Pnömoni	99,927	99,532	99,648	99,954	99,590	1,000
Pnömotoraks	94,083	71,736	55,136	97,881	62,350	0,949
TB	99,937	100,000	99,143	100,000	99,570	1,000
Ortalama	96,544	80,504	77,521	98,039	78,547	0,974

Tablo 165. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %82,942

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,303	60,831	64,060	94,762	62,404	0,940
COVID-19	99,769	98,884	98,064	99,909	98,472	1,000
Kardiyomegali	96,695	67,990	59,565	98,578	63,499	0,970
Fibröz	96,412	49,049	38,279	98,543	43,000	0,940
Akciğer Opasitesi	98,689	97,697	91,764	99,688	94,637	1,000
Normal	98,605	94,993	98,675	98,586	96,799	1,000
Plevral Efüzyon	90,778	63,102	77,735	92,835	69,658	0,950
Pnömoni	99,906	99,647	99,297	99,965	99,472	1,000
Pnömotoraks	93,768	70,175	51,948	97,847	59,701	0,950
TB	99,958	100,000	99,429	100,000	99,713	1,000
Ortalama	96,588	80,237	77,881	98,071	78,736	0,975

Tablo 166. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %81,861

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,799	58,161	65,363	94,029	61,552	0,940
COVID-19	99,381	99,552	92,254	99,966	95,765	1,000
Kardiyomegali	96,758	72,404	53,043	98,975	61,230	0,969
Fibröz	95,919	41,156	35,905	98,119	38,352	0,940
Akciğer Opasitesi	98,290	95,292	90,932	99,352	93,061	0,997
Normal	98,300	94,120	98,184	98,332	96,110	0,998
Plevral Efüzyon	91,534	70,544	64,946	95,725	67,629	0,949
Pnömoni	99,969	100,000	99,648	100,000	99,824	1,000
Pnömotoraks	92,950	58,587	70,484	95,141	63,987	0,951
TB	99,822	99,709	97,857	99,977	98,774	1,000
Ortalama	96,372	78,953	76,862	97,962	77,628	0,974

Tablo 167. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %82,165

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,715	57,842	64,898	93,994	61,167	0,939
COVID-19	99,528	96,060	97,787	99,671	96,916	1,000
Kardiyomegali	96,674	68,193	58,261	98,622	62,837	0,968
Fibröz	96,611	53,977	28,190	99,119	37,037	0,945
Akciğer Opasitesi	98,164	94,847	90,349	99,292	92,544	0,993
Normal	98,227	94,101	97,841	98,332	95,935	0,997
Plevral Efüzyon	91,691	71,848	64,099	96,041	67,752	0,949
Pnömoni	99,874	99,881	98,710	99,988	99,292	1,000
Pnömotoraks	92,961	58,381	72,373	94,968	64,628	0,954
TB	99,885	98,727	99,714	99,898	99,218	1,000
Ortalama	96,433	79,386	77,222	97,993	77,733	0,975

Tablo 168. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %83,875

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,890	64,683	61,732	95,720	63,173	0,934
COVID-19	99,738	99,574	96,957	99,966	98,248	1,000
Kardiyomegali	96,643	65,217	65,217	98,236	65,217	0,956
Fibröz	96,507	50,699	43,027	98,467	46,549	0,940
Akciğer Opasitesi	98,699	97,364	92,180	99,640	94,701	0,995
Normal	98,594	94,863	98,773	98,546	96,779	0,998
Plevral Efüzyon	91,880	68,582	74,499	94,620	71,418	0,950
Pnömoni	99,937	99,417	99,883	99,942	99,649	1,000
Pnömotoraks	93,926	66,029	65,171	96,730	65,597	0,951
TB	99,937	100,000	99,143	100,000	99,570	1,000
Ortalama	96,775	80,643	79,658	98,187	80,090	0,972

Tablo 169. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %83,456

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,723	63,158	63,687	95,283	63,421	0,933
COVID-19	99,528	99,707	94,053	99,977	96,797	1,000
Kardiyomegali	96,444	61,702	69,348	97,817	65,302	0,955
Fibröz	96,527	51,064	42,730	98,499	46,527	0,938
Akciğer Opasitesi	98,668	96,699	92,596	99,544	94,603	0,995
Normal	98,573	94,943	98,577	98,572	96,726	0,998
Plevral Efüzyon	91,775	69,122	71,572	94,960	70,326	0,950
Pnömoni	99,937	99,532	99,766	99,954	99,649	1,000
Pnömotoraks	93,821	65,926	63,046	96,822	64,454	0,951
TB	99,916	100,000	98,857	100,000	99,425	1,000
Ortalama	96,691	80,185	79,423	98,143	79,723	0,972

Tablo 170. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Hinge + Kategorik Çapraz Entropi, Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %83,980

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,901	64,299	63,222	95,543	63,756	0,934
COVID-19	99,717	99,714	96,542	99,977	98,103	1,000
Kardiyomegali	96,601	64,167	66,957	98,104	65,532	0,956
Fibröz	96,569	51,773	43,323	98,521	47,173	0,939
Akciğer Opasitesi	98,752	97,293	92,679	99,628	94,930	0,995
Normal	98,615	94,995	98,724	98,586	96,824	0,998
Plevral Efüzyon	91,901	69,169	73,112	94,863	71,086	0,950
Pnömoni	99,937	99,417	99,883	99,942	99,649	1,000
Pnömotoraks	94,031	66,787	65,289	96,834	66,030	0,951
TB	99,937	100,000	99,143	100,000	99,570	1,000
Ortalama	96,796	80,761	79,887	98,200	80,265	0,972

Tablo 171. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %84,253

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,523	61,065	68,343	94,467	64,499	0,949
COVID-19	99,790	99,161	98,064	99,932	98,609	1,000
Kardiyomegali	97,094	74,016	61,304	98,909	67,063	0,974
Fibröz	96,674	54,425	36,499	98,880	43,694	0,949
Akciğer Opasitesi	98,689	97,697	91,764	99,688	94,637	0,997
Normal	98,647	95,045	98,822	98,599	96,897	0,998
Plevral Efüzyon	92,016	70,173	71,957	95,179	71,054	0,957
Pnömoni	99,979	99,883	99,883	99,988	99,883	1,000
Pnömotoraks	94,157	66,590	68,713	96,638	67,635	0,961
TB	99,937	99,430	99,714	99,955	99,572	1,000
Ortalama	96,851	81,748	79,506	98,223	80,354	0,979

Tablo 172. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %83,949

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,628	61,835	67,132	94,739	64,375	0,948
COVID-19	99,748	99,574	97,095	99,966	98,319	1,000
Kardiyomegali	96,937	72,460	58,913	98,865	64,988	0,973
Fibröz	96,517	50,923	40,950	98,554	45,395	0,946
Akciğer Opasitesi	98,689	97,195	92,263	99,616	94,665	0,997
Normal	98,626	95,040	98,724	98,599	96,847	0,998
Plevral Efüzyon	91,765	68,256	73,883	94,583	70,958	0,956
Pnömoni	99,958	99,882	99,648	99,988	99,765	1,000
Pnömotoraks	94,094	67,574	64,463	96,983	65,982	0,957
TB	99,937	100,000	99,143	100,000	99,570	1,000
Ortalama	96,790	81,274	79,221	98,189	80,086	0,977

Tablo 173. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %84,274

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,660	61,832	67,877	94,680	64,714	0,950
COVID-19	99,801	99,300	98,064	99,943	98,678	1,000
Kardiyomegali	97,052	73,368	61,087	98,876	66,667	0,974
Fibröz	96,674	54,167	38,576	98,804	45,061	0,949
Akciğer Opasitesi	98,710	97,701	91,930	99,688	94,728	0,997
Normal	98,647	95,045	98,822	98,599	96,897	0,998
Plevral Efüzyon	91,922	69,355	72,881	94,923	71,074	0,957
Pnömoni	99,979	99,883	99,883	99,988	99,883	1,000
Pnömotoraks	94,157	67,059	67,296	96,776	67,177	0,961
TB	99,948	99,714	99,571	99,977	99,643	1,000
Ortalama	96,855	81,742	79,599	98,225	80,452	0,979

EK 12: On İki Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları

Tablo 174. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %76,175

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,590	54,790	47,393	95,529	50,824	0,905
COVID-19	99,541	99,414	93,914	99,959	96,586	1,000
Kardiyomegali	96,274	57,576	57,826	98,042	57,701	0,949
Konsolidasyon	94,994	23,934	20,000	97,704	21,791	0,819
Ödem	95,080	56,422	43,082	98,080	48,858	0,930
Fibröz	96,131	39,759	39,169	98,026	39,462	0,921
Akciğer Opasitesi	98,510	95,009	91,847	99,374	93,401	0,997
Normal	98,653	95,579	97,596	98,909	96,577	0,998
Plevral Efüzyon	89,052	54,413	72,188	91,439	62,053	0,923
Pnömoni	99,933	99,301	99,883	99,938	99,591	1,000
Pnömotoraks	93,724	61,728	59,032	96,778	60,350	0,933
TB	99,866	99,855	98,143	99,990	98,991	1,000
Ortalama	96,029	69,815	68,339	97,814	68,849	0,948

Tablo 175. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %76,538

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,603	60,296	53,166	95,997	56,507	0,903
COVID-19	98,882	86,506	99,308	98,851	92,466	1,000
Kardiyomegali	95,711	50,947	64,348	97,152	56,868	0,935
Konsolidasyon	96,160	23,944	4,658	99,466	7,798	0,811
Ödem	95,147	58,015	39,930	98,333	47,303	0,899
Fibröz	96,609	46,087	31,454	98,776	37,390	0,893
Akciğer Opasitesi	98,777	96,696	92,512	99,590	94,558	0,992
Normal	98,223	96,626	94,161	99,205	95,378	0,996
Plevral Efüzyon	90,103	58,147	72,034	92,661	64,350	0,925
Pnömoni	99,933	99,416	99,766	99,948	99,590	1,000
Pnömotoraks	92,023	50,536	66,824	94,242	57,550	0,920
TB	99,904	99,569	99,000	99,969	99,284	0,999
Ortalama	96,090	68,899	68,097	97,849	67,420	0,939

Tablo 176. Ağırlıklandırılmış Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)- Genel Doğruluk: %76,614

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,409	53,081	56,145	94,326	54,570	0,921
COVID-19	99,599	99,419	94,744	99,959	97,025	1,000
Kardiyomegali	96,303	58,239	56,087	98,151	57,143	0,950
Konsolidasyon	95,462	28,846	20,548	98,169	24,000	0,850
Ödem	95,052	55,824	44,483	97,969	49,513	0,930
Fibröz	96,227	41,420	41,543	98,046	41,481	0,939
Akciğer Opasitesi	98,710	97,171	91,431	99,655	94,213	0,996
Normal	98,491	93,884	98,675	98,446	96,220	0,998
Plevral Efüzyon	89,845	57,849	66,718	93,119	61,968	0,926
Pnömoni	99,943	99,417	99,883	99,948	99,649	1,000
Pnömotoraks	93,265	58,617	57,025	96,456	57,810	0,929
TB	99,924	99,713	99,143	99,980	99,427	1,000
Ortalama	96,102	70,290	68,869	97,852	69,418	0,953

