KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

DERİN ÖĞRENME TEMELLİ MEDİKAL GÖRÜNTÜ ANALİZİNDE SIĞ VE DERİN ÖZNİTELİKLERİN TÜMLEŞTİRİLMESİ

COŞKU ÖKSÜZ

KOCAELİ 2022

KOCAELİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ

ANABİLİM DALI

DOKTORA TEZİ

DERİN ÖĞRENME TEMELLİ MEDİKAL GÖRÜNTÜ ANALİZİNDE SIĞ VE DERİN ÖZNİTELİKLERİN TÜMLEŞTİRİLMESİ

COŞKU ÖKSÜZ

Prof. Dr. Oğuzhan URHAN		
Danışman,	**Kocaeli Üniversitesi**	**.....**
Prof. Dr. Mehmet Kemal GÜLLÜ		
Eş Danışman,	**Bakırçay Üniversitesi**	**.....**
Prof. Dr. Cem ÜNSALAN		
Jüri Üyesi,	**Marmara Üniversitesi**	**.....**
Doç. Dr. Aysun TAŞYAPI ÇELEBİ		
Jüri Üyesi,	**Kocaeli Üniversitesi**	**.....**
Dr. Öğr. Üyesi Orhan AKBULUT		
Jüri Üyesi,	**Kocaeli Üniversitesi**	**.....**
Dr. Öğr. Üyesi Ayhan KÜÇÜKMANİSA		
Jüri Üyesi,	**Kocaeli Üniversitesi**	**.....**
Doç. Dr. Gökçen ÇETİNEL		
Jüri Üyesi,	**Sakarya Üniversitesi**	**.....**

Tezin Savunulduğu Tarih: 24.01.2022

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında,

- Bu tezin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,

beyan ederim.

☒Bu tez çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.

☐Bu tez çalışması kapsamında üretilen veri ve bilgiler……..…..……..tarafından…….no'lu proje kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Coşku ÖKSÜZ

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma iznini Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanımı bana ait olacaktır.
Tezin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.
Yükseköğretim kurulu tarafından yayınlanan "***Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge***" kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

☐Enstitü yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.
☐Enstitü yönetim kurulu gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.
☒Tezim ile ilgili gizlilik kararı verilmemiştir.

Coşku ÖKSÜZ

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışmasında beyin MR görüntülerindeki kanserli bölgelerin sınıflandırılmasının yanı sıra dünya genelinde 5,5 milyondan fazla insanın ölümüne sebep olan COVID-19 hastalığı ve hastalık şiddetinin akciğer grafisi görüntülerinden belirlenebilmesine olanak tanıyan derin öğrenme temelli yöntemler geliştirilmiştir. Çalışma kapsamında aynı zamanda akciğerlerin ve beyin tümörlerinin bölütlenmesi performansında iyileşme sağlayan bir yöntem de önerilmiştir. Tez çalışmasında önerilen yöntemlerin bu alanda emek verenlere faydalı olmasını temenni ederim.

Yüksek lisans eğitimime başladığım 2011 yılından doktora eğitimimde sona geldiğim bu zamana kadar vermiş oldukları değerli katkılar ile bana mühendislik perspektifi kazandıran, desteklerini her daim hissettiğim çok değerli hocalarım Prof. Dr. Oğuzhan URHAN ve Prof. Dr. Mehmet Kemal GÜLLÜ'ye sonsuz teşekkürler sunarım. Bu yorucu süreçteki çalışmalarımda en yıpratıcı anlarda sağladıkları benzersiz motivasyonlar hiç şüphesiz beni yeniden toparlayarak bu çalışmanın nihayete ermesinde çok değerli olmuştur. Değerli görüşleriyle tez çalışmasının seyrine önemli katkılarda bulunan saygıdeğer hocam Prof. Dr. Cem ÜNSALAN'a ayrıca teşekkür ederim.

Tez çalışmalarım boyunca değerli zamanlarımızdan çokça fedakârlık yapan ve benim için koşulsuz şartsız her türlü zorluğu göze alan, birlikte daha güzel günleri hayal ettiğimiz biricik eşim Sibel'e minnettarım.

Hayatım boyunca sonsuz sevgi, ilgi ve desteğiyle beni bu günlere getiren annem Selma ÖKSÜZ ve babam Bülent ÖKSÜZ'e teşekkürü bir borç bilirim. Yoğun çalışma temposuna rağmen çalışmalarımı okuyarak yorumlarını esirgemeyen çok değerli kardeşim Dr. Oğuz ÖKSÜZ'e teşekkür ederim. Tez çalışmalarım boyunca zaman zaman başını ağrıttığım saygıdeğer Dr. Öğr. Üyesi Ali Can KARACA'ya verdiği tüm manevi desteklerden dolayı ayrıca teşekkürlerimi sunarım.

Ocak−2022 Coşku ÖKSÜZ

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI ii
ÖNSÖZ VE TEŞEKKÜR iii
İÇİNDEKİLER iv
ŞEKİLLER DİZİNİ vi
TABLOLAR DİZİNİ ix
SİMGELER VE KISALTMALAR DİZİNİ xi
ÖZET xii
ABSTRACT xiii
1. GİRİŞ 1
2. MEDİKAL GÖRÜNTÜLERDEN ÖZNİTELİK ÇIKARTMA VE SINIFLANDIRMA 8
2.1. OT Sistemlerinin Geliştirilme Süreci 8
2.1.1. Modüler OT Sistemleri 9
2.1.1.1. Radyomik Çıkartma 9
2.1.1.2. Öğrenme 12
2.1.2. Tümleşik OT Sistemleri 21
2.1.2.1. Derin Öğrenme 21
2.2. Tartışma 37
3. BEYİN MR GÖRÜNTÜLERİNDEN ÖZNİTELİK ÇIKARTMA VE TÜMÖR SINIFLANDIRMA 39
3.1. Önerilen Yöntem 47
3.1.1. Veri Kümeleri 47
3.1.2. ROI Genişletme 49
3.1.3. Öznitelik Çıkartma 51
3.1.4. Öznitelik Kaynaştırma ve Sınıflandırma 53
3.2. Deneysel Sonuçlar 53
3.2.1. Performans Değerlendirme Metrikleri 53
3.2.2. Önerilen Sınıflandırıcı Yapısının Eğitilmesi ve Değerlendirilmesi 54
3.2.3. ROI Genişletme ve Öznitelik Kaynaştırmanın Sınıflandırma Performansı Üzerindeki Etkisi 55
3.3. Tartışma 65
3.4. Görselleştirme 69
3.5. Değerlendirme 70
4. AKCİĞER GRAFİLERİNDEN ÖZNİTELİK ÇIKARTMA VE SINIFLANDIRMA: COVID-19 HASTALIĞI TESPİTİ 73
4.1. Önerilen Yöntem 79
4.1.1. Topluluk kodlayıcı 80
4.1.2. Topluluk Ağının Oluşturulması 82
4.1.2.1. Öznitelik Haritası Kaynaştırma 82
4.1.2.2. Ek Katmanlar 82
4.2. Deneysel Sonuçlar 83
4.2.1. Veri Kümesi 83
4.2.2. Hiperparametreler ve Veri Çoğaltma 87
4.2.3. Performans Metrikleri 88
4.2.4. Performans Karşılaştırma 88

4.2.4.1. Derin Öğrenme Temelli Topluluk Modeli Oluşturma (DÖT) 88
4.2.4.2. Klasik Topluluk Modelleri (KT) Karşısında DÖT 90
4.3. Görselleştirme 94
4.4. Tartışma 95
4.5. Değerlendirme 97
5. AKCİĞER GRAFİLERİNDEN COVID-19 ŞİDDET SKORU TAHMİNİ İÇİN ÖZNİTELİK ÇIKARTMA 98
5.1. Önerilen Yöntem 99
5.1.1. Öznitelik Çıkarma Ağı (ÖÇA) 99
5.1.2. Önem Skoru Tahmin Alt Ağı (ÖSTA) 100
5.2. Deneysel Sonuçlar 102
5.2.1. Veri kümesi 102
5.2.2. Hiperparametreler, Veri Çoğaltma ve Hata Fonksiyonu 102
5.2.3. Performans metrikleri 103
5.2.4. Performans karşılaştırma 103
5.3. Görselleştirme 106
5.4. Tartışma 107
5.5. Değerlendirme 108
6. MEDİKAL GÖRÜNTÜ BÖLÜTLEME İÇİN ÖZNİTELİK ÇIKARTMA VE SINIFLANDIRMA 109
6.1. Önerilen Yöntem 111
6.1.1. Kodlayıcı 111
6.1.2. Kod Çözücü 112
6.2. Deneysel Sonuçlar 113
6.2.1. Veri Kümesi 113
6.2.2. Ön Ayarlar 115
6.2.3. Hata Fonksiyonu 115
6.2.4. Performans Metrikleri 115
6.2.5. Performans Değerlendirme 116
6.2.6. Ablasyon Çalışması 116
6.3. Tartışma 121
6.3.1. Önerilen yapının farklı bir medikal bölütleme görevinde geçerlenmesi 125
6.4. Görselleştirme 127
6.5. Değerlendirme 127
7. SONUÇLAR VE ÖNERİLER 131
KAYNAKLAR 133
KİŞİSEL YAYIN VE ESERLER 152
ÖZGEÇMİŞ 154

ŞEKİLLER DİZİNİ

Şekil 2.1. Tipik bir bilgisayarlı tanı sistemini oluşturan birimler 9
Şekil 2.2. Biyobelirteçlerin elde edilmesindeki süreçler..... 11
Şekil 2.3. Öznitelik çıkartım stratejileri. (a) Bütünsel öznitelik çıkartma. (b) Yerel öznitelik çıkartma..... 12
Şekil 2.4. DVM modelinin kavramsal gösterimi 16
Şekil 2.5. Karar ağacı yapısı 17
Şekil 2.6. Yanlılık-değişinti hatası ve model karmaşıklığı ilişkisi..... 20
Şekil 2.7. Üç kanallı bir akciğer grafisinin derin bir ağın ilgili seviyelerindeki örnek temsilleri..... 22
Şekil 2.8. Genel bir ESA mimarisi..... 23
Şekil 2.9. ESA mimarilerinde evrişim işleminin kavramsal olarak gösterim..... 24
Şekil 2.10. Maksimum ve ortalama havuzlama işlemlerinin örneklendirilmesi 26
Şekil 2.11. Aktivasyon işlevinin örneklendirilmesi 27
Şekil 2.12. ESA mimarilerinde yaygın olarak kullanılan aktivasyon işlevlerinin karşılaştırılması..... 29
Şekil 3.1. Önerilen sınıflandırma çatısı..... 47
Şekil 3.2. Brain tumor veri kümesinin her bir tümör sınıfından seçilen örnek kesitler: (a) Gliom. (b) Menenjiyom. (c) Hipofiz tümörü. LGG-1p19qDeletion veri kümesinden seçilen örnek kesitler: (d)'de n/n sınıfına ait T1C ağırlıklı MR kesit, (e)'de (d)'de verilen kesitin T2 ağırlıklı karşılığı verilmektedir. (f)'de d/d sınıfından seçilen bir tümör örneğinin T1C ağırlıklı, (g)'de T2 ağırlıklı kesitleri verilmektedir. (f)'de d/d sınıfına ait T1C ağırlıklı kesit, (g)'de ise (d)'de verilen kesitin T2 ağırlıklı karşılığı gösterilmektedir. Her bir kesitte kırmızı ile vurgulanan çevritler tümör sınırlarını göstermektedir..... 49
Şekil 3.3. (a) ROI genişletme süreci: beyin MR diliminden genişletilmiş tümör bölgesinin kırpılması ve ağ giriş çözünürlüğüne göre yeniden boyutlandırılması. En soldaki görüntüde verilen genişletilmiş tümör maskesi (yeşil kontur), orijinal ROI maskesini (kırmızı kontur) genişleterek elde edilmektedir. Brain tumor veri kümesinden örnek ROI'ler: (b) İlk sıra gliomayı, ikinci sıra menenjiyomu ve üçüncü sıra hipofiz tümörü sınıflarını göstermektedir. LGG-1p19qDeletion veri kümesinden örnek ROI'ler: (c) İlk satırdaki ROI'ler d/d sınıfına, ikinci satırdaki ROI'ler n/n sınıfına aittir. Sütunlar, sırasıyla 0, 8, 16, 24, 32, 40, 48, 56, 64, 72, 80 çeşitli disk boyutları için elde edilen tümör bölgelerini gösterir..... 50
Şekil 3.4. Transfer öğrenmenin aşamaları..... 51
Şekil 3.5. Önerilen sınıflandırıcı yapısının Brain tumor veri kümesi üzerinde değerlendirilmesi. Karışıklık matrisi, en iyi sınıflandırma performansının elde edildiği disk boyutu R için sonuçları temsil etmektedir..... 56
Şekil 3.6. Önerilen yöntemin LGG-1p19qDeletion veri kümesi üzerinde değerlendirilmesi süreci. Karışıklık matrisi, en iyi sınıflandırma