Tablo 177. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %77,503

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,498	59,331	54,469	95,731	56,796	0,927
COVID-19	99,694	98,868	96,680	99,918	97,762	1,000
Kardiyomegali	96,236	57,399	55,652	98,102	56,512	0,952
Konsolidasyon	95,577	30,242	20,548	98,288	24,470	0,865
Ödem	95,395	60,325	45,534	98,272	51,896	0,942
Fibröz	96,532	44,196	29,377	98,766	35,294	0,931
Akciğer Opasitesi	98,729	96,117	92,679	99,514	94,367	0,993
Normal	98,624	95,010	98,086	98,754	96,523	0,998
Plevral Efüzyon	90,304	59,465	68,490	93,391	63,659	0,932
Pnömoni	99,971	99,650	100,000	99,969	99,824	1,000
Pnömotoraks	92,539	52,973	69,421	94,574	60,092	0,943
TB	99,904	99,145	99,429	99,939	99,287	1,000
Ortalama	96,250	71,060	69,197	97,935	69,707	0,957

Tablo 178. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %76,700

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,164	58,476	47,858	96,115	52,637	0,913
COVID-19	99,713	98,462	97,372	99,887	97,914	1,000
Kardiyomegali	96,274	56,554	65,652	97,682	60,765	0,958
Konsolidasyon	94,660	22,905	22,466	97,268	22,683	0,858
Ödem	95,185	57,395	45,534	98,050	50,781	0,932
Fibröz	96,599	46,520	37,685	98,559	41,639	0,941
Akciğer Opasitesi	98,624	96,404	91,431	99,558	93,851	0,997
Normal	98,586	94,914	97,988	98,731	96,427	0,998
Plevral Efüzyon	90,036	58,691	66,333	93,391	62,278	0,927
Pnömoni	99,971	99,883	99,766	99,990	99,824	1,000
Pnömotoraks	92,644	53,854	63,518	95,208	58,288	0,935
TB	99,943	100,000	99,143	100,000	99,570	1,000
Ortalama	96,117	70,338	69,562	97,870	69,721	0,955

Tablo 179. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %76,700

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,164	58,476	47,858	96,115	52,637	0,910
COVID-19	99,713	98,462	97,372	99,887	97,914	1,000
Kardiyomegali	96,274	56,554	65,652	97,682	60,765	0,960
Konsolidasyon	94,660	22,905	22,466	97,268	22,683	0,860
Ödem	95,185	57,395	45,534	98,050	50,781	0,930
Fibröz	96,599	46,520	37,685	98,559	41,639	0,940
Akciğer Opasitesi	98,624	96,404	91,431	99,558	93,851	1,000
Normal	98,586	94,914	97,988	98,731	96,427	1,000
Plevral Efüzyon	90,036	58,691	66,333	93,391	62,278	0,930
Pnömoni	99,971	99,883	99,766	99,990	99,824	1,000
Pnömotoraks	92,644	53,854	63,518	95,208	58,288	0,930
TB	99,943	100,000	99,143	100,000	99,570	1,000
Ortalama	96,117	70,338	69,562	97,870	69,721	0,955

Tablo 180. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi + Kategorik Hing)-- Genel Doğruluk: %77,503

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,498	59,331	54,469	95,731	56,796	0,927
COVID-19	99,694	98,868	96,680	99,918	97,762	1,000
Kardiyomegali	96,236	57,399	55,652	98,102	56,512	0,952
Konsolidasyon	95,577	30,242	20,548	98,288	24,470	0,865
Ödem	95,395	60,325	45,534	98,272	51,896	0,942
Fibröz	96,532	44,196	29,377	98,766	35,294	0,931
Akciğer Opasitesi	98,729	96,117	92,679	99,514	94,367	0,993
Normal	98,624	95,010	98,086	98,754	96,523	0,998
Plevral Efüzyon	90,304	59,465	68,490	93,391	63,659	0,932
Pnömoni	99,971	99,650	100,000	99,969	99,824	1,000
Pnömotoraks	92,539	52,973	69,421	94,574	60,092	0,943
TB	99,904	99,145	99,429	99,939	99,287	1,000
Ortalama	96,250	71,060	69,197	97,935	69,707	0,957

Tablo 181. Dinamik En Büyük Kayıp ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %76,223

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,734	54,990	53,352	95,007	54,159	0,900
COVID-19	99,742	98,603	97,649	99,897	98,124	1,000
Kardiyomegali	95,911	52,827	65,000	97,332	58,285	0,949
Konsolidasyon	94,440	22,251	23,836	96,991	23,016	0,809
Ödem	94,669	51,150	50,613	97,211	50,880	0,922
Fibröz	96,351	42,215	36,202	98,352	38,978	0,934
Akciğer Opasitesi	98,481	97,280	89,268	99,676	93,102	0,997
Normal	98,519	94,642	97,939	98,660	96,262	0,997
Plevral Efüzyon	90,428	61,229	62,173	94,427	61,697	0,915
Pnömoni	99,933	99,416	99,766	99,948	99,590	1,000
Pnömotoraks	93,361	59,201	57,733	96,497	58,458	0,911
TB	99,876	100,000	98,143	100,000	99,063	1,000
Ortalama	96,037	69,484	69,306	97,833	69,301	0,944

Tablo 182. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %77,665

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,507	58,920	56,890	95,465	57,887	0,939
COVID-19	99,580	98,293	95,574	99,877	96,914	1,000
Kardiyomegali	96,399	58,317	63,261	97,922	60,688	0,966
Konsolidasyon	95,634	30,992	20,548	98,347	24,712	0,876
Ödem	95,367	57,818	55,692	97,656	56,735	0,957
Fibröz	96,456	44,371	39,763	98,342	41,941	0,953
Akciğer Opasitesi	98,596	97,480	90,100	99,698	93,645	0,997
Normal	98,424	93,619	98,626	98,375	96,057	0,998
Plevral Efüzyon	89,712	57,180	67,797	92,814	62,037	0,933
Pnömoni	99,981	99,766	100,000	99,979	99,883	1,000
Pnömotoraks	93,771	62,326	58,205	96,903	60,195	0,941
TB	99,904	99,855	98,714	99,990	99,282	1,000
Ortalama	96,278	71,578	70,431	97,947	70,831	0,963

Tablo 183. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %76,433

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,170	51,965	55,400	94,145	53,628	0,919
COVID-19	99,618	97,234	97,234	99,795	97,234	1,000
Kardiyomegali	95,883	52,429	68,043	97,162	59,224	0,960
Konsolidasyon	95,577	28,696	18,082	98,377	22,185	0,877
Ödem	95,147	57,482	42,382	98,191	48,790	0,945
Fibröz	96,637	47,232	37,982	98,588	42,105	0,945
Akciğer Opasitesi	98,147	96,154	87,354	99,547	91,543	0,993
Normal	97,994	91,965	98,283	97,924	95,019	0,997
Plevral Efüzyon	90,409	60,426	65,639	93,915	62,925	0,932
Pnömoni	99,962	99,882	99,648	99,990	99,765	1,000
Pnömotoraks	93,418	59,338	59,268	96,424	59,303	0,942
TB	99,904	99,006	99,571	99,928	99,288	1,000
Ortalama	96,072	70,151	69,074	97,832	69,251	0,959

Tablo 184. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %77,598

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,240	57,842	53,911	95,508	55,807	0,926
COVID-19	99,752	99,154	97,234	99,938	98,184	1,000
Kardiyomegali	96,599	62,381	56,957	98,421	59,545	0,960
Konsolidasyon	95,338	27,798	21,096	98,020	23,988	0,865
Ödem	94,937	53,920	49,387	97,565	51,554	0,946
Fibröz	96,723	48,585	30,564	98,924	37,523	0,938
Akciğer Opasitesi	98,863	95,929	94,093	99,482	95,002	0,997
Normal	98,873	96,154	98,135	99,051	97,135	0,998
Plevral Efüzyon	89,387	55,698	70,416	92,072	62,198	0,931
Pnömoni	99,962	99,649	99,883	99,969	99,766	1,000
Pnömotoraks	93,609	60,206	61,983	96,393	61,082	0,946
TB	99,914	99,428	99,286	99,959	99,357	1,000
Ortalama	96,266	71,395	69,412	97,942	70,095	0,959

Tablo 185. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %79,394

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,488	58,296	59,870	95,103	59,072	0,939
COVID-19	99,818	99,162	98,202	99,938	98,680	1,000
Kardiyomegali	96,580	60,159	65,652	98,002	62,786	0,968
Konsolidasyon	95,892	33,831	18,630	98,684	24,028	0,890
Ödem	95,711	62,398	53,765	98,131	57,761	0,960
Fibröz	96,781	50,000	37,685	98,746	42,978	0,956
Akciğer Opasitesi	98,825	97,956	91,681	99,752	94,714	0,997
Normal	98,749	94,828	98,970	98,695	96,855	0,998
Plevral Efüzyon	90,648	60,140	72,881	93,162	65,900	0,942
Pnömoni	99,981	99,883	99,883	99,990	99,883	1,000
Pnömotoraks	94,354	65,534	63,754	97,048	64,632	0,954
TB	99,962	99,857	99,571	99,990	99,714	1,000
Ortalama	96,566	73,504	71,712	98,103	72,250	0,967

Tablo 186. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %78,888

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,880	60,526	59,963	95,529	60,243	0,935
COVID-19	99,723	99,150	96,819	99,938	97,971	1,000
Kardiyomegali	96,599	61,354	61,087	98,231	61,220	0,967
Konsolidasyon	95,711	30,000	17,260	98,545	21,913	0,886
Ödem	95,520	59,551	55,692	97,818	57,557	0,960
Fibröz	96,714	48,583	35,608	98,746	41,096	0,954
Akciğer Opasitesi	98,873	97,461	92,596	99,687	94,966	0,998
Normal	98,796	95,137	98,871	98,778	96,968	0,999
Plevral Efüzyon	90,113	58,082	72,804	92,563	64,615	0,939
Pnömoni	99,971	99,766	99,883	99,979	99,824	1,000
Pnömotoraks	93,934	63,086	60,331	96,892	61,678	0,950
TB	99,943	99,713	99,429	99,980	99,571	1,000
Ortalama	96,481	72,701	70,862	98,057	71,468	0,966

Tablo 187. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %79,404

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,593	58,850	60,056	95,199	59,447	0,936
COVID-19	99,828	99,163	98,340	99,938	98,750	1,000
Kardiyomegali	96,628	60,765	65,652	98,052	63,114	0,969
Konsolidasyon	95,883	33,500	18,356	98,684	23,717	0,890
Ödem	95,701	62,222	53,940	98,111	57,786	0,960
Fibröz	96,771	49,801	37,092	98,756	42,517	0,956
Akciğer Opasitesi	98,844	98,044	91,764	99,763	94,800	0,997
Normal	98,768	94,918	98,970	98,719	96,901	0,998
Plevral Efüzyon	90,562	59,773	73,035	93,043	65,742	0,942
Pnömoni	99,981	99,883	99,883	99,990	99,883	1,000
Pnömotoraks	94,287	65,091	63,400	97,007	64,234	0,954
TB	99,962	99,857	99,571	99,990	99,714	1,000
Ortalama	96,567	73,489	71,672	98,104	72,217	0,967

EK 13: On Dört Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları

Tablo 188. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %74,543

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	88,632	50,301	54,376	93,058	52,260	0,913
COVID-19	99,433	99,699	91,563	99,981	95,458	1,000
Kardiyomegali	96,147	53,089	59,783	97,718	56,237	0,952
Konsolidasyon	94,356	21,145	26,301	96,668	23,443	0,856
Ödem	95,355	55,064	52,364	97,685	53,680	0,952
Fibröz	96,309	38,486	36,202	98,190	37,309	0,930
Kosta Kırığı	98,110	53,398	49,107	99,118	51,163	0,970
Akciğer Opasitesi	98,767	93,469	95,258	99,192	94,355	0,997
Kitle	96,948	60,822	53,110	98,662	56,705	0,948
Normal	98,758	96,387	96,860	99,184	96,623	0,998
Plevral Efüzyon	90,836	61,236	58,783	95,077	59,984	0,924
Pnömoni	99,982	99,883	99,883	99,990	99,883	1,000
Pnömotoraks	93,703	61,352	56,789	96,901	58,982	0,934
TB	99,712	96,006	99,571	99,721	97,756	1,000
Ortalama	96,218	67,167	66,425	97,939	66,703	0,955

Tablo 189. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %74,149

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	89,902	58,075	48,883	95,330	53,084	0,900
COVID-19	99,613	95,093	99,170	99,644	97,089	0,999
Kardiyomegali	96,463	56,430	63,913	97,869	59,939	0,936
Konsolidasyon	95,725	15,625	6,849	98,744	9,524	0,814
Ödem	95,257	53,860	53,765	97,505	53,812	0,908
Fibröz	96,895	46,552	16,024	99,424	23,841	0,858
Kosta Kırığı	96,823	33,835	60,268	97,575	43,339	0,931
Akciğer Opasitesi	98,902	96,392	93,344	99,576	94,844	0,984
Kitle	95,338	41,667	59,809	96,727	49,116	0,912
Normal	98,767	96,388	96,909	99,184	96,648	0,995
Plevral Efüzyon	90,864	61,275	59,245	95,047	60,243	0,908
Pnömoni	99,874	98,385	100,000	99,864	99,186	1,000
Pnömotoraks	91,863	49,340	61,747	94,483	54,851	0,914
TB	99,883	99,711	98,429	99,981	99,065	0,999
Ortalama	96,155	64,473	65,597	97,925	63,899	0,933

Tablo 190. Ağırlıklandırılmış Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$) - Genel Doğruluk: %74,239

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	88,402	49,610	53,352	92,957	51,413	0,910
COVID-19	99,703	99,006	96,404	99,933	97,687	1,000
Kardiyomegali	96,490	57,743	56,739	98,207	57,237	0,950
Konsolidasyon	95,356	24,407	19,726	97,925	21,818	0,831
Ödem	95,266	54,144	51,489	97,637	52,783	0,936
Fibröz	96,157	37,143	38,576	97,958	37,846	0,937
Kosta Kırığı	97,750	45,000	52,232	98,686	48,347	0,963
Akciğer Opasitesi	98,749	97,498	90,765	99,717	94,011	0,996
Kitle	96,850	61,409	43,780	98,924	51,117	0,946
Normal	98,623	93,980	98,822	98,578	96,341	0,998
Plevral Efüzyon	90,423	58,628	61,248	94,283	59,910	0,919
Pnömoni	99,964	99,882	99,648	99,990	99,765	1,000
Pnömotoraks	92,702	54,009	57,261	95,774	55,587	0,923
TB	99,874	100,000	98,000	100,000	98,990	1,000
Ortalama	96,165	66,604	65,574	97,898	65,918	0,951

Tablo 191. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %74,410

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	87,519	46,589	59,777	91,115	52,365	0,913
COVID-19	99,127	99,683	86,860	99,981	92,831	1,000
Kardiyomegali	96,463	57,737	54,348	98,282	55,991	0,947
Konsolidasyon	95,680	26,531	17,808	98,325	21,311	0,851
Ödem	95,311	54,112	57,618	97,353	55,810	0,948
Fibröz	96,598	41,423	29,377	98,700	34,375	0,917
Kosta Kırığı	98,074	52,809	41,964	99,228	46,766	0,953
Akciğer Opasitesi	98,650	93,615	93,927	99,223	93,771	0,995
Kitle	97,165	68,727	45,215	99,196	54,545	0,943
Normal	98,353	93,895	97,350	98,578	95,591	0,997
Plevral Efüzyon	90,675	59,718	62,018	94,466	60,847	0,923
Pnömoni	99,937	99,532	99,648	99,961	99,590	1,000
Pnömotoraks	93,188	57,046	59,740	96,093	58,362	0,935
TB	99,802	97,346	99,571	99,817	98,446	1,000
Ortalama	96,181	67,769	64,659	97,880	65,757	0,951

Tablo 192. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %73,627

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	89,490	57,300	38,734	96,190	46,222	0,897
COVID-19	99,604	99,132	94,744	99,942	96,888	1,000
Kardiyomegali	96,148	52,787	65,870	97,455	58,607	0,956
Konsolidasyon	93,672	19,713	30,137	95,831	23,835	0,846
Ödem	95,275	55,476	40,806	98,226	47,023	0,929
Fibröz	96,274	38,438	37,982	98,097	38,209	0,925
Kosta Kırığı	97,894	47,807	48,661	98,907	48,230	0,961
Akciğer Opasitesi	98,812	95,805	93,095	99,505	94,430	0,997
Kitle	96,346	51,376	53,589	98,017	52,459	0,941
Normal	98,794	95,550	97,988	98,975	96,754	0,998
Plevral Efüzyon	90,684	60,202	59,784	94,772	59,992	0,919
Pnömoni	99,964	99,649	99,883	99,971	99,766	1,000
Pnömotoraks	92,186	51,005	62,928	94,735	56,342	0,933
TB	99,937	99,713	99,286	99,981	99,499	1,000
Ortalama	96,077	65,997	65,963	97,900	65,590	0,950

Tablo 193. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %74,797

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	89,081	53,040	47,114	94,557	49,901	0,904
COVID-19	99,784	99,434	97,234	99,961	98,322	1,000
Kardiyomegali	96,040	51,838	61,304	97,540	56,175	0,944
Konsolidasyon	95,347	22,857	17,534	97,990	19,845	0,837
Ödem	95,185	53,226	52,014	97,523	52,613	0,933
Fibröz	96,607	42,481	33,531	98,580	37,479	0,916
Kosta Kırığı	98,056	51,980	46,875	99,109	49,296	0,950
Akciğer Opasitesi	98,866	96,141	93,261	99,546	94,679	0,995
Kitle	96,472	53,299	50,239	98,279	51,724	0,938
Normal	98,812	95,468	98,184	98,953	96,807	0,998
Plevral Efüzyon	90,450	58,235	64,561	93,875	61,235	0,921
Pnömoni	99,955	99,417	100,000	99,951	99,708	1,000
Pnömotoraks	92,928	55,183	62,220	95,601	58,491	0,929
TB	99,901	99,855	98,571	99,990	99,209	1,000
Ortalama	96,249	66,604	65,903	97,961	66,106	0,947

Tablo 194. Dinamik En Büyük Kayıp ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %73,978

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	89,460	55,904	49,814	94,754	52,683	0,908
COVID-19	99,298	99,539	89,627	99,971	94,323	0,999
Kardiyomegali	96,562	58,864	56,304	98,300	57,556	0,944
Konsolidasyon	96,283	30,000	9,863	99,218	14,845	0,806
Ödem	94,428	46,809	61,646	96,205	53,212	0,938
Fibröz	96,328	38,284	34,421	98,264	36,250	0,925
Kosta Kırığı	97,903	47,739	42,411	99,045	44,917	0,961
Akciğer Opasitesi	98,434	94,696	90,599	99,384	92,602	0,995
Kitle	96,454	52,804	54,067	98,111	53,428	0,936
Normal	98,335	93,234	98,037	98,402	95,575	0,998
Plevral Efüzyon	90,909	62,081	57,011	95,393	59,438	0,913
Pnömoni	99,982	99,766	100,000	99,981	99,883	1,000
Pnömotoraks	91,368	47,522	69,067	93,321	56,304	0,930
TB	99,865	99,710	98,143	99,981	98,920	1,000
Ortalama	96,115	66,211	65,072	97,881	64,996	0,946

Tablo 195. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %74,563

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	87,585	46,689	63,687	90,656	53,879	0,918
COVID-19	99,649	99,138	95,436	99,942	97,252	0,999
Kardiyomegali	96,472	58,586	50,435	98,460	54,206	0,956
Konsolidasyon	95,500	24,335	17,534	98,148	20,382	0,866
Ödem	95,473	55,822	57,093	97,552	56,450	0,947
Fibröz	97,138	59,223	18,101	99,610	27,727	0,933
Kosta Kırığı	97,705	44,322	54,018	98,604	48,692	0,974
Akciğer Opasitesi	98,659	96,225	91,181	99,566	93,635	0,997
Kitle	96,076	48,185	57,177	97,596	52,298	0,952
Normal	98,560	94,292	98,086	98,666	96,152	0,998
Plevral Efüzyon	90,909	61,429	59,630	95,047	60,516	0,923
Pnömoni	99,937	99,532	99,648	99,961	99,590	1,000
Pnömotoraks	93,447	59,868	53,365	96,910	56,429	0,929
TB	99,874	98,584	99,429	99,904	99,004	1,000
Ortalama	96,213	67,588	65,344	97,902	65,444	0,957

Tablo 196. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %73,951

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	89,603	55,763	44,600	95,424	49,560	0,903
COVID-19	99,694	98,590	96,680	99,904	97,626	1,000
Kardiyomegali	96,499	57,871	56,739	98,216	57,300	0,946
Konsolidasyon	96,004	29,534	15,616	98,734	20,430	0,823
Ödem	94,959	50,987	49,737	97,410	50,355	0,922
Fibröz	96,130	35,866	35,015	98,041	35,435	0,930
Kosta Kırığı	97,741	44,828	52,232	98,677	48,247	0,957
Akciğer Opasitesi	98,776	95,478	93,095	99,465	94,271	0,997
Kitle	96,301	50,886	48,086	98,186	49,446	0,939
Normal	98,749	95,981	97,252	99,085	96,612	0,998
Plevral Efüzyon	88,713	51,213	71,572	90,980	59,704	0,920
Pnömoni	99,901	99,297	99,414	99,942	99,356	1,000
Pnömotoraks	93,073	57,050	51,594	96,650	54,185	0,917
TB	99,865	100,000	97,857	100,000	98,917	1,000
Ortalama	96,143	65,953	64,964	97,908	65,103	0,947