performansının elde edildiği disk boyutu R için elde edilen sonuçları temsil etmektedir 57
Şekil 3.7. Önerilen sınıflandırıcı yapısında derin öznitelik çıkartıcı olarak farklı ince ayarlı ağların kullanılması durumunda elde edilen performansın karşılaştırılması. Derin öznitelik çıkartıcı olarak (a)'da AlexNet, (b)'de GoogLeNet, (c)'de ResNet-18, (d)'de ShuffleNet kullanılmaktadır 59
Şekil 3.8. Her bir yöntem ile elde edilen ortalama geçen süreye karşı ortalama doğruluk 60
Şekil 3.9. Öznitelik çıkarma katmanına bağlı olarak elde edilen CV-10 hatasının (loss) değişimi 63
Şekil 3.10. Çıkartılan öznitelik setlerine ait 2B saçılım çizimleri. (a) $[\text{ResNet18ft}]^0$ öznitelik setine ait saçılım çizimi, (b) $[\text{ResNet18ft+ShallowNet}]^0$ öznitelik setine ait saçılım çizimi, (c) $[\text{ResNet18ft}]^{56}$ öznitelik setine ait saçılım çizimi, (d) $[\text{ResNet18ft+ShallowNet}]^{56}$ öznitelik setine ait saçılım çizimi 71
Şekil 3.11. GradCAM görselleri. Üst satırdaki görsellerde orijinal tümör bölgeleri ve karşılık gelen GradCAM görselleri verilmektedir. Alt satırdaki görüntülerde ise üst satırlarındaki orijinal tümör bölgelerine çevre dokularının dâhil edildiği genişletilmiş ROI'ler ve karşılık gelen GradCAM görselleri verilmektedir 72
Şekil 4.1. Önerilen hafif ağırlıklı topluluk ağı modeli 79
Şekil 4.2. Eğitim ve test kümelerine dâhil edilen hasta sayıları 89
Şekil 4.3. Önerilen sınıflandırma çerçevesinin beş-kat-çapraz-geçerleme süreci kullanılarak değerlendirilmesi 90
Şekil 4.4. Yöntemlerin toplam öğrenilebilir parametre sayısı karşısında elde edilen doğrulukları gösterir 2B saçılım çizimi 93
Şekil 4.5. Önerilen model tarafından döndürülen GradCAM imgeleri COVID-19 hastalığının sırasıyla hafif (a), orta (b) ve ağır (c) formlarını açıklamaktadır 95
Şekil 5.1. Önerilen önem skoru tahmin çerçevesi 101
Şekil 5.2. Önerilen yöntemin değerlendirilme süreci 104
Şekil 5.3. Yöntemlerin MAE, RMSE ve R2 metriklerine göre karşılaştırılması 105
Şekil 5.4. Ağın her bir şiddet tahmin başından kestirilen skorlar karşısında gerçek değerler. (a) Tutulum skoru tahminleri. (b) Opaklık skoru tahminleri 105
Şekil 5.5. Orta ve en sağdaki sütunlarda verilen Grad-RAM görüntüleri, sırasıyla modelin akciğer tutulum başı ve opasite skor başlığı kullanılarak elde edilmektedir 106
Şekil 6.1. Önerilen akciğer bölütleme ağı: Ensemble-LungMaskNet 114
Şekil 6.2. Önerilen bölütleme ağının açık erişimli veri setleri üzerinde geçerleme süreci 122
Şekil 6.3. Çalışma kapsamında kullanılan yöntemlerin karşılaştırılması 123
Şekil 6.4. Çalışma kapsamında geliştirilen bölütleme modellerinin Brain tumor veri kümesi üzerindeki performanslarının karşılaştırması 126
Şekil 6.5. Akciğerlerin bölütlenmesine ait yöntem çıktıları. Orijinal görüntüler (a) sütununda, karşılık gelen temel gerçekler ise (b)

sütununda verilmiştir. Bölütleme çıktıları ShuffleNet temelli bölütleme ağı için (c) sütununda, önerilen yöntem için ise (d) sütununda için verilmiştir. Her yöntem tarafından tahmin edilen sınırlar karşılaştırmalı olarak sütun (e)'de verilmiştir. (e)'deki kırmızı ile verilen sınırlar gerçek çevriti göstermektedir. (e)'deki yeşil olarak verilen sınırlar ShuffleNet temelli mimariye aitken mavi ile verilen sınırlar ise önerilen yönteme aittir. Tahmin edilen skorlar da görsellerin altında verilmiştir. Eğik çizgiden sonra verilen çevrit eşleştirme puanları (veya BF1) önerilen yönteme aittir 128

Şekil 6.6. Beyin tümörlerinin bölütlenmesine ilişkin yöntem örnek çıktıları. Orijinal görüntüler (a) sütununda, karşılık gelen yer doğruları ise (b) sütununda verilmektedir. Bölütleme çıktıları ShuffleNet temelli bölütleme ağı için (c) sütununda, önerilen yöntem için ise (d) sütununda için verilmektedir. Her bir yöntem tarafından tahmin edilen sınırlar karşılaştırmalı olarak sütun (e)'de verilmektedir. (e)'deki kırmızı ile verilen sınırlar gerçek çevriti, yeşil olarak verilen sınırlar ShuffleNet temelli mimariye aitken mavi ile verilen sınırlar ise önerilen yönteme aittir. Tahmin edilen skorlar da görsellerin altında verilmiştir. Eğik çizgiden sonra verilen çevrit eşleştirme puanları (veya BF1) önerilen yönteme aittir 129

TABLOLAR DİZİNİ

Tablo 2.1. Medikal görüntülerden çıkartılan radyomikler 13
Tablo 3.1. Beyin tümörü sınıflandırma için geliştirilen literatürdeki çalışmaların özeti 43
Tablo 3.2. *Brain tumor* veri kümesinin her bir katında bulunan kesit ve hasta sayısı 48
Tablo 3.3. *LGG-1p19qDeletion* veri kümesinin her bir sınıfında bulunan kesit sayısı 48
Tablo 3.4. Sığ ESA katmanları 52
Tablo 3.5. Çalışmada kullanılan hiperparametreler 54
Tablo 3.6. Çalışmada kullanılan yöntemler için *Brain tumor* veri kümesinin her bir katında elde edilen doğruluk skorları 58
Tablo 3.7. *Brain tumor* veri kümesi üzerinde yöntemlerin sınıflandırma performanslarının karşılaştırılması 62
Tablo 3.8. Değişen disk boyutlarına bağlı olarak elde edilen CV-10 doğruluk skorları 63
Tablo 3.9. *LGG-1p19qDeletion* veri kümesi üzerinde yöntemlerin sınıflandırma performanslarının karşılaştırılması 64
Tablo 3.10. *Brain tumor* veri kümesi üzerinde önerilen yöntem kullanılarak elde edilen karışma matrisi. Eğik çizgiden sonra gelen ve kalın olarak belirtilen değerler $[\text{ResNet18}_{\text{ft}}+\text{ShallowNet}]^{56}$+DVM mimarisi kullanıldığında elde edilmektedir. Eğik çizgiden önce gelen değerler ise $[\text{ResNet18}_{\text{ft}}]^{0}$+DVM mimarisi kullanıldığında elde edilmektedir 65
Tablo 3.11. *LGG-1p19qDeletion* veri kümesinde önerilen yöntem kullanılarak elde edilen karışıklık matrisi. Eğik çizgiden sonra gelen ve kalın olarak belirtilen değerler $[\text{ResNet18}_{\text{pt}}+\text{ShallowNet}]^{80}$+kNN mimarisi ile elde edilmektedir. Eğik çizgiden önce gelen değerler ise $[\text{ResNet18}_{\text{pt}}]^{0}$+kNN mimarisi ile elde edilmektedir 65
Tablo 3.12. Sınıflandırma sonuçlarının *Brain tumor* veri kümesini kullanan referans çalışmalarla karşılaştırılması 67
Tablo 3.13. Sınıflandırma sonuçlarının *LGG-1p19qDeletion* veri kümesini kullanan referans çalışmalarla karşılaştırılması 68
Tablo 4.1. Çalışmada kullanılan veri kümelerinin özeti 86
Tablo 4.2. Çalışmada kullanılan eğitim hiperparametreleri ve veri çoğaltma teknikleri 88
Tablo 4.3. *Veri kümesi-1*'in her bir test katı üzerinde elde edilen model performansları 90
Tablo 4.4. Çalışmada sunulan her bir yöntem ile *Veri kümesi-1* üzerinde elde edilen CV-5 skorları 91
Tablo 4.5. Çalışmada sunulan yöntemler için karışma matrisi. Sıralama: Fused features #3 + GentleBoost/EfficientNet-B0/Ensemble-CVDNet#1/Ensemble-CVDNet 92
Tablo 4.6. *Veri kümesi-2* üzerinde elde edilen sınıflandırma sonuçları 94

Tablo 4.7. Sınıflandırma sonuçlarının COVID-19 hastalığının şiddet düzeyine göre sınıflandırma performansını analiz eden referans çalışma ile karşılaştırılması 95
Tablo 4.8. *COVID-19 Image Data Collection* veri kümesindeki her bir şiddet düzeyi için önerilen yöntemin değerlendirilmesi 96
Tablo 5.1. Öznitelik haritalarının çıkartıldığı katmanlar ve karşılık gelen tensörler..... 100
Tablo 5.2. Performans karşılaştırma 104
Tablo 5.3. Çalışmada elde edilen sonuçların aynı veri kümesi kullanan referans çalışmalar ile karşılaştırılması..... 108
Tablo 6.1. Toplu kodlayıcı mimarisinin bölütleme performansı üzerindeki etkisi. Sonuçlar %95 güven aralığı ile verilmektedir..... 118
Tablo 6.2. Ensemble-LungMaskNet#2 modelinin kod çözme aşamalarına dâhil edilen kodlayıcı semantik haritalarının bölütleme performansı üzerindeki etkisi. Sonuçlar %95 güven aralığı ile verilmektedir..... 119
Tablo 6.3. Bölütleme performansının *V7 Darwin* veri kümesini kullanan referans çalışmaları ile karşılaştırılması..... 123
Tablo 6.4. Bölütleme performansının *Tuberculosis Chest X-Ray Image* veri kümesini kullanan referans çalışmalarla karşılaştırılması 124

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

BoW	: Bag of Visual Words
BP	: Back Propogation
BRISK	: Binary Robust Invariant Scalable Keypoints
CART	: Classification and Regression Trees
CNN	: Convolutional Neural Network
DWT	: Discrete Wavelet Transform
GLCM	: Gray Level Co-occruance Matrix
GLRLM	: Gray Level Run Length Matrix
GLZLM	: Gray Level Zone Length Matrix
HoG	: Histogram of Oriented Gradients
KELM	: Kernel Extreme Leaning Machine
LASSO	: Least Absolute Shrinkage and Selection Operator
LBP	: Local Binary Patterns
LGG	: Low Grade Gliomas
MLP	: Multi Layer Perceptron
mRMR	: minumum Redundancy Maximum Relevance
MSER	: Maximally Stable Extremal Regions
NCA	: Neighborhood Component Analysis
NGLDM	: Neighborhood Grey Level Difference Matrix
NN	: Neural Network
ID3	: Iterative Dichotomiser 3
ORB	: Oriented Fast and Rotated BRIEF
PCA	: Principal Component Analysis
PNN	: Probabilistic Neural Network
SIFT	: Scale Invariant Feature Transform
SURF	: Speeded Up Robust Features

DERİN ÖĞRENME TEMELLİ MEDİKAL GÖRÜNTÜ ANALİZİNDE SIĞ VE DERİN ÖZNİTELİKLERİN TÜMLEŞTİRİLMESİ

ÖZET

Tıbbi uzmanlar, günlük çalışma rutinlerinde çeşitli hastalıkların varlığı ya da yokluğu, hastalık seyrinin izlenmesi ve benzeri birçok klinik durumun kontrolü için medikal görüntüleri analiz ederek çeşitli anlamsal öznitelikler çıkartmaktadırlar. Bu açıdan bakıldığında görüntüleme, hastalıklara cerrahi bir müdahale gerektirmeksizin uzmanlara değerli bilgi sağladığından kritik bir öneme sahiptir. Bununla birlikte, dünya genelindeki nüfus artış hızına paralel olarak hasta sayısı ve dolayısıyla elde edilen veri miktarı da muazzam artış göstermiştir. Artan veri, uzmanların iş yükünü de arttırarak verilecek kararları hataya açık hale getirmektedir. Öte yandan medikal görüntüler, içlerinde bir tıbbi uzman tarafından yorumlananın çok daha ötesinde bilgi içeriğine sahiptir. Bu motivasyonla, medikal görüntülerin sahip olduğu içeriği ortaya koymak için gelişmiş görüntü işleme algoritmaları kullanılmaktadır. Son yıllarda önemi hızla kavranan radyomikler, medikal görüntülerden çıkartılan sayısal görüntüleme özniteliklerini ifade etmektedir. Çıkartılan sayısal öznitelikler ile geliştirilen radyomik klinik karar destek sistemleri uzman kaynaklı hataları önemli ölçüde azaltabilme potansiyeli taşımaktadır. Daha iyi karar desteği sağlayacak sistemlerin geliştirilmesi, temsil gücü yüksek özniteliklerin medikal görüntülerden keşfedilmesini gerektirmektedir. Bu tez çalışması kapsamında, derin ve sığ özniteliklerin kaynaşımına olanak tanıyan derin öğrenme temelli klinik karar destek sistemleri geliştirilmiştir. Çalışmada yakın geçmişte Dünya genelinde ölüm oranlarındaki artışa önemli katkı sağlayan COVID-19 hastalığı ve beyin tümör türleri hasta dostu görüntüleme modalitelerinin kullanıldığı medikal görüntülerden tespit edilmektedir. Deneysel sonuçlar, tez çalışması kapsamında önerilen yöntemlerin literatürdeki çalışmalar karşısında çeşitli üstünlüklere sahip olduğunu ve uzmanlara verecekleri kararlarda yardımcı birer araç olarak kullanılabileceklerini göstermektedir.