Tablo 197. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %73,780

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	89,331	55,599	39,292	95,888	46,045	0,908
COVID-19	99,631	96,585	97,787	99,759	97,182	1,000
Kardiyomegali	96,670	61,364	52,826	98,563	56,776	0,955
Konsolidasyon	94,851	15,842	13,151	97,627	14,371	0,834
Ödem	94,356	46,447	64,098	95,996	53,863	0,945
Fibröz	96,805	46,087	31,454	98,849	37,390	0,938
Kosta Kırığı	98,056	52,273	41,071	99,228	46,000	0,957
Akciğer Opasitesi	98,713	97,319	90,599	99,697	93,839	0,997
Kitle	96,760	59,864	42,105	98,896	49,438	0,946
Normal	98,605	94,264	98,381	98,655	96,279	0,998
Plevral Efüzyon	89,361	53,541	67,565	92,244	59,741	0,920
Pnömoni	99,955	99,765	99,648	99,981	99,707	1,000
Pnömotoraks	92,471	52,522	62,692	95,065	57,158	0,933
TB	99,865	100,000	97,857	100,000	98,917	1,000
Ortalama	96,102	66,534	64,181	97,889	64,765	0,952

Tablo 198. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %75,554

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	88,518	50,000	55,773	92,766	52,729	0,914
COVID-19	99,667	99,710	95,159	99,981	97,381	1,000
Kardiyomegali	96,319	55,280	58,043	97,972	56,628	0,951
Konsolidasyon	95,635	24,790	16,164	98,334	19,569	0,852
Ödem	95,239	53,547	55,517	97,391	54,514	0,947
Fibröz	96,643	42,857	32,047	98,663	36,672	0,925
Kosta Kırığı	98,119	53,968	45,536	99,201	49,395	0,958
Akciğer Opasitesi	98,965	96,255	94,093	99,556	95,162	0,996
Kitle	97,120	65,313	50,000	98,962	56,640	0,946
Normal	98,821	95,557	98,135	98,975	96,829	0,998
Plevral Efüzyon	90,684	59,346	64,330	94,170	61,738	0,927
Pnömoni	99,964	99,533	100,000	99,961	99,766	1,000
Pnömotoraks	93,381	58,068	62,456	96,073	60,182	0,936
TB	99,901	98,865	99,571	99,923	99,217	1,000
Ortalama	96,355	68,078	66,202	97,995	66,887	0,954

Tablo 199. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %74,797

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	89,070	52,984	47,114	94,545	49,877	0,904
COVID-19	99,784	99,434	97,234	99,961	98,322	1,000
Kardiyomegali	96,049	51,934	61,304	97,549	56,231	0,944
Konsolidasyon	95,347	22,857	17,534	97,990	19,845	0,837
Ödem	95,185	53,226	52,014	97,523	52,613	0,933
Fibröz	96,607	42,481	33,531	98,580	37,479	0,916
Kosta Kırığı	98,056	51,980	46,875	99,109	49,296	0,950
Akciğer Opasitesi	98,866	96,141	93,261	99,546	94,679	0,995
Kitle	96,472	53,299	50,239	98,279	51,724	0,938
Normal	98,812	95,468	98,184	98,953	96,807	0,998
Plevral Efüzyon	90,450	58,235	64,561	93,875	61,235	0,921
Pnömoni	99,955	99,417	100,000	99,951	99,708	1,000
Pnömotoraks	92,928	55,183	62,220	95,601	58,491	0,929
TB	99,901	99,855	98,571	99,990	99,209	1,000
Ortalama	96,249	66,607	65,903	97,961	66,108	0,947

Tablo 200. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %75,671

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	88,935	51,799	53,631	93,520	52,699	0,913
COVID-19	99,739	99,571	96,404	99,971	97,962	1,000
Kardiyomegali	96,301	54,832	60,435	97,850	57,497	0,951
Konsolidasyon	95,527	24,016	16,712	98,204	19,709	0,851
Ödem	95,275	54,021	54,116	97,505	54,068	0,947
Fibröz	96,661	43,462	33,531	98,635	37,856	0,925
Kosta Kırığı	98,101	53,333	46,429	99,164	49,642	0,957
Akciğer Opasitesi	98,920	96,082	93,844	99,536	94,949	0,996
Kitle	96,958	61,561	50,957	98,756	55,759	0,946
Normal	98,821	95,600	98,086	98,986	96,827	0,998
Plevral Efüzyon	90,747	59,480	65,254	94,119	62,234	0,927
Pnömoni	99,964	99,533	100,000	99,961	99,766	1,000
Pnömotoraks	93,377	57,980	63,046	96,020	60,407	0,936
TB	99,937	99,713	99,286	99,981	99,499	1,000
Ortalama	96,376	67,927	66,552	98,015	67,063	0,953

Tablo 201. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %76,877

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,017	56,279	57,169	94,261	56,721	0,923
COVID-19	99,811	99,160	97,925	99,942	98,539	1,000
Kardiyomegali	96,787	62,005	57,826	98,469	59,843	0,964
Konsolidasyon	96,103	31,720	16,164	98,818	21,416	0,864
Ödem	95,437	55,212	59,370	97,391	57,215	0,955
Fibröz	97,021	51,531	29,970	99,118	37,899	0,942
Kosta Kırığı	97,939	49,020	55,804	98,806	52,192	0,970
Akciğer Opasitesi	98,992	97,309	93,261	99,687	95,242	0,998
Kitle	96,652	55,693	53,828	98,326	54,745	0,959
Normal	98,911	95,665	98,528	98,997	97,075	0,999
Plevral Efüzyon	90,630	58,077	71,186	93,202	63,967	0,935
Pnömoni	99,973	99,766	99,883	99,981	99,824	1,000
Pnömotoraks	93,716	60,890	59,740	96,667	60,310	0,944
TB	99,928	99,856	99,000	99,990	99,426	1,000
Ortalama	96,565	69,441	67,833	98,118	68,172	0,961

Tablo 202. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %75,293

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	89,758	55,726	50,745	94,795	53,119	0,921
COVID-19	99,811	99,437	97,649	99,961	98,535	1,000
Kardiyomegali	96,715	60,870	57,826	98,394	59,309	0,961
Konsolidasyon	96,166	33,333	16,712	98,865	22,263	0,862
Ödem	95,212	53,464	52,715	97,514	53,086	0,950
Fibröz	96,589	41,797	31,751	98,617	36,088	0,940
Kosta Kırığı	97,732	44,737	53,125	98,650	48,571	0,969
Akciğer Opasitesi	98,947	96,487	93,677	99,586	95,061	0,998
Kitle	96,328	51,185	51,675	98,073	51,429	0,957
Normal	98,893	96,012	98,037	99,085	97,014	0,999
Plevral Efüzyon	89,388	53,425	71,495	91,755	61,153	0,931
Pnömoni	99,937	99,648	99,531	99,971	99,589	1,000
Pnömotoraks	93,344	58,984	53,483	96,787	56,099	0,939
TB	99,910	100,000	98,571	100,000	99,281	1,000
Ortalama	96,338	67,507	66,214	98,004	66,471	0,959

Tablo 203. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %76,841

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,086	56,602	57,076	94,349	56,838	0,923
COVID-19	99,820	99,299	97,925	99,952	98,607	1,000
Kardiyomegali	96,760	61,792	56,957	98,479	59,276	0,964
Konsolidasyon	96,148	32,597	16,164	98,865	21,612	0,864
Ödem	95,410	54,992	58,844	97,391	56,853	0,954
Fibröz	97,003	50,990	30,564	99,081	38,219	0,942
Kosta Kırığı	97,921	48,627	55,357	98,797	51,775	0,970
Akciğer Opasitesi	99,010	97,314	93,428	99,687	95,331	0,998
Kitle	96,634	55,392	54,067	98,298	54,722	0,959
Normal	98,911	95,665	98,528	98,997	97,075	0,999
Plevral Efüzyon	90,486	57,480	71,341	93,019	63,664	0,935
Pnömoni	99,973	99,766	99,883	99,981	99,824	1,000
Pnömotoraks	93,764	61,314	59,504	96,739	60,395	0,944
TB	99,937	100,000	99,000	100,000	99,497	1,000
Ortalama	96,562	69,416	67,760	98,117	68,121	0,961

EK 14: On Beş Sınıf için Önerilen Kayıp Fonksiyonları Test Sonuçları

Tablo 204. Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %71,366

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,532	48,330	43,110	95,334	45,571	0,894
COVID-19	99,846	99,718	97,787	99,982	98,743	1,000
Kardiyomegali	96,653	58,118	53,696	98,414	55,819	0,948
Konsolidasyon	92,433	14,694	29,589	94,460	19,636	0,821
Ödem	95,386	52,797	52,890	97,570	52,843	0,939
Fibröz	96,345	36,686	36,795	98,114	36,741	0,924
Kosta Kırığı	97,860	45,324	56,250	98,673	50,199	0,967
İnfiltrasyon	93,580	37,535	46,853	95,986	41,680	0,896
Akciğer Opasitesi	98,921	94,908	94,592	99,418	94,750	0,998
Kitle	96,970	62,214	38,995	99,121	47,941	0,937
Normal	98,947	96,594	97,399	99,274	96,995	0,999
Plevral Efüzyon	91,337	62,306	55,778	95,782	58,862	0,918
Pnömoni	99,961	99,649	99,883	99,969	99,766	1,000
Pnömotoraks	94,008	60,110	51,594	97,323	55,527	0,925
TB	99,949	100,000	99,143	100,000	99,570	1,000
Ortalama	96,182	64,599	63,624	97,961	63,643	0,944

Tablo 205. Kategorik Hinge Test Sonuçları- Genel Doğruluk: %74,854

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,269	53,000	44,413	96,012	48,328	0,886
COVID-19	99,623	99,707	94,191	99,982	96,871	0,998
Kardiyomegali	96,559	56,905	51,957	98,387	54,318	0,926
Konsolidasyon	96,747	22,222	1,644	99,814	3,061	0,805
Ödem	95,455	53,497	53,590	97,606	53,543	0,916
Fibröz	96,037	29,677	27,300	98,078	28,439	0,867
Kosta Kırığı	97,937	46,188	45,982	98,953	46,085	0,912
İnfiltrasyon	93,100	35,697	51,049	95,266	42,014	0,906
Akciğer Opasitesi	98,913	94,094	95,424	99,313	94,754	0,991
Kitle	96,396	49,604	44,976	98,304	47,177	0,909
Normal	98,939	96,592	97,350	99,274	96,970	0,994
Plevral Efüzyon	91,174	60,277	60,324	95,031	60,300	0,911
Pnömoni	99,865	98,385	100,000	99,853	99,186	1,000
Pnömotoraks	91,748	45,177	64,699	93,862	53,204	0,905
TB	99,932	99,570	99,286	99,973	99,428	1,000
Ortalama	96,246	62,706	62,146	97,981	61,579	0,928

Tablo 206. Ağırlıklandırılmış Hibrit Kayıp Fonksiyonu Test Sonuçları ($w_{KCE} = 0,8$ ve $w_{KH} = 0,2$)- Genel Doğruluk: %71,118

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,063	51,908	37,989	96,437	43,871	0,909
COVID-19	99,640	97,622	96,542	99,845	97,079	1,000
Kardiyomegali	96,773	64,360	40,435	99,082	49,666	0,961
Konsolidasyon	96,054	23,333	11,507	98,781	15,413	0,851
Ödem	95,669	56,930	46,760	98,182	51,346	0,953
Fibröz	95,788	31,325	38,576	97,488	34,574	0,930
Kosta Kırığı	98,048	48,958	41,964	99,145	45,192	0,977
İnfiltrasyon	94,342	41,588	38,462	97,219	39,964	0,920
Akciğer Opasitesi	98,956	95,302	94,509	99,466	94,904	0,998
Kitle	96,054	45,549	52,632	97,665	48,835	0,941
Normal	98,870	96,397	97,154	99,233	96,774	0,999
Plevral Efüzyon	87,408	46,081	78,351	88,540	58,031	0,928
Pnömoni	99,904	98,955	99,883	99,906	99,417	1,000
Pnömotoraks	93,700	59,113	42,503	97,702	49,451	0,926
TB	99,957	99,572	99,714	99,973	99,643	1,000
Ortalama	96,148	63,800	61,132	97,911	61,611	0,953

Tablo 207. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %72,137

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,575	48,665	45,810	95,107	47,194	0,893
COVID-19	99,820	99,437	97,649	99,964	98,535	1,000
Kardiyomegali	96,379	54,273	51,087	98,236	52,632	0,939
Konsolidasyon	95,309	21,317	18,630	97,782	19,883	0,819
Ödem	95,763	58,190	47,285	98,254	52,174	0,926
Fibröz	96,345	35,484	32,641	98,237	34,003	0,906
Kosta Kırığı	98,023	48,548	52,232	98,918	50,323	0,965
İnfiltrasyon	93,691	38,494	48,252	96,031	42,824	0,899
Akciğer Opasitesi	98,861	94,653	94,260	99,389	94,456	0,996
Kitle	96,884	59,507	40,431	98,979	48,148	0,928
Normal	98,913	96,496	97,301	99,253	96,897	0,998
Plevral Efüzyon	90,276	55,525	62,712	93,721	58,900	0,918
Pnömoni	99,942	99,417	99,883	99,948	99,649	1,000
Pnömotoraks	93,537	55,000	59,740	96,179	57,272	0,928
TB	99,949	99,713	99,429	99,982	99,571	1,000
Ortalama	96,284	64,314	63,156	97,999	63,497	0,941

Tablo 208. Dinamik Kayıp Fonksiyonu Test Sonuçları (Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %71,5631

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,772	49,767	39,851	95,928	44,261	0,893
COVID-19	99,726	97,655	97,925	99,845	97,790	1,000
Kardiyomegali	96,619	59,878	42,826	98,824	49,937	0,938
Konsolidasyon	95,215	21,302	19,726	97,650	20,484	0,832
Ödem	95,489	54,198	49,737	97,840	51,872	0,932
Fibröz	97,107	49,677	22,849	99,312	31,301	0,921
Kosta Kırığı	98,065	49,485	42,857	99,145	45,933	0,962
İnfiltrasyon	93,315	37,146	52,797	95,401	43,610	0,912
Akciğer Opasitesi	98,827	95,319	93,178	99,475	94,236	0,995
Kitle	97,072	64,961	39,474	99,210	49,107	0,936
Normal	98,767	95,705	97,301	99,077	96,496	0,997
Plevral Efüzyon	89,240	51,168	69,183	91,747	58,827	0,917
Pnömoni	99,961	99,649	99,883	99,969	99,766	1,000
Pnömotoraks	93,015	51,658	57,025	95,828	54,209	0,916
TB	99,932	99,570	99,286	99,973	99,428	1,000
Ortalama	96,208	65,143	61,593	97,948	62,484	0,943

Tablo 209. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %71,007

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,284	46,759	40,968	95,277	43,672	0,861
COVID-19	99,290	100,000	88,520	100,000	93,910	1,000
Kardiyomegali	96,525	56,429	51,522	98,369	53,864	0,932
Konsolidasyon	94,025	16,090	21,644	96,359	18,458	0,774
Ödem	95,592	55,490	49,562	97,957	52,359	0,923
Fibröz	95,977	33,079	38,576	97,682	35,616	0,881
Kosta Kırığı	98,031	48,750	52,232	98,927	50,431	0,956
İnfiltrasyon	93,169	35,476	48,252	95,482	40,889	0,881
Akciğer Opasitesi	98,682	95,724	91,265	99,532	93,441	0,996
Kitle	97,115	63,918	44,498	99,068	52,468	0,908
Normal	98,553	93,689	98,332	98,600	95,954	0,998
Plevral Efüzyon	90,986	58,769	63,251	94,453	60,928	0,908
Pnömoni	99,923	99,185	99,883	99,927	99,533	1,000
Pnömotoraks	93,999	59,707	53,011	97,204	56,160	0,912
TB	99,854	99,854	97,714	99,991	98,773	1,000
Ortalama	96,134	64,194	62,615	97,922	63,097	0,929

Tablo 210. Dinamik Kayıp Fonksiyonu Test Sonuçları (En İyi Kategorik Hinge + Kategorik Çapraz Entropi)- Genel Doğruluk: %71,563

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,772	49,767	39,851	95,928	44,261	0,893
COVID-19	99,726	97,655	97,925	99,845	97,790	1,000
Kardiyomegali	96,619	59,878	42,826	98,824	49,937	0,938
Konsolidasyon	95,215	21,302	19,726	97,650	20,484	0,832
Ödem	95,489	54,198	49,737	97,840	51,872	0,932
Fibröz	97,107	49,677	22,849	99,312	31,301	0,921
Kosta Kırığı	98,065	49,485	42,857	99,145	45,933	0,962
İnfiltrasyon	93,315	37,146	52,797	95,401	43,610	0,912
Akciğer Opasitesi	98,827	95,319	93,178	99,475	94,236	0,995
Kitle	97,072	64,961	39,474	99,210	49,107	0,936
Normal	98,767	95,705	97,301	99,077	96,496	0,997
Plevral Efüzyon	89,240	51,168	69,183	91,747	58,827	0,917
Pnömoni	99,961	99,649	99,883	99,969	99,766	1,000
Pnömotoraks	93,015	51,658	57,025	95,828	54,209	0,916
TB	99,932	99,570	99,286	99,973	99,428	1,000
Ortalama	96,208	65,143	61,593	97,948	62,484	0,943

Tablo 211. Dinamik En Büyük Kayıp ($L_{son} = \max(L_{KCE}, L_{KH})$)- Genel Doğruluk: %68,028

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,909	50,968	29,423	97,134	37,308	0,895
COVID-19	98,468	81,121	98,064	98,494	88,791	0,999
Kardiyomegali	95,600	45,833	64,565	96,872	53,610	0,956
Konsolidasyon	95,643	18,966	12,055	98,339	14,740	0,853
Ödem	95,155	50,381	57,968	97,066	53,909	0,955
Fibröz	97,064	46,591	12,166	99,586	19,294	0,932
Kosta Kırığı	98,305	60,833	32,589	99,590	42,442	0,979
İnfiltrasyon	93,683	38,277	47,378	96,067	42,344	0,923
Akciğer Opasitesi	96,807	89,439	78,203	98,941	83,444	0,990
Kitle	96,935	65,957	29,665	99,432	40,924	0,938
Normal	97,817	91,369	96,614	98,071	93,918	0,997
Plevral Efüzyon	87,613	46,284	71,495	89,628	56,191	0,921
Pnömoni	99,856	99,762	98,476	99,979	99,115	1,000
Pnömotoraks	93,631	58,214	43,093	97,582	49,525	0,922
TB	98,553	80,623	99,857	98,470	89,215	1,000
Ortalama	95,736	61,641	58,107	97,683	57,651	0,951

Tablo 212. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=2)- Genel Doğruluk: %71,195

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,003	51,415	38,920	96,276	44,303	0,894
COVID-19	99,281	100,000	88,382	100,000	93,833	1,000
Kardiyomegali	96,662	58,706	51,304	98,521	54,756	0,955
Konsolidasyon	94,735	20,519	23,836	97,022	22,053	0,839
Ödem	95,677	57,674	43,433	98,362	49,550	0,947
Fibröz	96,670	38,393	25,519	98,784	30,660	0,924
Kosta Kırığı	97,543	40,125	57,143	98,333	47,145	0,979
İnfiltrasyon	93,648	38,514	49,825	95,905	43,445	0,900
Akciğer Opasitesi	98,742	93,132	94,759	99,198	93,938	0,998
Kitle	96,858	57,612	46,172	98,739	51,262	0,938
Normal	98,733	95,608	97,203	99,056	96,399	0,998
Plevral Efüzyon	90,832	58,303	61,402	94,511	59,812	0,927
Pnömoni	99,952	99,649	99,766	99,969	99,707	1,000
Pnömotoraks	92,236	47,326	62,692	94,545	53,936	0,925
TB	99,812	97,214	99,714	99,818	98,449	1,000
Ortalama	96,159	63,613	62,671	97,936	62,617	0,948

Tablo 213. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=3)- Genel Doğruluk: %71,674

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,020	51,483	40,410	96,144	45,279	0,896
COVID-19	99,820	98,214	98,893	99,881	98,553	1,000
Kardiyomegali	96,122	50,674	57,174	97,719	53,728	0,953
Konsolidasyon	95,283	22,321	20,548	97,694	21,398	0,844
Ödem	95,643	56,769	45,534	98,218	50,534	0,938
Fibröz	96,011	33,995	40,653	97,655	37,027	0,934
Kosta Kırığı	97,954	46,377	42,857	99,031	44,548	0,958
İnfiltrasyon	94,248	41,228	41,084	96,985	41,156	0,914
Akciğer Opasitesi	98,665	91,707	95,674	99,008	93,648	0,996
Kitle	96,345	48,980	51,675	98,002	50,291	0,939
Normal	98,827	97,218	96,026	99,419	96,618	0,998
Plevral Efüzyon	89,985	54,108	64,946	93,114	59,034	0,921
Pnömoni	99,952	99,417	100,000	99,948	99,708	1,000
Pnömotoraks	93,511	55,597	52,184	96,742	53,837	0,926
TB	99,957	99,714	99,571	99,982	99,643	1,000
Ortalama	96,223	63,187	63,149	97,970	63,000	0,948

Tablo 214. Ceza Terimi Eklenmiş Kategorik Çapraz Entropi (b=5)- Genel Doğruluk: %71,965