Anahtar Kelimeler: Derin Öğrenme, Evrişimsel Sinir Ağları, Öznitelik Çıkartma, Radyomikler, Sınıflandırma.

FUSION OF SHALLOW AND DEEP FEATURES IN DEEP LEARNING-BASED MEDICAL IMAGE ANALYSIS

ABSTRACT

Medical experts extract various semantic features by analyzing medical images for the presence or absence of various diseases, and for monitoring the course of the disease in their daily work routines. From this point of view, imaging has critical importance as it provides valuable information to specialists without requiring surgical intervention for diagnosing diseases. However, in parallel with the worldwide population growth rate, the number of patients and therefore the amount of data obtained has increased tremendously. Increasing data also increases the workload of experts, making the decisions to be made prone to errors. On the other hand, medical images have information content far beyond what is interpreted by a medical expert. With this motivation, advanced image processing algorithms are used to reveal the content of medical images. Radiomics, the importance of which has been rapidly recognized in recent years, refers to the digital imaging features extracted from medical images. Radiomic clinical decision support systems developed with the extracted quantitative features have the potential to significantly reduce expert-sourced errors. The development of systems that will provide better decision support requires the discovery of highly representative features from medical images. Within the scope of this thesis, deep learning-based clinical decision support systems that allow the fusion of deep and shallow features have been developed. In the study, COVID-19 disease and brain tumors, which are the important causes of the increase in mortality rates worldwide in the recent past, are detected from medical images using patient-friendly imaging modalities. Experimental results show that the methods proposed within the scope of the thesis study have various superiority over the studies in the literature and can be used as an auxiliary tool in the decisions they will give to the experts.

Keywords: Deep Learning, Convolutional Neural Networks, Feature Extraction, Radiomics, Classification.

1. GİRİŞ

Tıbbi görüntüleme, hastalıkların tespit edilmesi ve tanılanması için vazgeçilmez olup hassas tıp (Hodson, 2016) için gün geçtikçe daha da önemli hale gelmektedir. Mevcut durumda Röntgen (X-Işını), Bilgisayarlı Tomografi (BT), Manyetik Rezonans (MR), Pozitron Emisyon Tomografisi (PET) gibi görüntüleme teknikleri, radyologlar ve diğer sağlık uzmanları tarafından yaygın olarak kullanılmaktadır (J. Gao ve diğ., 2019). Günümüzde insan nüfusunun hızla artmasının sağlık sektörüne bir yansıması olarak sağlık uzmanları tarafından ele alınması gereken klinik veri miktarı muazzam derecede artmıştır. Böylelikle önemli bir çoğunluktaki sağlık uzmanı günlük klinik rutinlerinde laboratuvar verilerini ve tıbbi görüntüleri çeşitli hastalıkların varlığını araştırmak adına analiz etmektedir. Artan karmaşaya bağlı olarak uzmanların iş yüklerinin de artması verilecek klinik kararlarda kritik hataların oluşmasına zemin hazırlamaktadır. Yorgunluk ve deneyimsizlik gibi faktörler hastalıkların yanlış tanılanmasına, lezyon olmayan bölgelerin lezyon olarak değerlendirilebilmesine, özellikle kötü huylu lezyonların iyi huylu olarak yorumlanabilmesine sebep olabilmektedir (F. Li ve diğ., 2002; Q. Li ve diğ., 2005; Suzuki ve diğ., 2008; K Doi, 2005). (C. S. Lee ve diğ., 2013)'de yapılan geriye dönük bir çalışmada radyolojik incelemelerin hata oranının %30 civarında olduğu, radyologların günlük hata oranın ise %3-5 arasında olduğu belirtilmektedir. Dahası aynı çalışmada tıbbi uygulama hatası iddialarının yaklaşık %75'inin teşhis hatalarıyla ilgili olduğu belirtilmektedir (C. S. Lee ve diğ., 2013). (Obermeyer ve Emanuel, 2016)'de tanılama hatalarının sayısının alarm verici seviyede arttığı ve hataları azaltabilecek kabileyette yeterli müdahalenin yapılamadığı belirtilmektedir. Bu sebeple sağlık alanında uzmanlara verecekleri kararlarda yardımcı olabilecek bilgisayarlı tanılama sistemlerinin geliştirilmesine ihtiyaç bulunmaktadır. Bilgisayarlı tanılama sistemleri, meme kanseri, akciğer kanseri, prostat kanseri, deri lezyonları, inme, Alzheimer hastalığı ve daha birçok hastalığın tespiti ve teşhisi için yaygın olarak kullanılmaktadır. Geliştirilen bu gibi sistemler sayesinde bazı durumlarda uzmanların çıplak göz ile göremediği hastalıklara ilişkin örüntüler bilgisayar görüsü teknikleri ile yüksek hassasiyette yakalanabilmektedir. Böylelikle sağlık uzmanlarının iş yüklerinin azaltılması zamanın daha efektif olarak kullanılması ve tanılama doğruluklarının arttırılması sağlanabilmektedir (Arimura, 2017; Nishio ve Nagashima, 2017). Bilgisayarlı tanılama sistemlerinin geliştirilmesi bilhassa

yeterli uzmanın bulunmadığı gelişmemiş ve gelişmekte olan ülkeler için önem arz etmektedir.

Tıbbi görüntülerin bilgisayarlı analizi, klinik çıktıların tahmin edilebilmesi için bu görüntülerin sayısal yöntemler ile işlenerek veriden anlam çıkarma süreci olarak tanımlanabilmektedir. Tıbbi görüntülerin bilgisayarlar ile analiz edilmesini hedefleyen ilk çalışmalar 1960 yılların ilk yarısına dayanmaktadır (Lodwick ve diğ., 1963; Meyers ve diğ., 1964; Winsberg ve diğ., 1967; Kruger ve diğ., 1972; Kruger ve diğ., 1974; Toriwaki ve diğ., 1973; Engle, 1992). Bu dönemde bilgisayarların belirli görevleri icra etmede insanlardan daha üstün olduğu fikrinin baskın olması bu görüntülerdeki anormalliklerin tespit edilmesinde radyologların yerini makinelerin alması gerektiği düşüncesini oluşturmuştur. Bu düşünce ile birlikte Otomatik Tanı (OT) kavramı ortaya çıkmıştır. 1960 yıllarda geliştirilen ilk OT sistemlerinde göğüs kanserinin mamogramdan kestirilmesi amaçlanmıştır (Takahashi ve Kajikawa, 2017). Buna rağmen, bu dönemde sayısal görüntülerin kolaylıkla elde edilememesi, bilgisayarların işlem gücünün yetersizliği ve ileri görüntü işleme tekniklerinin henüz geliştirilmemiş olması gibi etkenler sebebiyle tatmin edici bir başarı elde edilememiştir (Kunio Doi, 2007). Bu olumsuzluklar OT sistemlerinin erken dönemde kullanımını kısıtlamıştır. OT sistemlerinin gelişimindeki erken dönemde (Engle, 1992)'de hematoloji alanında yapılan 30 yıl süreli bir araştırmada uzmanların verecekleri kararları taklit edecek bilgisayar programların geliştirilmesinin umut vadetmediği ve bilgisayarlara tanı koyucular gözüyle bakılması düşüncesinden vazgeçildiği sonucuna varılmıştır.

Bilgisayarlı tanılama sistemlerinin geliştirilmesindeki ikinci girişim 1980'lerde yapılmıştır. Bu dönem çalışmalarına Chicago Üniversitesi'nin radyoloji bölümündeki radyolojik görüntü araştırmaları için kurulan Kurt Rossman Laboratuvarları'nda (Kurt Rossmann Laboratories for Radiologic Image Research) başlanmıştır (Kunio Doi, 2007). Önceki dönemde başarısız olunan OT kavramı 1980'lere gelindiğinde yerini Bilgisayar Destekli Tanı (BDT) kavramına bırakmıştır. BDT'nin OT'den temel farkı bilgisayarların uzmanların yerini almadan onlara verecekleri kararlarda destek sağlamasıdır. Bu açıdan bakıldığında BDT sistemleri aracılığıyla elde edilen bilgisayar çıktıları radyologlara verecekleri kararlarda destek olabilecek ikinci bir görüş sağlamaktadır. Ancak bir önceki dönemdeki girişimin başarısızlığı bu dönemde yeni türeyen BDT kavramı ile bir başarının

yine elde edilemeyeceği inancını oluşturmuştur. 1980'li yıllarda geliştirilen sistemlerin 1960'lı yıllarda geliştirilmiş olanlardan temel farklılığı daha sistematik olması, eldeki teknolojinin bir miktar gelişimi ve bu sayede daha iyi bir performansın elde edilebilmesidir.

Günümüzde bilgisayarların veriyi işleme gücünün artışı ve daha yüksek kalitede görüntüler elde edilebilmesine olanak tanıyan tarayıcıların geliştirilmesi gibi etkenler tıbbi görüntülerin daha iyi analiz edilebilmesini mümkün kılmış ve OT sistemlerinin ürettiği hataların azalmasını sağlamıştır. Bunlara bağlı olarak medikal alanda geliştirilen BDT sistemleri radyolojinin önemli bir parçası haline gelmeye başlamıştır. Böylelikle erken dönemde uygulanmasından vazgeçilen OT sistemleri ileri görüntü işleme tekniklerinin geliştirilmesi ve bilgisayarların veri işleme gücündeki artış sayesinde BDT sistemleri ile birlikte var olmaktadır. Literatürde mevcut bir medikal problemin çözümü için OT veya BDT sistemlerinden herhangi birini gerçekleştirmeyi hedefleyen birçok çalışma yapılmıştır. Geliştirilen tanılama sisteminin hangi amaçla kullanılacağı büyük oranda üzerinde çalışılan tıbbi problemin riskleri ile geliştirilen sistemin duyarlılık ve kesinliğine bağlı olmaktadır. OT sistemlerinde klinik uzmanı taklit eden bir sistem elde etmek genel bir hedef olduğundan elde edilecek performans seviyesinin oldukça yüksek olması önem arz etmektedir. Örnek bir durum olarak MR görüntülerinde tümörlü bölgelerin konumunu tespit etmek için geliştirilen bir OT sisteminin yanlış negatif sayısının fazla olması ve görüntü başına birden fazla yanlış pozitif üretmesi uzman kontrolünü zorunlu hale getirecektir. Böyle bir durumda ise önerilen sistem tam otomatik bir sistem olma özelliğinden yoksun olmaktadır. Bu nedenle OT sistemlerinin yüksek yakalama oranı ve yüksek özgüllüğe sahip olması bir gerekliliktir. Bunun yanında BDT sistemleri tarafından üretilen çıktılar uzmana ikinci bir görüş sağlayarak kabul veya reddedilebilmektedir. Böylece son kararı yine uzman vermektedir. BDT sistemleri tam otomatik olmasa da uzman tarafından verilen kararların sistem kararları ile birleştirilmesi bir etkileşim meydana getirerek tanılama hataları azaltılabilmektedir.