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,738	49,589	44,972	95,371	47,168	0,900
COVID-19	99,426	100,000	90,733	100,000	95,141	1,000
Kardiyomegali	96,807	61,417	50,870	98,690	55,648	0,948
Konsolidasyon	94,153	19,305	27,397	96,306	22,650	0,844
Ödem	95,532	55,115	46,235	98,065	50,286	0,947
Fibröz	96,627	40,273	35,015	98,457	37,460	0,924
Kosta Kırığı	98,117	50,909	50,000	99,057	50,450	0,970
İnfiltrasyon	93,640	38,042	47,552	96,013	42,269	0,904
Akciğer Opasitesi	98,707	93,610	93,844	99,265	93,727	0,997
Kitle	96,850	57,576	45,455	98,757	50,802	0,936
Normal	98,647	94,762	97,645	98,859	96,182	0,998
Plevral Efüzyon	91,602	63,132	58,706	95,715	60,838	0,921
Pnömoni	99,961	99,766	99,766	99,979	99,766	1,000
Pnömotoraks	93,220	52,602	65,643	95,376	58,403	0,933
TB	99,897	99,568	98,714	99,973	99,139	1,000
Ortalama	96,262	65,044	63,503	97,992	63,995	0,948

Tablo 215. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %72,710

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,858	50,308	45,624	95,437	47,852	0,883
COVID-19	99,743	100,000	95,851	100,000	97,881	1,000
Kardiyomegali	96,602	57,208	54,348	98,334	55,741	0,941
Konsolidasyon	94,984	18,873	18,356	97,455	18,611	0,799
Ödem	95,823	58,218	51,489	98,101	54,647	0,932
Fibröz	96,174	34,551	36,499	97,946	35,498	0,899
Kosta Kırığı	98,014	48,347	52,232	98,909	50,215	0,968
İnfiltrasyon	93,511	37,534	48,951	95,806	42,489	0,895
Akciğer Opasitesi	98,956	96,075	93,677	99,561	94,861	0,996
Kitle	97,107	63,793	44,258	99,068	52,260	0,923
Normal	98,913	95,609	98,283	99,046	96,927	0,998
Plevral Efüzyon	90,789	57,719	63,945	94,145	60,673	0,918
Pnömoni	99,923	99,185	99,883	99,927	99,533	1,000
Pnömotoraks	94,085	59,443	57,969	96,908	58,697	0,926
TB	99,932	99,856	99,000	99,991	99,426	1,000
Ortalama	96,361	65,115	64,024	98,042	64,354	0,938

Tablo 216. Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %72,205

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,567	48,532	43,110	95,371	45,661	0,882
COVID-19	99,555	100,000	92,808	100,000	96,270	1,000
Kardiyomegali	96,610	57,477	53,478	98,378	55,405	0,941
Konsolidasyon	94,676	19,185	21,918	97,022	20,460	0,798
Ödem	95,780	57,800	50,613	98,101	53,968	0,931
Fibröz	96,071	34,115	38,872	97,770	36,338	0,898
Kosta Kırığı	98,048	49,167	52,679	98,935	50,862	0,968
İnfiltrasyon	93,409	37,008	49,301	95,680	42,279	0,894
Akciğer Opasitesi	98,844	96,031	92,596	99,561	94,282	0,996
Kitle	97,201	66,192	44,498	99,157	53,219	0,922
Normal	98,725	94,531	98,381	98,797	96,417	0,998
Plevral Efüzyon	91,037	58,932	63,790	94,443	61,265	0,918
Pnömoni	99,923	99,185	99,883	99,927	99,533	1,000
Pnömotoraks	94,025	59,209	56,553	96,954	57,850	0,926
TB	99,932	100,000	98,857	100,000	99,425	1,000
Ortalama	96,293	65,158	63,822	98,006	64,216	0,938

Tablo 217. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (En İyi Kategorik Çapraz Entropi + Kategorik Hinge, Kategorik Çapraz Entropi + Kategorik Hinge)- Genel Doğruluk: %72,419

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,738	49,586	44,600	95,409	46,961	0,882
COVID-19	99,700	100,000	95,159	100,000	97,519	1,000
Kardiyomegali	96,602	57,208	54,348	98,334	55,741	0,941
Konsolidasyon	94,787	18,718	20,000	97,199	19,338	0,799
Ödem	95,780	57,895	50,088	98,128	53,709	0,932
Fibröz	96,139	34,595	37,982	97,867	36,209	0,899
Kosta Kırığı	98,014	48,347	52,232	98,909	50,215	0,968
İnfiltrasyon	93,469	37,284	48,951	95,761	42,328	0,895
Akciğer Opasitesi	98,870	96,041	92,845	99,561	94,416	0,996
Kitle	97,167	65,052	44,976	99,103	53,182	0,922
Normal	98,784	94,929	98,283	98,891	96,577	0,998
Plevral Efüzyon	90,901	58,292	63,636	94,309	60,847	0,918
Pnömoni	99,923	99,185	99,883	99,927	99,533	1,000
Pnömotoraks	94,025	59,141	56,907	96,927	58,002	0,926
TB	99,932	100,000	98,857	100,000	99,425	1,000
Ortalama	96,322	65,085	63,916	98,022	64,267	0,938

Tablo 218. Aritmetik Ortalama Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %74,260

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,534	54,857	44,693	96,276	49,256	0,911
COVID-19	99,769	100,000	96,266	100,000	98,097	1,000
Kardiyomegali	96,687	57,918	58,043	98,271	57,980	0,963
Konsolidasyon	95,095	24,129	26,575	97,305	25,293	0,859
Ödem	96,105	63,242	48,511	98,551	54,906	0,954
Fibröz	96,781	43,345	37,685	98,537	40,317	0,939
Kosta Kırığı	98,108	50,617	54,911	98,953	52,677	0,979
İnfiltrasyon	94,051	41,202	50,350	96,301	45,319	0,916
Akciğer Opasitesi	99,093	95,515	95,674	99,485	95,594	0,998
Kitle	96,893	57,576	50,000	98,633	53,521	0,948
Normal	99,033	96,701	97,792	99,295	97,243	0,999
Plevral Efüzyon	91,688	61,822	65,871	94,915	63,782	0,935
Pnömoni	99,961	99,649	99,883	99,969	99,766	1,000
Pnömotoraks	93,777	55,952	66,588	95,902	60,809	0,940
TB	99,940	99,429	99,571	99,964	99,500	1,000
Ortalama	96,568	66,797	66,161	98,157	66,271	0,956

Tablo 219. Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %73,112

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,388	53,855	44,227	96,163	48,569	0,906
COVID-19	99,444	100,000	91,010	100,000	95,293	1,000
Kardiyomegali	96,841	61,757	51,957	98,681	56,434	0,959
Konsolidasyon	94,573	21,921	28,767	96,695	24,882	0,853
Ödem	95,977	61,197	48,336	98,425	54,012	0,953
Fibröz	96,730	41,573	32,938	98,625	36,755	0,934
Kosta Kırığı	98,057	49,434	58,482	98,831	53,579	0,980
İnfiltrasyon	93,717	38,995	50,175	95,959	43,884	0,910
Akciğer Opasitesi	98,853	93,842	95,092	99,284	94,463	0,998
Kitle	96,841	57,538	44,737	98,775	50,336	0,944
Normal	98,853	95,769	97,743	99,088	96,746	0,999
Plevral Efüzyon	91,842	63,593	62,173	95,551	62,875	0,933
Pnömoni	99,971	99,766	99,883	99,979	99,824	1,000
Pnömotoraks	93,237	52,575	68,713	95,155	59,570	0,937
TB	99,897	98,864	99,429	99,927	99,145	1,000
Ortalama	96,415	66,045	64,911	98,076	65,091	0,954

Tablo 220. Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %74,345

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,577	55,161	44,786	96,314	49,435	0,911
COVID-19	99,726	100,000	95,574	100,000	97,737	1,000
Kardiyomegali	96,756	59,268	56,304	98,414	57,748	0,963
Konsolidasyon	94,958	23,709	27,671	97,128	25,537	0,859
Ödem	96,088	62,611	49,562	98,479	55,327	0,954
Fibröz	96,730	42,105	35,608	98,546	38,585	0,939
Kosta Kırığı	98,125	50,996	57,143	98,927	53,895	0,979
İnfiltrasyon	94,059	41,360	51,049	96,274	45,696	0,915
Akciğer Opasitesi	99,076	95,507	95,507	99,485	95,507	0,998
Kitle	96,978	59,207	50,000	98,722	54,215	0,948
Normal	99,033	96,565	97,939	99,264	97,247	0,999
Plevral Efüzyon	91,851	62,758	65,562	95,137	64,130	0,935
Pnömoni	99,971	99,766	99,883	99,979	99,824	1,000
Pnömotoraks	93,820	56,074	68,123	95,828	61,514	0,940
TB	99,940	99,429	99,571	99,964	99,500	1,000
Ortalama	96,579	66,968	66,286	98,164	66,393	0,956

EK 15: En Başarılı Kayıp Fonksiyonunun Model Bazında Test Sonuçları

Tablo 221. Model 1- Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %67,694

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,532	47,933	34,544	96,201	40,152	0,8945
COVID-19	99,358	94,628	95,021	99,644	94,824	0,9988
Kardiyomegali	96,713	66,379	33,478	99,305	44,509	0,9554
Konsolidasyon	94,342	19,167	25,205	96,572	21,775	0,8368
Ödem	95,660	69,277	20,140	99,541	31,208	0,9346
Fibröz	97,192	71,429	4,451	99,947	8,380	0,9259
Kosta Kırığı	98,065	49,519	45,982	99,084	47,685	0,9668
İnfiltrasyon	94,453	41,810	33,916	97,570	37,452	0,9199
Akciğer Opasitesi	98,767	95,060	92,845	99,447	93,939	0,9974
Kitle	96,953	67,033	29,187	99,467	40,667	0,9375
Normal	98,519	95,510	96,026	99,046	95,767	0,9973
Plevral Efüzyon	84,515	39,403	73,190	85,930	51,227	0,9061
Pnömoni	99,923	99,882	99,179	99,990	99,529	1,0000
Pnömotoraks	90,661	40,409	60,685	93,004	48,513	0,9110
TB	99,726	99,408	96,000	99,964	97,674	0,9998
Ortalama	95,692	66,456	55,990	97,647	56,887	0,9455

Tablo 222 Model 1- Kategorik Hinge Test Sonuçları- Genel Doğruluk: %67,266

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,798	49,940	38,454	96,097	43,451	0,8713
COVID-19	99,666	98,034	96,542	99,872	97,282	0,9974
Kardiyomegali	96,747	65,625	36,522	99,216	46,927	0,9125
Konsolidasyon	96,259	18,421	5,753	99,178	8,768	0,8035
Ödem	93,760	37,618	42,032	96,418	39,702	0,8770
Fibröz	96,841	29,487	6,825	99,515	11,084	0,8473
Kosta Kırığı	98,014	45,349	17,411	99,590	25,161	0,8637
İnfiltrasyon	93,751	35,316	33,217	96,868	34,234	0,9028
Akciğer Opasitesi	98,750	94,444	93,344	99,370	93,891	0,9778
Kitle	96,679	57,143	28,708	99,201	38,217	0,8860
Normal	98,733	95,785	97,007	99,098	96,392	0,9940
Plevral Efüzyon	91,491	66,344	47,535	96,986	55,386	0,8987
Pnömoni	99,942	99,532	99,766	99,958	99,649	1,0000
Pnömotoraks	83,145	27,470	80,756	83,332	40,995	0,9087
TB	99,949	99,856	99,286	99,991	99,570	0,9991
Ortalama	95,635	61,358	54,877	97,646	55,381	0,9160