Klinik uygulamalardaki tanılama hatalarını azaltmak ve uzmanlara vereceklerdeki kararlarda destek olmak için geliştirilen tüm bilgisayarlı tanılama sistemleri öznitelik mühendisliği (A. Zheng ve Casari, 2018) ve makine öğrenmesi (Mitchell, 1997) alanlarındaki ilerlemeler sayesinde geliştirilebilmektedir. Öznitelik mühendisliği ham veriden veriyi daha düşük boyutta temsil eden en uygun öznitelik kümesinin bulunması

sürecidir (A. Zheng ve Casari, 2018; Heaton, 2016). Makine öğrenmesi ise öznitelik mühendisliği ile elde edilen en uygun öznitelik kümelerini girdi olarak kullanarak çıktı (karar) üreten bilgisayar algoritmalarının tasarlanması sürecidir (A. Zheng ve Casari, 2018; Heaton, 2016). En uygun öznitelik kümesinin bulunması öğrenme yönteminin performansını da büyük oranda etkilemektedir. Bilhassa, günümüz teknolojisinde bilgisayarların veriyi işleme yeteneğinin gelişmesine paralel olarak makine öğrenmesinin bir alt alanı olan derin öğrenme performansı eniyileyecek özniteliklerin öğrenilebilmesine olanak tanımaktadır. Bu bağlamda, derin öğrenme öznitelik mühendisliği ve makine öğrenmesinin birleştirildiği tümleşik çözümler sunarak daha yüksek performansta sistemlerin geliştirilmesine olanak tanımaktadır (LeCun ve diğ., 2015). Tez çalışması kapsamında MR ve X-Işını gibi hasta dostu görüntüleme yöntemleriyle elde edilen tıbbi görüntüleme özniteliklerinden yararlanılarak hastalıkların invasif olmayan yolla tespit edilebilmesine olanak tanıyan derin öğrenme temelli özgün OT sistemleri geliştirilmiştir. Tez çalışması kapsamında beyin kanserleri ile COVID-19 hastalığı konu alınmaktadır.

Beyin kanseri (Ostrom ve diğ., 2020) dünya genelinde morbidite ve ölümlülük oranlarındaki artışın en önemli sebeplerinden biridir. (Saenz del Burgo ve diğ., 2014)'de her yıl yaklaşık 238,000 insana merkezi sinir sistemi veya diğer bir beyin tümörü tanısı konulduğu belirtilmektedir. Uluslararası Kanser Araştırma Ajansı kayıtlarına göre 2020'de 308,000 tanılama ve 251,000 ölüm gerçekleştiği belirtilirken, 2030 yılında ise bu değerlerin sırasıyla 372,000 ve 303,000'e ulaşacağı öngörülmektedir (URL-1, 01.12.2021). Beyin tümör türlerinin özellikle erken dönemde görüntüleme öznitelikleri temelli tespit edilmesi hastalar için külfetli olan ve yüksek risk oluşturan biyopsiye iyi bir alternatif olmaktadır. Bu nedenle tümör türlerinin tıbbi görüntülerden tespit edilebilmesi önem arz etmektedir. Diğer bir yandan 2019 yılının Aralık ayında başlayan küresel COVID-19 salgını 5,5M'den fazla insanın ölümüne sebep olmuştur (URL-2, 12.01.2022). Birçok ülkede yoğun bakım üniteleri hastalığa neden olan SARS-COV-2 virüsünün enfekte etmiş olduğu hastalar ile dolmuştur. Bazı kaynaklarda hastalığın 2024 yılına kadar devam edeceği öngörülmektedir (Kissler ve diğ., 2020). Özellikle nüfusun fazla olduğu gelişmemiş ülkelerde salgının kontrol altına alınabilmesi için invasif olmayan alternatif tarama araçlarının geliştirilmesine ihtiyaç vardır. Tüm bu belirtilenler bu tez çalışmasında beyin kanseri ve COVID-19 hastalığının konu alınmasının ardındaki temel motivasyonu oluşturmaktadır.

MR, BT, PET, X-ışını ve Ultrasonografi gibi teknikler medikal görüntü analizi için yaygın olarak kullanılan görüntüleme tekniklerini oluşturmaktadır. MR, BT ve PET, beyin incelemelerinde kullanılabilen tekniklerdir. BT ve PET görüntüleme, hastalıkların tanılanmasında etkili olsa da bu görüntüleme yöntemlerinde hastaların maruz kalacağı radyasyon miktarı risk arz etmektedir. (Salmon ve diğ., 2015)'de PET'in elde edilmesi sürecinde hastanın farkedilemeyecek seviyedeki çok küçük baş hareketlerinde dahi elde edilen görüntünün çok sayıda artefaktlar içerebileceği belirtilmektedir. BT karşısında MR görüntüleme, sıfır iyonize radyasyon ve yüksek yumuşak doku karşıtlığı vermesi gibi özellikleri sayesinde hem hasta dostudur hem de görüntüleme öznitelikleri temelli tespiti kolaylaştırıcı bir yöne sahiptir. X-ışını görüntüleme tekniği ise BT yönteminin ucuz bir alternatifi olarak neredeyse tüm sağlık kuruluşlarında bulunmaktadır. Ayrıca, BT ile karşılaştırıldığında X-ışını tekniğinde hasta daha düşük radyasyona maruz kalmaktadır (Mettler ve diğ., 2008). Bu motivasyonla, tez çalışması kapsamında MR ve X-ışını görüntüleme özniteliklerinin kullanıldığı bilgisayar destekli tanı sistemlerinin geliştirilmesi hedeflenmiştir.

Son yıllarda uzmanlara verecekleri kararlarda destek olmak amacıyla geliştirilen bilgisayar destekli tanı sistemleri, görevin doğası için en uygun özniteliklerin optimizasyon süreci ile otomatik olarak öğrenilebilmesi sebebiyle derin öğrenme yaklaşımlarından yararlanılarak geliştirilmektedir. Bilgisayar destekli tanı sistemleri, öznitelik çıkartıcı olarak bir derin öğrenme modeli ile klasik makine öğrenmesi modelinin birleşiminden oluştuğu modüler yapıdaki sistemler ya da öznitelik çıkartma ve sınıflandırma/bağlanım birimlerinin birleştirildiği tümleşik yapıdaki sistemler olarak iki şekilde geliştirilebilmektedir. Daha iyi bir performansa ulaşılması temsil gücü daha yüksek özniteliklerin elde edilebilmesine olanak tanıyan yapıların geliştirilmesi ile mümkündür. Derin ağın ilk katmanlarında birçok görev için genel olan düşük seviyeli öznitelikler, ağ katmanlarında ilerlendikçe eldeki görev için daha ayırt edici niteliğe sahip yüksek dereceli soyut öznitelikler öğrenilmektedir. Buna rağmen, ağ derinliğinin artışı performansı düşürebilecek ince taneli detayların sönümlenebilmesine sebep olabilmektedir. İnce taneli detayların kurtarılması performansı iyileştirebilecektir. Bu motivasyonla, tez çalışması kapsamında derin ve sığ özniteliklerin kaynaşımına olanak tanıyan modüler ve tümleşik yapıdaki sistemler geliştirilerek performans iyileştirilmektedir.

Tez çalışmasının literatüre sunduğu ana katkılar aşağıda verilmektedir:

- Tümöre çevre dokularının dâhil edildiği bölgeden çıkartılan derin ve sığ özniteliklerin kaynaştırılarak kullanıldığı bir sınıflandırma çatısı önerilmektedir. Önerilen yöntem, sınıf içi değişintiyi azaltarak sınıf örneklerini birbirine yaklaştırırken, sınıflararası değişintiyi arttırıp sınıfları birbirinden uzaklaştırarak doğrusal ayrılabilirliğe katkıda bulunmaktadır. Geliştirilen sınıflandırma çatısı ile merkezi sinir sistemi tümörlerinin tümörlerinin (yani Gliom, Menenjiyom ve Hipofiz tümörleri) sınıflandırılması ve Düşük Evreli Gliomlarda (DEG) 1p/19q biyobelirtecinin eş silinme durumu tahmin performansı ortalama %10 iyileştirişebilmektedir (Öksüz ve diğ., 2022).

- Literatürde tıbbi görüntülerden çıkartılan el yapımı öznitelikler ile eğitilen geleneksel topluluk sınıflandırıcı modellerinin aksine ImageNet (Russakovsky ve diğ., 2015b) veri kümesi üzerinde eğitilerek birçok düşük ve yüksek dereceli öznitelik birleşimini öğrenmiş olan farklı derinlikteki hafif ağlar, ince ve kaba taneli özniteliklerin kaynaştırılabilmesi motivasyonu ile tümleştirilmiştir. Bu açıdan görüntülerden manuel olarak çıkartılan özniteliklerin tepesinde eğitilen bagging ve boosting gibi topluluk modellerine göre görüntüleme özniteliklerinin otomatik olarak çıkartıldığı ve performansı eldeki problem için optimize edecek *derin topluluk modeli* oluşturulmuştur. Böylelikle elde edilen uçtan uca eğitilebilir derin kodlayıcı yapısı ile COVID-19 pnömonisinin X-ışını görüntülerinden tespitinde %80'lik duyarlılığa ulaşılmıştır. Dahası, önerilen bu yapı ile X-ışını görüntülerinde belirgin imzalar taşımayan hafif ve orta şiddetli vakaların tespitinde sırasıyla %67 ve %93 duyarlılık elde edilmiştir. Elde edilen 5,62M parametreye sahip ağ yapısı görüntü başına 10ms gibi bir tahmin süresine sahiptir.

- X-ışını görüntülerinden COVID-19 hastalığının tespiti için önerilen, derin ve sığ özniteliklerin uçtan uca eğitilebilir yapı ile kaynaşımına olanak tanıyan *derin topluluk modelinin* bölütleme görevinde de performansı arttırdığı ortaya koyulmuştur. Bu bağlamda, kodlayıcı yapısı bir derin topluluk modeli olan ağ yapısına, hesapsal yükü düşürecek derin öğrenme tekniklerden yararlanılarak tasarlanan bir kod çözücü ağ yapısı eklenmiştir. Böylelikle, elde edilen bölütleyici ağ yapısı aktivasyon haritalarının ince ve kaba taneli detaylar ile sağlamlaştırılmasına olanak tanıyarak

akciğer çevritinin bulunmasında %3, beyin tümör çevritinin bulunmasında ise %2,37'lik bir performans artışı sağlamaktadır (Öksüz ve diğ., 2021).

- COVID-19 hastalığının şiddet skorlarının X-ışını görüntülerinden doğrudan tahmin edilebilmesine olanak tanıyan 2,19M parametreli çift başlı hafif ağırlıklı bir model önerilmiştir.

Tez çalışmasının ikinci bölümünde görüntüleme biyobelirteçleri (radyomikler), radyomiklerin elde edilmesindeki akış süreci, radyomiklerin sınıflandırılmasında kullanılan öğrenme yöntemleri tanıtılarak kavramsal arka plan sağlamak amaçlanmaktadır.

Tez çalışmasının üçüncü bölümünde beyin tümörlerinin MR görüntülerinden tespiti için literatürdeki mevcut yöntemler gözden geçirilmektedir. Ardından önerilen sınıflandırma çatısı tanıtılmaktadır. Bölümün sonunda önerilen yaklaşımın performansı değerlendirilerek literatürdeki çalışmalar ile karşılaştırılmaktadır.

Tez çalışmasının dördüncü bölümü X-ışını görüntülerinden COVID-19 pnemonisinin tespitine ve beşinci bölümü ise hastalığa ilişkin şiddet skorlarının X-ışını görüntülerinden kestirimine ayrılmıştır.

Tez çalışmasının altıncı bölümünde dördüncü bölümde sunulan topluluk ağı mimarisinin bölütleme görevinde de performansı iyileştirebildiği gösterilmektedir. Bölüm sonunda önerilen ağ yapısı ile elde edilen performans literatürdeki diğer çalışmalar ile karşılaştırılmaktadır.

Tez çalışmasının son bölümünde çalışma kapsamında önerilen yöntemler genel olarak değerlendirilmekte ve gelecekte yapılabilecek çalışmalar hakkında bilgi verilmektedir.

2. MEDİKAL GÖRÜNTÜLERDEN ÖZNİTELİK ÇIKARTMA VE SINIFLANDIRMA

Mevcut klinik işleyiş içerisinde radyolojik görüntüleme yöntemleri ile elde edilen sayısal tıbbi görüntüler, hassas tıp (Hodson, 2016) uygulamalarının desteklenebilmesi ve hastalıkların daha iyi anlaşılabilmesi açısından büyük bir öneme sahiptir. Buna rağmen, standart görüntüleme yöntemleri uzmanlar tarafından yorumlandığında hastalıklar hakkında yalnızca sığ bilgiler elde edilebilmektedir. Örnek bir durumu beyin kanserleri üzerinden vermek mümkündür. Beyin tümörüne sahip bir hastaya ait MR görüntüsü aracılığıyla tümörlü bölgenin şekli ve zıtlığı gibi genel bilgiler edinilebilmektedir. Ancak tıbbi görüntüler tüm bunların ötesinde daha zengin bir bilgi içeriğine sahiptir. Çeşitli hastalıklar hakkında kritik bilgiler içerebilen tıbbi görüntünün içeriği bilgisayar destekli yorumlama süreci ile belirlenebilmektedir.

Bilgisayar destekli yorumlama, sayısal tıbbi görüntülerin işlenmesi ve analiz edilmesi sürecidir. Sayısal tıbbi görüntülerin işlenmesi ve analizi, karar destek sistemlerinin oluşumunda yardımcı bir araç olan görüntüleme biyobelirteçlerinin elde edilmesi hedefiyle tıbbi verinin nicel veriye haritalanması süreci olarak tanımlanmaktadır (Limkin ve diğ., 2017). Bu süreç sonucunda elde edilen görüntüleme biyobelirteçleri aynı zamanda radyomikler olarak isimlendirilmektedir. (Lambin ve diğ., 2012)'de verilen başka bir tanıma göre ise radyomikler, radyografik görüntülerden büyük miktarda yüksek verimli görüntüleme özelliğinin çıkartılması süreci olarak tanımlanmaktadır. Tıbbi görüntülerden çıkartılan radyomikler farklı kanser türlerinin tespiti ve tanılanması, en uygun tedavi stratejisinin belirlenmesi, hastalığın seyri ve uygulanan tedaviye verilecek yanıtın tahmini gibi konular hakkında uzmanlara verecekleri kararlarda katkıda bulunarak ikinci bir görüş sağlamaktadır (Limkin ve diğ., 2017). Bir sonraki bölümde OT sistemlerinin geliştirilme süreci özetlenmektedir.

2.1. OT Sistemlerinin Geliştirilme Süreci

OT sistemleri Şekil 2.1'de verildiği gibi görüntü edinme, görüntü ön işleme, görüntü bölütleme, öznitelik çıkartma ve sınıflandırma/bağlanım gibi birbirini izleyen ortak adımlardan oluşmaktadır. Klinik karar sistemi oluşturmayı hedefleyen erken dönem çalışmalarında tüm bu adımların bağımsız birer birim olarak düşünüldüğü geleneksel

yöntem izlenmektedir. Daha güncel yöntemler, öznitelik çıkartma ve sınıflandırma/bağlanım gibi aşamaların tümleştirilebildiği daha etkili sistemlerin geliştirilebilmesine olanak tanımaktadır.

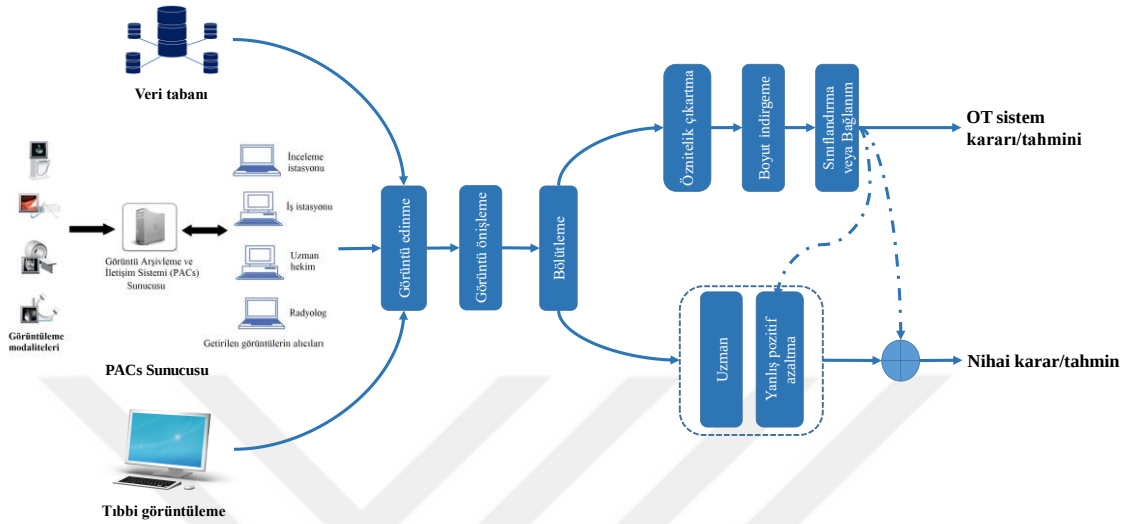

Şekil 2.1. Tipik bir bilgisayarlı tanı sistemini oluşturan birimler

Yukarıda söz edildiği üzere OT sistemleri aşağıdaki iki temel yaklaşımdan biri izlenerek geliştirilmektedir.

- Öznitelik çıkartma ve öğrenme aşamalarının bağımsız birer birim olarak geliştirildiği sistemler (Modüler Sistem)
- Öznitelik çıkartma ve öğrenme aşamalarının tek bir birim olarak geliştirildiği OT sistemleri (Tümleşik Sistem)

2.1.1. Modüler OT Sistemleri

Modüler OT sistemlerinde sistemi oluşturan kritik aşamaların her biri bağımsız olarak tasarlanmaktadır. Böylelikle tüm sistem bağımsız çalışan birimlerin sırasal olarak birleşiminden meydana gelmektedir. Alt bölümlerde modüler OT sistemlerini oluşturan kritik aşamalar özetlenmektedir.

2.1.1.1. Radyomik Çıkartma

Biyobelirteç, biyolojik bir durumun ölçülebilir işaretçisi olarak tanımlanmaktadır. Hastalıkların altında yatan nedenlerin kavranabilmesi için hastalığın işaretçileri olan biyobelirteçlerin elde edilmesi büyük bir öneme sahiptir. Bu amaca yönelik olarak klinik

rutinde sıklıkla gerçekleştirilen kan/idrar testleri ve biyopsi gibi işlemler sonucunda hastalardan invasif olarak toplanan tıbbi veriler geleneksel biyobelirteçleri oluşturmaktadır.

Hastalıkların altında yatan nedenlerin anlaşılması için tıbbi görüntüleme yöntemleri kullanılarak uzmanlar tarafından elde edilen radyolojik veriler diğer bir veri kaynağıdır. Görüntüleme ile elde edilen bilgi hastaya müdahala gerektirmediğinden oldukça değerlidir. Buna rağmen, radyografik görüntülerin uzmanlar tarafından incelenmesi yoluyla elde edilen bilgiler, şüpheli görülen bölgenin geometrik şekli, dokusu ve zıtlığı gibi oldukça sığ bir nitelik taşımaktadır. Dahası, radyografik görüntülerden hastalıklara ilişkin yapılan değerlendirmeler uzmandan uzmana farklılık gösterebilmektedir. Bu durum, değerlendirme sürecini öznel hale getirmektedir. Radyografik görüntüler hastalıkların altında yatan nedenlere ilişkin çok daha fazla bilgi içeriğine sahip olabilmektedir. Bu motivasyonla, hastalıkların altında yatan sebeplerin daha iyi anlaşılabilmesi amacıyla birçok araştırmacı ileri görüntü işleme tekniklerinden de yararlanarak anlamsal veri çıkartmak için radyografik görüntüleri analiz etmektedir. Geleneksel biyobelirteçlerin yanı sıra MR, BT, X-Işını, PET ve Ultrason gibi radyografik görüntülerden çıkartılan sayısal görüntüleme öznitelikleri radyomikler olarak bilinmektedir. Radyomikler, ilgilenilen bölgeleri karakterize eden özniteliklerdir. Herhangi bir hastalık için radyomiklerin hangi görüntüleme yöntemlerinden yararlanılarak çıkartılacağı ise büyük oranda hastalıklara ilişkin örüntülerin tıbbi görüntülerdeki belirginliğine bağlıdır. Örneğin beyin tümörlerinin tespitinde yaygın olarak kullanılan görüntüleme yöntemi, yüksek yumuşak doku karşıtlığı sağlaması sebebiyle MR görüntüleme olmaktadır. Beyin tümörlerinin tespitinde MR kadar yaygın olmasa da PET ve BT gibi görüntüleme yöntemlerinden de yararlanılabilmektedir. Bununla birlikte, akciğerlerle ilgili hastalıkların tespitinde yaygın olarak BT ve X-ışını görüntüleme yöntemleri kullanılmaktadır. Biyobelirteçlerin elde edilmesi süreci genel olarak Şekil 2.2'de verilmektedir. Literatürdeki çeşitli çalışmalarda klinik veriler, patolojik veriler ve diğer bir omik veri olan genomikler görüntülerden çıkartılan radyomik öznitelikler ile kaynaştırılarak çoklu omik veri elde edilmektedir. Radyomiklerin klinik ve omik veriler ile kaynaştırılması tamamlayıcı bilgi sağlamaktadır. Böylelikle, geliştirilecek modellerin tespit duyarlılığını arttırmak amaçlanmaktadır.

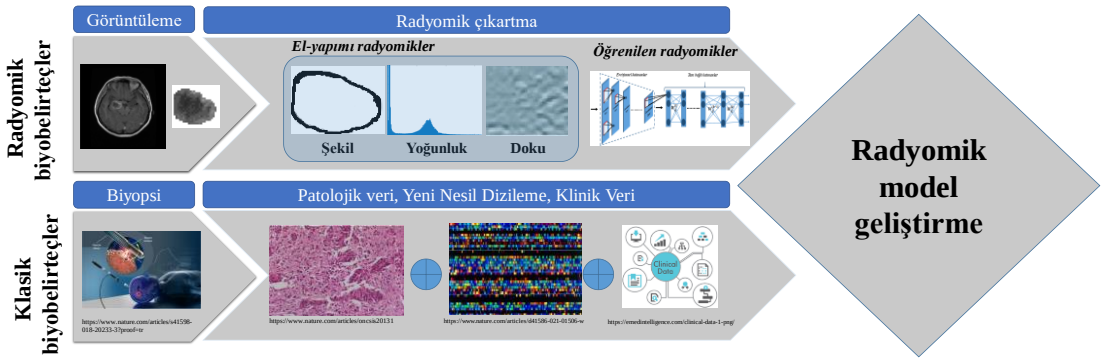

Şekil 2.2. Biyobelirteçlerin elde edilmesindeki süreçler (Limkin ve diğ., 2017)

Tıbbi görüntülerde radyomikler genel olarak manuel ya da tam otomatik bir bölütleme işlemi sonrasında elde edilen ilgilenilen bölgeden (Region of Interest: ROI) çıkartılmaktadır. Buna rağmen bazı çalışmalarda ROI'nin dışında kalan ilgilenilmeyen alanlar da öznitelik çıkartma sürecine dâhil edilmektedir. Literatürde çeşitli çalışmalarda her iki durumun performans üzerindeki etkisi değerlendirilmiştir (Afshar ve diğ., 2018).

Görüntülerden çıkartılan öznitelikleri sağladıkları istatistiksel bilgi bakımından birinci derece ve ikinci derece yöntemler olmak üzere iki genel kategoriye ayırmak mümkündür. Tıbbi görüntülerdeki hastalıklı bölgelerden çıkartılan ve bölgenin yüzeyini karakterize eden şekil, boyut gibi nicel tanımlayıcı öznitelikler birinci derece istatistiksel öznitelikler olarak tanımlanmaktadır. Birinci derece istatiksel bilgi yalnızca ilgilenilen bölge içerisindeki piksel veya voksel değerlerinin dağılımı hakkında bilgi sağlamaktadır. Öte yandan bu yaklaşımda pikseller arasındaki komşuluk ilişkileri (uzamsal ilişkiler) dikkate alınmadığından yeterince ayırt edici bilgi elde edilememektedir (El Naqa ve diğ., 2009). İkinci derece istatistik, pikseller ya da vokseller arasındaki uzamsal ilişkileri hesaba katarak daha etkili özniteliklerin elde edilmesine olanak tanımaktadır. İkinci derece istatistikten yararlanan yöntemlerden en yaygın kullanılanı Haralick tarafından tanıtılan gri seviye eş oluşum matrisidir (GLCM). Bu matris üzerinden zıtlık, enerji, homojenlik ve ilinti gibi öznitelikler çıkartılmaktadır (Haralick ve diğ., 1973). Bununla birlikte, GLRLM (Galloway, 1975), GLZLM (Thibault ve diğ., 2014) ve NGLDM (Sun ve diğ., 1983) uzamsal ilişkilerin dikkate alındığı diğer yöntemlerdir. Literatürde Gabor ve Fourier gibi filtreleme yöntemleri de uzamsal ve uzamsal-zamansal bilginin çıkartılması amacıyla kullanılmıştır (Narang ve diğ., 2016; Y. Zheng ve diğ., 2009). Belirtilen

yöntemler kullanılarak çıkartılan bazı sayısal değerlerin ROI'nin çevresine bağlılığı ilgili yöntemlerin temel kısıtlılığını oluşturmaktadır (Limkin ve diğ.,. 2017).