Tablo 223. Model 1- Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %72,813

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	92,116	65,029	30,819	98,322	41,819	0,9153
COVID-19	99,743	99,010	96,819	99,936	97,902	0,9997
Kardiyomegali	96,644	56,391	65,217	97,933	60,484	0,9672
Konsolidasyon	96,088	24,157	11,781	98,807	15,838	0,8629
Ödem	95,044	49,449	62,872	96,697	55,359	0,9592
Fibröz	96,730	41,573	32,938	98,625	36,755	0,9418
Kosta Kırığı	98,151	51,905	48,661	99,119	50,230	0,9747
İnfiltrasyon	93,554	38,045	50,350	95,779	43,341	0,9277
Akciğer Opasitesi	98,904	98,553	90,682	99,847	94,454	0,9974
Kitle	97,141	64,384	44,976	99,077	52,958	0,9532
Normal	98,759	94,003	99,215	98,662	96,539	0,9983
Plevral Efüzyon	88,855	49,903	79,045	90,081	61,181	0,9380
Pnömoni	99,971	99,883	99,766	99,990	99,824	1,0000
Pnömotoraks	94,102	62,742	45,927	97,868	53,033	0,9383
TB	99,820	97,218	99,857	99,818	98,520	1,0000
Ortalama	96,375	66,150	63,928	98,037	63,882	0,9582

Tablo 224. Model 3- Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %66,127

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	88,906	41,540	50,745	92,770	45,683	0,8706
COVID-19	98,588	99,821	77,317	99,991	87,140	0,9996
Kardiyomegali	96,756	60,800	49,565	98,690	54,611	0,9458
Konsolidasyon	93,220	16,272	28,219	95,317	20,641	0,8192
Ödem	95,446	53,801	48,336	97,867	50,923	0,9365
Fibröz	97,004	44,628	16,024	99,409	23,581	0,9051
Kosta Kırığı	97,954	46,781	48,661	98,918	47,702	0,9764
İnfiltrasyon	93,606	37,300	44,930	96,112	40,761	0,8720
Akciğer Opasitesi	97,492	94,515	80,283	99,466	86,820	0,9931
Kitle	96,619	53,628	40,670	98,695	46,259	0,9081
Normal	97,021	95,333	87,193	99,098	91,081	0,9955
Plevral Efüzyon	89,659	52,992	61,402	93,191	56,888	0,8979
Pnömoni	99,653	96,054	99,883	99,633	97,931	1,0000
Pnömotoraks	91,680	44,385	58,323	94,287	50,408	0,8973
TB	98,613	99,815	77,000	99,991	86,935	0,9997
Ortalama	95,481	62,511	57,903	97,562	59,158	0,9345

Tablo 225. Model 3- Kategorik Hinge Test Sonuçları- Genel Doğruluk: %65,057

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	90,104	43,614	26,071	96,587	32,634	0,8640
COVID-19	99,666	98,857	95,712	99,927	97,259	0,9912
Kardiyomegali	94,256	27,696	28,478	96,952	28,081	0,8839
Konsolidasyon	95,206	9,877	6,575	98,065	7,895	0,7987
Ödem	91,311	30,249	59,545	92,944	40,118	0,9189
Fibröz	96,867	35,354	10,386	99,436	16,055	0,8568
Kosta Kırığı	97,963	43,966	22,768	99,433	30,000	0,9495
İnfiltrasyon	90,293	26,466	55,245	92,097	35,787	0,9040
Akciğer Opasitesi	98,844	96,922	91,681	99,666	94,228	0,9535
Kitle	96,448	54,545	4,306	99,867	7,982	0,8750
Normal	98,750	94,413	98,675	98,766	96,497	0,9926
Plevral Efüzyon	89,848	54,130	56,549	94,010	55,313	0,9045
Pnömoni	99,904	99,069	99,766	99,916	99,416	1,0000
Pnömotoraks	90,704	36,405	37,780	94,841	37,080	0,8598
TB	99,940	99,713	99,286	99,982	99,499	0,9999
Ortalama	95,340	56,752	52,855	97,499	51,856	0,9168

Tablo 226. Model 3- Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %72,470

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,209	52,563	44,879	95,899	48,418	0,9174
COVID-19	99,726	99,007	96,542	99,936	97,759	0,9997
Kardiyomegali	96,824	61,741	50,870	98,708	55,781	0,9663
Konsolidasyon	96,199	21,583	8,219	99,037	11,905	0,8543
Ödem	95,292	51,598	59,370	97,138	55,212	0,9555
Fibröz	97,004	46,632	26,706	99,092	33,962	0,9389
Kosta Kırığı	98,408	63,571	39,732	99,555	48,901	0,9769
İnfiltrasyon	92,921	35,849	56,469	94,797	43,856	0,9270
Akciğer Opasitesi	98,656	98,514	88,270	99,847	93,111	0,9977
Kitle	96,995	61,279	43,541	98,979	50,909	0,9494
Normal	98,519	92,638	99,411	98,331	95,905	0,9986
Plevral Efüzyon	89,411	51,628	74,499	91,275	60,990	0,9318
Pnömoni	99,884	98,613	100,000	99,874	99,302	1,0000
Pnömotoraks	93,939	60,578	46,989	97,610	52,926	0,9351
TB	99,940	99,856	99,143	99,991	99,498	1,0000
Ortalama	96,329	66,377	62,309	98,005	63,229	0,9566

Tablo 227. Model 4- Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %71,529

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,806	50,000	41,806	41,806	95,767	45,538
COVID-19	99,555	94,555	98,479	98,479	99,626	96,477
Kardiyomegali	96,430	54,433	57,391	57,391	98,031	55,873
Konsolidasyon	96,448	28,070	8,767	8,767	99,275	13,361
Ödem	95,703	58,435	41,856	41,856	98,470	48,776
Fibröz	97,132	50,962	15,727	15,727	99,550	24,036
Kosta Kırığı	98,228	56,800	31,696	31,696	99,529	40,688
İnfiltrasyon	92,450	34,021	57,692	57,692	94,239	42,802
Akciğer Opasitesi	98,853	95,876	92,845	92,845	99,542	94,336
Kitle	96,790	56,825	42,823	42,823	98,793	48,840
Normal	98,716	95,472	97,252	97,252	99,025	96,354
Plevral Efüzyon	88,127	47,880	77,427	77,427	89,465	59,170
Pnömoni	99,952	99,882	99,531	99,531	99,990	99,706
Pnömotoraks	93,922	61,102	44,510	44,510	97,785	51,503
TB	99,940	99,289	99,714	99,714	99,954	99,501
Ortalama	96,203	65,574	60,501	60,501	97,936	61,131

Tablo 228. Model 4- Kategorik Hinge Test Sonuçları- Genel Doğruluk: %64,287

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	89,103	37,969	29,236	29,236	95,164	33,035
COVID-19	99,623	98,709	95,159	95,159	99,918	96,901
Kardiyomegali	94,222	26,580	26,522	26,522	96,997	26,551
Konsolidasyon	96,011	10,853	3,836	3,836	98,984	5,668
Ödem	93,717	38,340	46,935	46,935	96,121	42,205
Fibröz	96,139	22,330	13,650	13,650	98,590	16,943
Kosta Kırığı	96,584	25,895	41,964	41,964	97,652	32,027
İnfiltrasyon	89,317	24,776	58,042	58,042	90,927	34,728
Akciğer Opasitesi	98,468	97,056	87,770	87,770	99,695	92,180
Kitle	95,951	29,323	9,330	9,330	99,165	14,156
Normal	98,442	92,608	98,970	98,970	98,331	95,683
Plevral Efüzyon	89,522	52,548	58,783	58,783	93,365	55,491
Pnömoni	99,836	98,157	99,883	99,883	99,832	99,012
Pnömotoraks	91,714	39,060	25,502	25,502	96,890	30,857
TB	99,906	99,855	98,571	98,571	99,991	99,209
Ortalama	95,237	52,937	52,944	52,944	97,441	51,643

Tablo 229. Model 4- Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %71,537

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,757	63,438	24,395	24,395	98,577	35,239
COVID-19	99,572	98,140	94,882	94,882	99,881	96,484
Kardiyomegali	96,242	51,813	65,217	65,217	97,514	57,748
Konsolidasyon	96,610	26,866	4,932	4,932	99,567	8,333
Ödem	94,145	42,946	60,245	60,245	95,887	50,146
Fibröz	97,021	45,736	17,507	17,507	99,383	25,322
Kosta Kırığı	98,262	55,440	47,768	47,768	99,249	51,319
İnfiltrasyon	92,750	33,689	49,650	49,650	94,968	40,141
Akciğer Opasitesi	98,887	96,935	92,097	92,097	99,666	94,454
Kitle	96,816	56,725	46,411	46,411	98,686	51,053
Normal	98,639	93,964	98,528	98,528	98,662	96,192
Plevral Efüzyon	90,027	53,869	71,341	71,341	92,363	61,385
Pnömoni	99,904	98,841	100,000	100,000	99,895	99,417
Pnömotoraks	92,518	48,718	60,567	60,567	95,016	54,000
TB	99,914	99,145	99,429	99,429	99,945	99,287
Ortalama	96,204	64,418	62,198	62,198	97,951	61,368

Tablo 230. Model 5- Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %72,188

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	89,283	44,059	61,453	92,100	51,322	0,9090
COVID-19	99,504	99,259	92,669	99,954	95,851	0,9997
Kardiyomegali	96,507	54,815	64,348	97,826	59,200	0,9617
Konsolidasyon	96,037	21,512	10,137	98,807	13,780	0,8494
Ödem	95,754	57,396	50,963	98,056	53,989	0,9536
Fibröz	96,978	45,745	25,519	99,101	32,762	0,9386
Kosta Kırığı	97,586	41,317	61,607	98,289	49,462	0,9781
İnfiltrasyon	94,230	42,081	47,378	96,643	44,572	0,9258
Akciğer Opasitesi	98,639	91,753	95,341	99,017	93,513	0,9977
Kitle	97,012	62,366	41,627	99,068	49,928	0,9462
Normal	98,742	96,325	96,467	99,222	96,396	0,9985
Plevral Efüzyon	91,662	68,664	45,917	97,381	55,032	0,9272
Pnömoni	99,913	99,070	99,883	99,916	99,475	1,0000
Pnömotoraks	92,561	49,025	65,289	94,693	56,000	0,9324
TB	99,957	99,714	99,571	99,982	99,643	1,0000
Ortalama	96,291	64,873	63,878	98,004	63,395	0,9545