Tıbbi görüntülerde ROI'den yalnızca tek bir değerin elde edildiği bütünsel öznitelik çıkartma süreci izlenebilmektedir. Diğer bir yöntem ise ilgilenilen bölgenin yerel alt bölgelere ayrılarak her bir alt bölgeden çıkartılan özniteliklerin kaynaştırıldığı yerel öznitelik çıkartım sürecidir. Şekil 2.3(a)'da bütünsel, Şekil 2.3(b)'de ise yerel öznitelik çıkartma stratejileri gösterilmektedir. İkinci yaklaşım ile hesapsal yük artsa dahi ROI'den daha fazla ayırt edici nitelikte detayın çıkartılabilmesi sebebiyle performans iyileştirilebilmektedir.

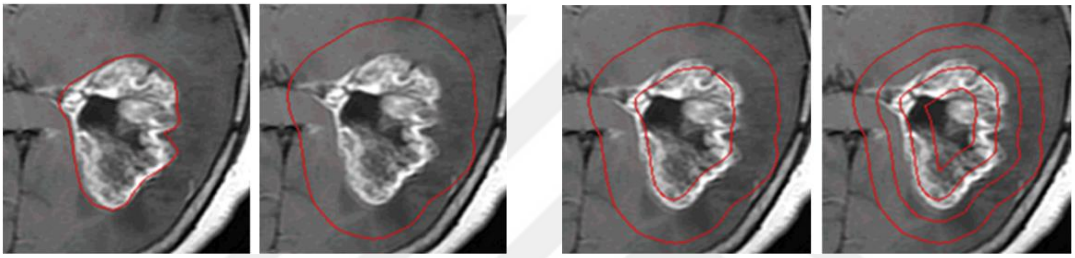

(a) (b)

Şekil 2.3. Öznitelik çıkartım stratejileri (Cheng ve diğ., 2015). (a) Bütünsel öznitelik çıkartma. (b) Yerel öznitelik çıkartma

Radyografik görüntülerden çıkartılan el-yapımı radyomiklerin yanı sıra ImageNet (Russakovsky ve diğ., 2015b) veri kümesi üzerinde eğitilen derin öğrenme modelleri de öznitelik çıkartma amacıyla kullanılabilmektedir. Derin öğrenme modellerinden çıkartılan öznitelikler *derin radyomikler* (Kobayashi ve diğ., 2021; Paul ve diğ., 2021) olarak adlandırılmaktadır. Eğitimli derin ağlar, tıbbi görüntüler ile eğitilmemiş olsalar dahi birçok problem alanı için ortak olan öznitelikler bu ağlar tarafından öğrenilmiştir. Bu sebeple, el-yapımı radyomikler karşısında hazır ağların uygun katmanlarından çıkartılan *derin radyomikler* daha yüksek bir temsil gücüne sahip olabilmektedir. Tablo 2.1'de medikal görüntülerden çıkartılabilen radyomikler genel anlamda özetlenmektedir.

2.1.1.2. Öğrenme

Radyomiklerin elde edilmesi sürecinde genellikle 50-5000 arasında öznitelik (p) çıkartılmaktadır (Arezzo ve diğ., 2021). Bununla birlikte çalışmalarda verilerin elde edildiği hasta sayısı (n) son derece azdır. Böylelikle $p \gg n$ olduğundan makine

Tablo 2.1. Medikal görüntülerden çıkartılan radyomikler

Domen	Öznitelik Çıkartma Yöntemi	Tanım
Uzamsal düzlem (domain) yöntemleri	Yoğunluk histogramı	İmge yoğunluk histogramından piksel yoğunluk değerleri ile ilgili bilgi elde edilir. Histogramdan ortalama, değişinti, çarpıklık, basıklık, entropi, enerji gibi öznitelikler çıkartılmaktadır.
	GLCM (Haralick ve diğ., 1973)	Piksel çiftleri arasındaki ilişkiler dikkate alınarak elde edilen matrislerden öznitelik çıkartım süreci yürütülür.
	GLRLM (Galloway, 1975)	
	NGLDM (Sun ve Wee, 1983)	
	GLZLM (Thibault ve diğ., 2014)	
	BoW (Csurka et al. 2004)	İmge alt bölgelere ayrılarak her bir bölgeyi tanımlayan vektörler elde edilir. Elde edilen tanımlayıcılar bir kümeleme algoritması ile gruplanır. Bulunan her bir grup merkezi bir özniteliği temsil etmektedir.
	LBP (Ojala ve diğ., 2002)	Histogram temelli yöntemlerdir. İmge yerel özniteliklerinin çıkartılmasına olanak tanır.
	HoG (Dalal ve Triggs, 2005)	
	SIFT (Lowe, 2004)	Rotasyon ve ölçek bağımsız özniteliklerin elde edilmesine olanak tanır. Hesapsal yükü ağırdır. İmgedeki bulanıklık ve ışıklılık değişimi gibi etkenler çıkartılacak özniteliklere olumsuz etki edebilmektedir.
	BRISK (Leutenegger ve diğ., 2011)	Yerel görüntü öznitelikleri yerel yoğunluk farkları temelli algoritmalar ile tespit edilmektedir. İkili öznitelikler elde edilmektedir.
	ORB (Rublee ve diğ., 2011)	
	MSER (Matas ve diğ., 2004)	Yerel öznitelikleri yoğunluk temelli algoritma ile tespit edilmektedir.
	SURF (Bay ve diğ., 2008)	Ölçek bağımsız yerel görüntü öznitelikleri yerel gradyanlar temelli algoritma ile tespit edilmektedir. Hesapsal yükü ağırdır.
	KAZE (Alcantarilla ve diğ., 2012)	Gürültü azaltılırken nesne sınır bilgisinin korunabilmesi için Gauss ölçek uzayı yerine doğrusal olmayan bir ölçek uzayında difüzyon filtreleme ile öznitelikler tespit edilmektedir (Alcantarilla, Bartoli, and Davison 2012).
	Derin öznitelikler	Öznitelikler eğitimli derin öğrenme modellerinden çıkartılmaktadır.
Dönüşüm düzlemi yöntemleri	Dalgacık (Andén ve Mallat, 2014)	Dalgacık dönüşümleri, işaretin ölçeğe bağlı olarak analizine olanak tanır. Böylelikle, çıkartılan öznitelikler uzamsal bilgi de içermektedir. Doku tanıma amacıyla kullanılabilmektedir.
	Fourier	Nesne sınır pikseller değerlerinin Fourier katsayıları şekil temelli özniteliklerin elde edilmesi için kullanılmaktadır (G. Zhang ve diğ., 2008).
	Gabor (Jain ve Farrokhnia, 1991)	Gabor filtreleri, yerel imge bölgelerinde belirli yönlerde belirli bir örüntüyü aramak için kullanışlıdır. Bu bağlamda doku analizi için yaygın olarak kullanılmıştır.

öğrenmesi alanında boyutluluk kâbusu (curse of dimensionality) (Clarke ve diğ., 2008) olarak bilinen bir durum ortaya çıkmaktadır. Son yıllarda farklı hastalıklar hakkında önemli ipuçları taşıdığı keşfedilen mikrodizilim veri kümeleri bu durumu örneklemektedir. Mikrodizilim veri kümelerinde her bir gen öznitelik olarak kabul edilmekte ve boyutluluk yaklaşık olarak 13000 seviyesine kadar ulaşabilmektedir. (Nutt ve diğ., 2003)'da yüksek evreli gliom tür tümörlerden, (D. Singh ve diğ., 2002)'de ise prostat tümör örneklerinden toplanan mikrodizilim veri kümelerinin sahip olduğu boyutluluğun sırasıyla 12625 ve 12600 olduğu belirtilmelidir.

Yüksek boyutlu veriler ile ilgili karşılaşılabilen iki önemli problemden biri verinin görselleştirilmesinde veya analiz edilmesindeki zorluktur. Makine öğrenmesi modellerinin boyutluluğu yüksek olan veri ile eğitilmesi ise karşılaşılabilen bir diğer önemli zorluktur. Bununla birlikte, tıbbi karar destek sistemi oluşturmayı hedefleyen birçok çalışmada diğer modellere göre boyutluluk daha iyi ele alınabildiğinden Karar Ağaçları ve Rassal Ormanlar (Hawkins ve diğ., 2016; Shen ve diğ., 2015), Destek Vektör Makinaları (Hastie ve diğ., 2009) gibi öğrenme yöntemlerinden yararlanılmaktadır.

Verideki boyut sayısının artmasının öğrenmenin gerçekleşmesi için gerekli kombinasyon sayısını da arttırması söz edilmesi gereken diğer bir durumdur. Bazı durumlarda modelin eğitiminde kullanılan eğitim örnekleri bazı kombinasyonların diğerlerinden daha sık oluşması sebebiyle tüm olası kombinasyonların yakalanamamasına sebep olabilmektedir. Eldeki eğitim örnekleri ile tüm olası kombinasyonların yakalanamaması veride seyreklik olarak nitelendirilmektedir. Böylece, seyrek nitelikli eğitim verisi ile bir modelin eğitimi değişinti hatasının artmasına neden olarak modelin görülmemiş örnekler üzerinde zayıf bir performans göstermesine sebep olabilecektir. Bu durum makine öğrenmesinde aşırı uydurma olarak adlandırılmaktadır (Limkin et al. 2017). Boyut indirgeme ve öznitelik seçme gibi yöntemler kullanılarak verideki artıklık azaltılabilmektedir (Kanas ve diğ., 2017). Böylelikle daha düşük boyutlardaki öznitelik uzayında modeller eğitilerek modellerin genelleme yeteneği de arttırılabilmektedir. Gözetimsiz teknikler sınıf etiketlerini gerektirmeyerek doğrusal ya da doğrusal olmayan bir dönüşüm aracılığıyla veriyi bilgi kaybının enküçüklendiği daha düşük boyutlardaki bir alt uzaya haritalamaktadır. Boyut indirgemeden farklı olarak öznitelik seçme yönteminde temel amaç eldeki görevin performansını enbüyükleyecek optimal öznitelik kümesinin elde

edilmesidir (Parmar ve diğ., 2015). Öznitelik seçme süreci genellikle sınıflandırma ve bağlanım gibi görevler için geliştirilecek modellerin eğitiminden önce bağımsız bir süreç olarak yürütülmektedir (Parmar ve diğ., 2015). Ancak tüm süreci kapsayacak tek bir matematiksel model olarak da ele alınabilmektedir. LASSO (Roth, 2004) ve ElasticNet (Zou ve Hastie, 2005) bu duruma örnek olarak verilebilmektedir. Beyin tümör türlerinin ayırt edilmesini hedefleyen (Öksüz ve Güllü, 2020)'daki çalışmada boyut indirgeme ve öznitelik seçme yöntemlerinden yararlanılarak elde edilen performanslar karşılaştırılmıştır. (Öksüz ve Güllü, 2020)'deki çalışma kapsamında hazır ImageNet (Russakovsky ve diğ., 2015b) modellerinden AlexNet ağının son katmanından 1000 boyutlu derin öznitelik vektörleri elde edilmektedir. Çalışmada boyut indirgeme yöntemi olarak PCA, öznitelik seçme için ise mRMR ve NCA yöntemlerinden yararlanılmaktadır. İki farklı bağımsız test kümesi üzerinde birbirine daha yakın performanslar PCA yöntemi ile toplam değişintinin %95'ini yakalayan 83 öznitelik kullanıldığında elde edilmiştir.

Destek Vektör Makineleri

Destek Vektör Makineleri (DVM) (Hastie ve diğ., 2009; Cortes ve Vapnik, 1995), maksimum pay (marjin) sınıflandırıcısı olarak da bilinen gözetimli bir öğrenme modelidir. Sınıflandırma problemlerinin yanı sıra bağlanım görevlerinde de kullanılabilmektedir. DVM, orijinal olarak ikili sınıflandırma problemleri için geliştirilen bir makine öğrenmesi modeli olsa da çoklu sınıflı problemlere de uyarlanabilmektedir. DVM modelinde Şekil 2.4'te gösterildiği gibi iki sınıf üyelerini ayıran maksimum marjine sahip bir karar düzlemi bulmak amaçlanmaktadır. DVM modeline ait matematiksel ifadeler aşağıda verilmektedir. Matematiksel olarak bir karar düzlemi Eşitlik (2.1)'deki gibi verilebilmektedir.

$$\mathrm{w}^T\mathrm{x} - b = 0 \tag{2.1}$$

Eşitlik (2.1)'deki w, karar düzleminin normal vektörünü; x, d-boyutlu gözlem vektörünü, b ise yanlılık değerini ifade etmektedir. $b/\|\mathrm{w}\|$, karar düzleminin orijinden uzaklığını ifade eden offset değerini belirtmektedir.