Tablo 231. Model 5- Kategorik Hinge Test Sonuçları- Genel Doğruluk: %71,443

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,851	59,242	36,406	97,464	45,098	0,8824
COVID-19	99,563	99,412	93,499	99,964	96,365	0,9968
Kardiyomegali	96,122	50,628	61,304	97,549	55,457	0,9406
Konsolidasyon	95,985	14,865	6,027	98,887	8,577	0,7991
Ödem	95,189	50,732	54,641	97,273	52,614	0,9220
Fibröz	96,858	36,607	12,166	99,374	18,263	0,8591
Kosta Kırığı	98,065	49,432	38,839	99,223	43,500	0,9238
İnfiltrasyon	92,946	35,874	55,944	94,851	43,716	0,9115
Akciğer Opasitesi	98,887	96,935	92,097	99,666	94,454	0,9789
Kitle	96,122	46,050	48,804	97,878	47,387	0,9133
Normal	98,707	94,275	98,577	98,735	96,378	0,9963
Plevral Efüzyon	90,241	55,071	66,102	93,259	60,084	0,9172
Pnömoni	99,952	99,417	100,000	99,948	99,708	1,0000
Pnömotoraks	92,578	48,994	57,497	95,321	52,906	0,9051
TB	99,812	97,346	99,571	99,827	98,446	0,9997
Ortalama	96,192	62,325	61,432	97,948	60,864	0,9297

Tablo 232. Model 5- Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %72,890

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	90,652	49,185	50,559	94,712	49,862	0,9161
COVID-19	99,743	99,149	96,680	99,945	97,899	0,9999
Kardiyomegali	96,619	56,410	62,174	98,031	59,152	0,9665
Konsolidasyon	96,319	25,926	9,589	99,116	14,000	0,8576
Ödem	95,797	58,969	46,060	98,353	51,721	0,9562
Fibröz	97,261	61,644	13,353	99,753	21,951	0,9413
Kosta Kırığı	98,348	62,205	35,268	99,581	45,014	0,9799
İnfiltrasyon	94,119	41,431	48,601	96,463	44,730	0,9267
Akciğer Opasitesi	98,964	97,874	91,930	99,771	94,809	0,9981
Kitle	97,090	65,000	40,431	99,192	49,853	0,9488
Normal	98,870	94,700	99,068	98,828	96,835	0,9989
Plevral Efüzyon	88,666	49,366	77,966	90,004	60,454	0,9343
Pnömoni	99,961	99,766	99,766	99,979	99,766	1,0000
Pnömotoraks	93,460	55,194	52,066	96,696	53,584	0,9341
TB	99,906	99,855	98,571	99,991	99,209	1,0000
Ortalama	96,385	67,778	61,472	98,028	62,589	0,9572

Tablo 233. Model 6- Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %71,349

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,765	56,588	44,786	96,521	50,000	0,9118
COVID-19	99,683	98,722	96,127	99,918	97,407	0,9996
Kardiyomegali	96,781	65,000	39,565	99,127	49,189	0,9635
Konsolidasyon	94,479	19,163	23,836	96,757	21,245	0,8540
Ödem	95,651	57,143	44,133	98,299	49,802	0,9456
Fibröz	97,004	45,963	21,958	99,233	29,719	0,9393
Kosta Kırığı	97,980	47,479	50,446	98,909	48,918	0,9770
İnfiltrasyon	93,845	39,013	45,629	96,328	42,063	0,9225
Akciğer Opasitesi	98,776	98,356	89,601	99,828	93,774	0,9977
Kitle	96,739	55,331	45,933	98,624	50,196	0,9452
Normal	98,570	93,130	99,117	98,455	96,030	0,9985
Plevral Efüzyon	88,341	48,314	70,647	90,553	57,384	0,9236
Pnömoni	99,904	99,183	99,648	99,927	99,415	1,0000
Pnömotoraks	93,366	54,286	53,837	96,456	54,060	0,9267
TB	99,803	99,853	96,857	99,991	98,332	1,0000
Ortalama	96,179	65,168	61,475	97,928	62,502	0,9537

Tablo 234. Model 6- Kategorik Hinge Test Sonuçları- Genel Doğruluk: %70,818

	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skoru	AUC
	(%)	(%)	(%)	(%)	(%)	
Atelektazi	91,329	53,915	39,106	96,616	45,332	0,8835
COVID-19	99,709	96,744	98,617	99,781	97,671	0,9993
Kardiyomegali	94,539	39,093	69,348	95,571	50,000	0,9428
Konsolidasyon	95,925	13,245	5,479	98,842	7,752	0,8160
Ödem	94,350	43,504	52,189	96,517	47,452	0,9075
Fibröz	96,850	37,984	14,540	99,295	21,030	0,8704
Kosta Kırığı	97,526	38,095	46,429	98,525	41,851	0,9141
İnfiltrasyon	94,119	38,921	35,315	97,147	37,030	0,9053
Akciğer Opasitesi	99,058	97,396	93,344	99,714	95,327	0,9802
Kitle	96,713	55,743	39,474	98,837	46,218	0,9069
Normal	98,887	95,777	97,939	99,088	96,846	0,9962
Plevral Efüzyon	90,473	56,323	63,482	93,846	59,689	0,9156
Pnömoni	99,971	99,766	99,883	99,979	99,824	1,0000
Pnömotoraks	92,244	47,193	58,560	94,878	52,266	0,8994
TB	99,940	100,000	99,000	100,000	99,497	0,9998
Ortalama	96,109	60,913	60,847	97,909	59,852	0,9291

Tablo 235. Model 6- Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %71,948

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,868	64,692	25,419	98,595	36,497	0,9011
COVID-19	99,718	99,855	95,574	99,991	97,668	0,9999
Kardiyomegali	96,816	60,837	53,696	98,583	57,044	0,9612
Konsolidasyon	95,703	22,925	15,890	98,277	18,770	0,8492
Ödem	95,626	55,597	52,189	97,858	53,839	0,9555
Fibröz	96,379	37,784	39,466	98,070	38,607	0,9357
Kosta Kırığı	98,245	56,738	35,714	99,468	43,836	0,9786
İnfiltrasyon	92,681	34,866	56,993	94,518	43,265	0,9197
Akciğer Opasitesi	98,870	95,416	93,511	99,485	94,454	0,9975
Kitle	96,739	55,125	47,608	98,562	51,091	0,9420
Normal	98,896	96,000	97,743	99,139	96,864	0,9984
Plevral Efüzyon	89,188	50,932	73,652	91,131	60,220	0,9296
Pnömoni	99,952	99,533	99,883	99,958	99,707	1,0000
Pnömotoraks	93,289	53,481	57,143	96,114	55,251	0,9261
TB	99,923	99,856	98,857	99,991	99,354	1,0000
Ortalama	96,259	65,576	62,889	97,983	63,098	0,9530

Tablo 236. Model 7- Kategorik Çapraz Entropi Test Sonuçları- Genel Doğruluk: %69,038

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,508	57,455	29,423	97,794	38,916	0,9114
COVID-19	98,673	82,719	99,308	98,631	90,258	0,9996
Kardiyomegali	96,858	62,205	51,522	98,717	56,361	0,9652
Konsolidasyon	96,448	15,278	3,014	99,461	5,034	0,8512
Ödem	94,907	47,895	47,811	97,327	47,853	0,9456
Fibröz	97,115	50,000	9,496	99,718	15,960	0,9327
Kosta Kırığı	98,048	49,167	52,679	98,935	50,862	0,9780
İnfiltrasyon	91,945	32,243	58,566	93,663	41,589	0,9290
Akciğer Opasitesi	97,680	99,052	78,203	99,914	87,401	0,9941
Kitle	96,704	55,709	38,517	98,864	45,545	0,9430
Normal	97,278	89,020	96,271	97,491	92,504	0,9951
Plevral Efüzyon	89,471	51,979	68,798	92,055	59,218	0,9265
Pnömoni	99,865	98,610	99,766	99,874	99,184	1,0000
Pnömotoraks	91,705	44,865	62,928	93,955	52,383	0,9248
TB	99,854	99,709	97,857	99,982	98,774	1,0000
Ortalama	95,871	62,394	59,610	97,759	58,789	0,9531

Tablo 237. Model 7- Kategorik Hinge Test Sonuçları- Genel Doğruluk: %70,895

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,568	56,554	35,754	97,219	43,811	0,8790
COVID-19	99,700	99,425	95,712	99,964	97,533	0,9972
Kardiyomegali	96,362	53,968	51,739	98,191	52,830	0,9231
Konsolidasyon	95,951	17,857	8,219	98,781	11,257	0,8015
Ödem	95,241	51,159	57,968	97,156	54,351	0,9229
Fibröz	96,079	30,293	27,596	98,114	28,882	0,8592
Kosta Kırığı	97,937	45,251	36,161	99,145	40,199	0,9006
İnfiltrasyon	93,203	35,433	47,203	95,572	40,480	0,9122
Akciğer Opasitesi	98,930	95,214	94,343	99,456	94,776	0,9828
Kitle	96,276	47,696	42,105	98,287	44,727	0,9039
Normal	98,879	95,908	97,743	99,119	96,817	0,9963
Plevral Efüzyon	91,380	61,575	59,630	95,349	60,587	0,9134
Pnömoni	99,884	98,613	100,000	99,874	99,302	1,0000
Pnömotoraks	90,430	39,941	63,518	92,533	49,043	0,8975
TB	99,957	99,857	99,429	99,991	99,642	0,9995
Ortalama	96,119	61,916	61,141	97,917	60,949	0,9259

Tablo 238. Model 7- Doğruluğa Göre Ağırlıklı Topluluk Kayıp Fonksiyonu (Ceza terimi b=2, b=3, b=5)- Genel Doğruluk: %72,898

	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skoru (%)	AUC
Atelektazi	91,722	58,346	34,823	97,483	43,615	0,9129
COVID-19	99,863	99,441	98,340	99,964	98,887	0,9998
Kardiyomegali	96,088	50,234	70,000	97,157	58,492	0,9626
Konsolidasyon	95,566	21,771	16,164	98,127	18,553	0,8507
Ödem	95,874	59,737	47,811	98,344	53,113	0,9521
Fibröz	96,721	40,650	29,674	98,713	34,305	0,9389
Kosta Kırığı	98,288	56,977	43,750	99,354	49,495	0,9816
İnfiltrasyon	91,782	32,585	63,462	93,240	43,060	0,9214
Akciğer Opasitesi	99,076	97,483	93,428	99,723	95,412	0,9980
Kitle	97,030	61,415	45,694	98,935	52,401	0,9454
Normal	99,041	95,989	98,626	99,129	97,289	0,9985
Plevral Efüzyon	91,089	58,653	67,103	94,087	62,594	0,9330
Pnömoni	99,961	99,533	100,000	99,958	99,766	1,0000
Pnömotoraks	93,768	57,143	56,198	96,705	56,667	0,9343
TB	99,923	99,856	98,857	99,991	99,354	1,0000
Ortalama	96,386	65,988	64,262	98,061	64,200	0,9553