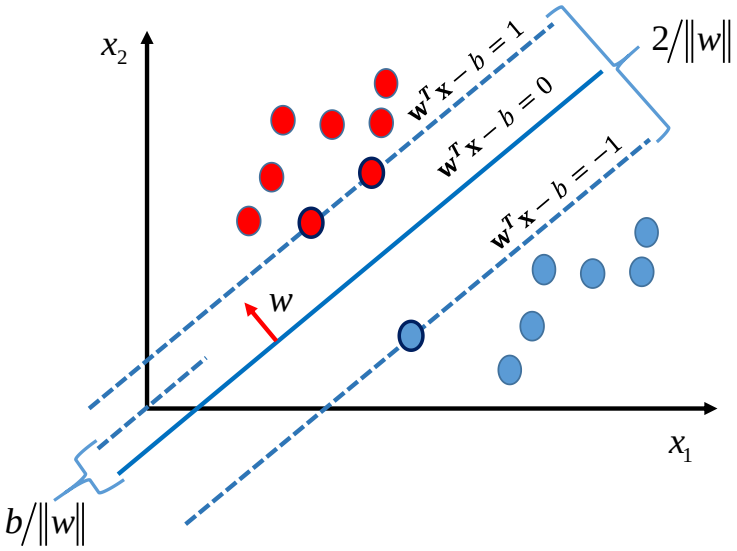

Şekil 2.4. DVM modelinin kavramsal gösterimi

Teoreme göre herhangi bir x_i vektörü $\mathrm{w}^T\mathrm{x}-b=1$ düzlemi üzerinde bir bölgeye düşerse ilgili sınıf etiketi $\mathrm{y}_i=+1$; eğer ilgili vektör $\mathrm{w}^T\mathrm{x}-b=-1$ düzlemi altında bir bölgeye düşerse $\mathrm{y}_i=-1$ olarak atanmaktadır. Şekil 2.4'te $\mathrm{w}^T\mathrm{x}-b=1$ ve $\mathrm{w}^T\mathrm{x}-b=-1$ düzlemleri üzerine düşen vektörler destek vektörleri olarak adlandırılmaktadır. Yöntemde maksimum marjine sahip bir karar düzlemi elde etmek hedeflendiğinden, düzlemler arasındaki mesafe $2/\|\mathrm{w}\|$'nin enbüyüklenmesi gerekmektedir. Böylelikle enbüyükleme problemi $\|\mathrm{w}\|$'nin $y_i(\mathrm{w}^T\mathrm{x}-b)\geq 1,\ 1\leq i\leq n$ kısıtına göre enküçüklenmesi problemine dönüşmektedir. Enküçükleme sonucunda w ve b için bulunan en uygun değerler sınıflandırıcı yapısını belirlemektedir. DVM sınıflandırıcı yapısı Eşitlik (2.2)'de verildiği gibi olmaktadır.

$$\hat{y}_i = sign(\mathrm{w}^T\mathrm{x}_i - b) \tag{2.2}$$

Şekil 2.4'te verilen marjin içerisinde herhangi bir gözlemin düşmediği örnek durum sert-marjin DVM olarak adlandırılmaktadır. Bunun yanında, belli bir hata payıyla marjin içerisine bazı gözlemlerin düştüğü durum yumuşak-marjin DVM olarak adlandırılmaktadır. Böylelikle gözlemlerin doğrusal olarak ayrılamadığı durumlarda da DVM modelinden yararlanılabilmektedir. Bu durumda *hinge* hata işlevi (ℓ_{hinge}) kullanılarak model optimizasyonu gerçekleştirilmektedir. Düzenlileştirme terimi eklenmiş hata işlevi Eşitlik (2.3)'teki gibi verilebilmektedir.

$$\ell_{hinge} = \max(0, 1 - y_i(\mathrm{w}^T \mathrm{x}_i - b),$$
$$\ell = \lambda \|\mathrm{w}\|^2 + \left[\frac{1}{n} \sum_{i=1}^{n} \max(0, 1 - y_i(\mathrm{w}^T \mathrm{x}_i - b)) \right] \quad (2.3)$$

Eşitlik (2.3)'teki λ, marjinin genişliğini kontrol eden ceza parametresini ifade etmektedir.

Karar Ağacı

Karar ağacı sınıflandırma ve bağlanım görevlerinde kullanılmak üzere geliştirilen gözetimli ve parametrik olmayan bir öğrenme modelidir. Karar ağacı, şartsal durumlara bağlı olarak akış çizelgesi şeklinde tasarlanan bir yapıya sahiptir. Şekil 2.5'te verildiği gibi bir karar ağacı yapısı, kök adı verilen birimden dallanarak dâhili düğümleri oluşturmakta ve ardından yaprak adı verilen düğümlerde sonlanmaktadır.



Şekil 2.5. Karar ağacı yapısı

Şekil 2.5'te verilen yapıda kök ve dâhili düğümler verideki boyutları, yapraklar ise etiketleri temsil etmektedir. Kök ve dâhili düğümlerin belirlenmesinde ise verinin sahip olduğu bilgi içeriği (saflık derecesi, homojenlik) öneme sahiptir. Diğer bir ifadeyle, en yüksek homojenliğe sahip değişken, kök ya da düğüm olarak belirlenmektedir. Düğüm aday değişkenlerinin saflık derecesi ise, Gini indeksi, entropi ve standart sapma gibi ölçütler ile değerlendirilmektedir. CART ve ID3 gibi algoritmalar karar ağacı oluşturmak için yaygın olarak kullanılmaktadır (Hastie ve diğ., 2009).

k En Yakın Komşuluk Modeli

k en yakın komşuluk modeli (k-NN), sınıflandırma ve bağlanım görevleri için kullanılan parametrik olmayan bir algoritmadır (Hastie ve diğ., 2009). Algoritmadaki k, en yakın komşu sayısını ifade etmektedir. Bu bağlamda, sınıflandırma görevlerinde her bir gözlem için en yakın k-komşunun sınıf etiketlerinin çoğunluğuna göre sınıf üyeliği atanmaktadır.

Yanlılık ve Değişinti Hatası

Verideki sinyali yakalamak üzere kestirilen modellerin orijinal modele ne denli yakın olduğu belirsizdir. Böylelikle modeller belli bir hata ile kestirilmektedir. Bu durum matematiksel olarak Eşitlik (2.4) ve Eşitlik (2.5)'te verilen ifadeler ile açıklanabilmektedir.

$$\begin{aligned} b_{\hat{h}} &= y - E[\hat{h}], \;\; y = f + \varepsilon, \\ \sigma^2_{\hat{h}} &= E\left[\hat{h}^2\right] - E\left[\hat{h}\right]^2, \\ \sigma^2_{\varepsilon} &= E\left[\varepsilon^2\right] - E\left[\varepsilon\right]^2, \\ &\quad 0 \end{aligned} \tag{2.4}$$

Eşitlik 2.4'te y, $\hat{h}$ ve ε sırasıyla orijinal modeli, kestirilen model ve gürültüyü ifade etmektedir. Eşitlik 2.4'te verilen $b_{\hat{h}}$, $\sigma^2_{\hat{h}}$ ve σ^2_{ε} ifadeleri ise model yanlılığını, model değişintisi ve gürültü değişintisini belirtmektedir. Eşitlik 2.5'te kestirilen modelin ortalama karesel hatası verilmektedir. Eşitlik 2.5'te elde edilen ifadeye göre giriş ve çıkış arasındaki haritalama fonksiyonunu öğrenmek için eğitilen makine öğrenmesi modellerinin ürettikleri hataları aşağıdaki üç genel kategoriye ayırmak mümkündür.

- İndirgenemez hatalar (σ^2_{ε})
- İndirgenebilir hatalar
  - Yanlılık hatası ($b_{\hat{h}}{}^2$)
  - Değişinti hatası ($\sigma^2_{\hat{h}}$)

$$
\begin{aligned}
E\left[\left(f+\varepsilon-\hat{h}\right)^2\right] &= E\left[\left(f+\varepsilon-\hat{h}+E\left[\hat{h}\right]-E\left[\hat{h}\right]\right)^2\right] \\
&= E\left[\left(\left(f-E\left[\hat{h}\right]\right)+\left(\varepsilon-\hat{h}+E\left[\hat{h}\right]\right)\right)^2\right] \\
&= E\left[\underbrace{\left(f-E\left[\hat{h}\right]\right)^2}_{b_{\hat{h}}}+\left(\varepsilon-\hat{h}\right)^2+E\left[\hat{h}\right]^2+2\left(\varepsilon-\hat{h}\right)E\left[\hat{h}\right]\right] \\
&= E\left[b_{\hat{h}}{}^2+\varepsilon^2+\hat{h}^2-2\varepsilon\hat{h}+E\left[\hat{h}\right]^2+2\left(\varepsilon-\hat{h}\right)E\left[\hat{h}\right]\right] \\
&= b_{\hat{h}}{}^2+\underbrace{E\left[\varepsilon^2\right]}_{\sigma_\varepsilon^2}+E\left[\hat{h}^2\right]-\underbrace{2E\left[\varepsilon\right]E\left[\hat{h}\right]}_{0}+E\left[\hat{h}\right]^2+\underbrace{2E\left[\varepsilon\right]E\left[\hat{h}\right]}_{0}-2E\left[\hat{h}\right]^2 \\
&= b_{\hat{h}}{}^2+\underbrace{E\left[\hat{h}^2\right]-E\left[\hat{h}\right]^2}_{\sigma_{\hat{h}}^2}+\sigma_\varepsilon^2 \\
&= b_{\hat{h}}{}^2+\sigma_{\hat{h}}^2+\sigma_\varepsilon^2
\end{aligned}
\tag{2.5}
$$

İndirgenemez hatalar, modelin geliştirildiği algoritmadan bağımsız olup, giriş verisinin çıkışa haritalanmasında etki sahibi olan ve bilinmeyen değişkenler nedeniyle oluşan hatalardır. Kaynağı bilinen hatalar ise indirgenebilmektedir. Yanlılık ve değişinti hataları, makine öğrenimi modelleri ile karşılaşılabilen kaynağı bilinen iki önemli hata türüdür. Her iki hata, modellerin genelleme yeteneğini düşüren bir özelliğe sahip olduğundan bu hataların enküçüklenmesi gerekliliktir. Yanlılık hatası, modelin eğitim verisini karakterize eden sinyali yakalayabilecek karmaşıklığa sahip olmamasından kaynaklanmaktadır. Özetle, model olması gerekenden daha az karmaşıklığa sahip olduğunda yanlılık hatası meydana gelmektedir. Bunun bir sonucu olarak modelin tahmin performansı azalmaktadır. Bu durum *yetersiz uydurma* (under-fitting) olarak bilinmektedir. Öğrenilen haritalama fonksiyonu olması gerekenden fazla karmaşaya sahip olduğunda değişinti hatası meydana gelmektedir. Modelin eğitim verisini karakterize edecek gerçek sinyali öğrenmek yerine gürültüyü öğrenmiş olması bu durumun temel sebebidir. Sonuç olarak, model eğitildiği küme üzerinde aşırı iyimser bir performans sağlarken, farklı veri kümeleri üzerindeki tahmin performansı fazlasıyla düşmektedir. Bu durum, *aşırı uydurma* (over-fitting) olarak adlandırılmaktadır. Genellikle doğrusal olmayan makine öğrenmesi algoritmaları model karmaşıklığını arttırabilen fazlaca parametre içermektedir. Böylelikle aşırı uydurma riski artmaktadır.

Karar ağaçları gibi yapılar fazla parametreye sahip olup değişinti hataları yüksek ve dolayısıyla aşırı uydurma riski oluşturmaya eğilimlidir. Ağ budama gibi stratejilerden yaralanılarak değişinti hatası ve aşırı uydurma riski azaltılabilmektedir (James ve diğ., 2013). Bir genelleme yapmak gerekirse:

- Doğrusal modeller (Doğrusal Ayırtaç, Lojistik Regresyon, Doğrusal Regresyon) için yanlılık hatası yüksek ancak değişinti hatası düşük olmaya eğilimlidir.

- Doğrusal olmayan modeller (Karar Ağaçları, k-NN, Destek Vektör Makinaları) için yanlılık hatası düşük ancak değişinti hatası yüksek olmaya eğilimlidir. Örnek bir durum olarak k-NN modeli dikkate alındığında, *k* parametresinin arttırılması model karmaşıklığını azaltarak yanlılık hatasını arttırmaktadır. Dolayısıyla yanlılık hatasının azaltılması için parametre optimizasyonu gerekmektedir.

Şekil 2.6'da yanlılık-değişinti hatası ve model karmaşıklığı arasındaki ilişki özetlenmektedir. Anlaşılabileceği gibi yanlılık ve değişinti hataları arasında daima bir ödünleşim bulunmaktadır. Her iki hatayı eş zamanlı olarak enküçüklemek mümkün değildir. Genellikle pratik uygulamalarda öğrenilen haritalama fonksiyonunun analitik formu bilinemediğinden yanlılık ve değişinti hatasının ölçülmesi mümkün olmamaktadır. Buna rağmen en uygun model karmaşıklığına, modelin eğitim ve test performansı gözlenerek karar verilebilmektedir.

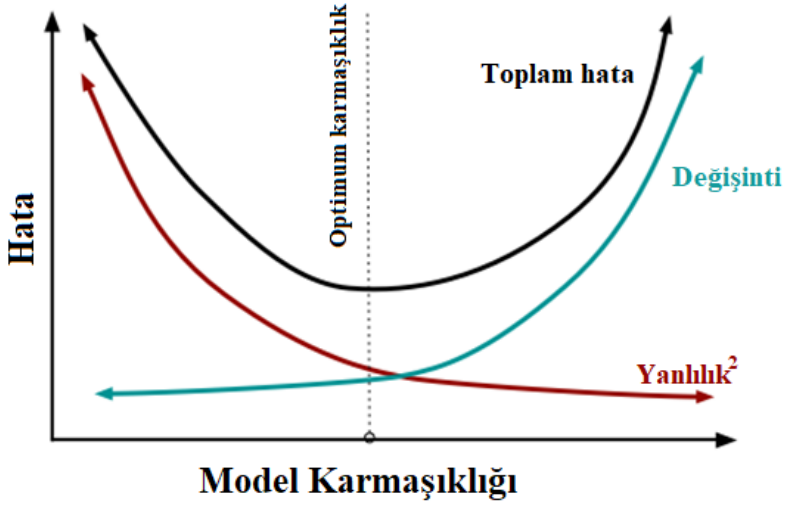

Şekil 2.6. Yanlılık-değişinti hatası ve model karmaşıklığı ilişkisi (Şekil kaynak: URL-3)

Bagging (Bootstrap aggregation) ve Boosting gibi topluluk modeli oluşturma algoritmaları kullanılarak sırasıyla, değişinti ve yanlılık hataları azaltılabilmektedir.

Topluluk Modelleri

Topluluk modelleri önceki bölümde açıklanan yanlılık ve değişinti hatalarını indirgeyebilmek amacıyla oluşturulmaktadır. Topluluk modelleri bagging ve boosting olarak bilinen iki yaklaşımdan biri ile oluşturulmaktadır. Bagging ile temelde aşırı uydurmaya eğilimli ve düşük yanlılığa sahip modeller bir araya getirilerek gürültü yumuşatılmaktadır. Böylelikle, yanlılık değişmezken değişinti hatası azaltılabilmektedir. Bagging için yararlanılan en popüler yöntem Rassal Ormanlar (Random Forest) algoritmasıdır (Hastie ve diğ., 2009). Bu algoritmada birbiri ile ilişkisiz olan çok sayıda karar ağacı bir araya getirilmektedir.

Boosting algoritmasında ise çok sayıda zayıf öğrenme modeli (weak learner) bir araya getirilerek yanlılık azaltılmaktadır. Boosting için yararlanılan en popüler yöntem Uyarlamalı Boosting (AdaBoost) algoritmasıdır (Freund ve Schapire, 1997). AdaBoost algoritmasında, zayıf modeller iteratif olarak oluşturulan topluluk modeli yapısına eklenmektedir.

2.1.2. Tümleşik OT Sistemleri

Güncel çalışmaların önemli bir çoğunluğunda manuel öznitelik çıkartma sürecinin atlanarak öznitelik çıkartma sürecinin otomatik hale getirilmesi ve klasik makine modellerinden daha üstün performansların elde edilebilmesi sebebiyle Evrişimli Sinir Ağı (ESA) mimarileri (Öksüz ve diğ., 2020) geliştirilmektedir.

2.1.2.1. Derin Öğrenme

Temsil öğrenme; ham verinin sistem tarafından girdi olarak alınmasından sonra işlenerek sınıflandırma, nesne algılama, imge bölütleme ve bağlanım gibi görevler için performansı eniyileyecek temsillerin otomatik olarak öğrenilmesi sürecidir. Derin öğrenme, ilgili görev için temsillerin otomatik olarak öğrenilebilmesine olanak tanıyan yöntemler bütünü olarak tanımlanabilmektedir. Bir derin öğrenme yapısı her bir seviyesinde (katman) giriş görüntüsünün farklı temsillerinin öğrenildiği birden çok seviyeden oluşmaktadır. Yapının her bir katmanında giriş ve çıkış arasında doğrusal olmayan haritalama fonksiyonu öğrenilmektedir. Bu nedenle bazı kaynaklarda derin öğrenme modeli her bir katmanının öğrenme işine adanmış olduğu çok katmanlı ağ mimarisi olarak da tanımlanabilmektedir

(LeCun ve diğ., 2015). Ağın ilk katmanlarında birçok problem alanı için ortak olan kenar gibi düşük seviyeli bilgiler öğrenilmektedir. Katmanlar ilerledikçe kenarların birleşimiyle elde edilen desenler öğrenilirken, son katmanlara doğru göreve özel olan daha karmaşık ve yüksek dereceli öznitelikler öğrenilmektedir. Derin öğrenme modellerini klasik makine öğrenmesi modellerinden ayıran temel özellik, öğrenme ve sınıflandırma/bölütleme/bağlanım gibi süreçleri tümleştiren tek bir yapı sunmasıdır. Bu açıdan bakıldığında tüm ağ yapısı için öğrenme işlemi öznitelik öğrenmenin gerçekleştiği evrişimsel katmanlar ve öğrenilmiş özniteliklerin vektörel forma getirilip (düzleştirme) işlenerek daha yüksek dereceli özniteliklerin öğrenildiği tam bağlı katmanlar olmak üzere iki farklı düzende gerçekleştirilmektedir.

Öğrenme, bir grup denklem takımının ağırlıklarının eniyilenmesi süreci olarak da tanımlanabilir. Bu bağlamda, ağdaki öğrenilebilir olan tüm parametreler önceden belirlenen bir hata işlevinin enküçükleyecek şekilde her bir dönemde (epoch) güncellenmektedir. Ağın evrişimsel katmanlarında önceden yapılandırılmış çekirdeklere ait ağırlıklar eğitim süresi zarfında performansı eniyileyecek olan değerlere yakınsamaktadır. Benzer şekilde tam bağlı katmanlardaki her bir hesaplama elemanı (aktivasyonlar) için ağırlıklar en uygun değerlerine yakınsanmaktadır.

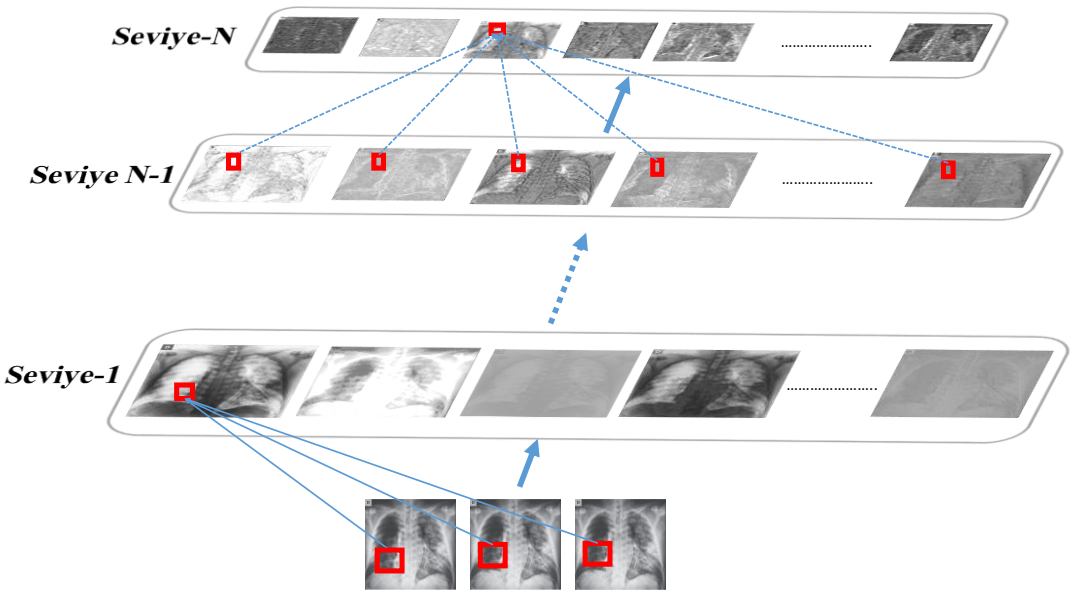

Şekil 2.7. Üç kanallı bir akciğer grafisinin derin bir ağın ilgili seviyelerindeki örnek temsilleri

Şekil 2.7'de eğitimli derin bir ağa beslenen akciğer grafisinin ağ tafından her bir seviyede nasıl görüldüğüne ilişkin temsiller verilmektedir. Şekil 2.7'de verilen betimlemeden anlaşılabileceği gibi giriş görüntüsü her bir seviyede ağ tarafından farklı şekillerde görülmektedir. Dahası, her bir seviyede giriş boyutları indirgenerek eldeki veriye ilişkin detaylar azaltılmaktadır. Böylelikle, veri her bir katmanda farklı bir soyutluluk seviyesinde ele alınmaktadır. Eldeki görev için gerekli seviye sayısına karar verilmesi ise görevin karmaşıklığına bağlı olup deneysel bir süreçtir.

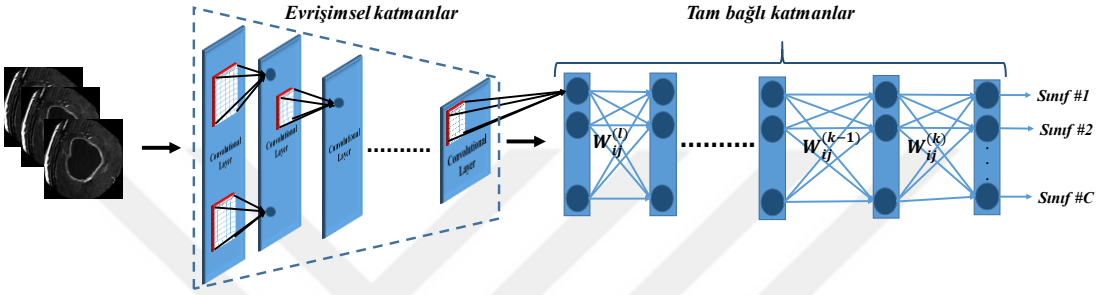

Şekil 2.8. Genel bir ESA mimarisi

Genel bir ESA mimarisi, Şekil 2.8'deki gibi evrişimsel katmanların ardından gelen tam bağlı katmanlardan oluşmaktadır. Şekil 2.8'de verilen her bir evrişimsel ve tam bağlı katmana; normalizasyon katmanı, aktivasyon işlevi ve havuzlama katmanı gibi birimler dâhil edilmektedir. Aşağıda verilen alt başlıklarda ESA'yı oluşturan birimler kısaca açıklanmaktadır.

Evrişimsel Katman

Evrişimsel katman, ESA mimarilerinde yerel görüntü özelliklerin otomatik olarak öğrenildiği katmandır. Ağın evrişimsel katman çıkışları Eşitlik (2.6)'da verildiği gibi hesaplanmaktadır.

$$x_j^l = \sum_{l=1}^{N} W_{ij}^{l-1} * x_i^{l-1} + b_j^l \tag{2.6}$$

Eşitlik (2.6)'daki, W^{l-1}, $l-1$ katmanındaki çekirdek ağırlıklarını; x_i^{l-1}, katman girişindeki imgeyi; $b_j{}^l$, l katmanındaki j. aktivasyon haritasına ait yanlılık (bias) terimini; $*$ ise evrişim operatörünü ifade etmektedir.

Şekil 2.9'da ESA mimarilerinde evrişim işlemi kavramsal olarak gösterilmektedir. Şekil 2.9'da görüldüğü gibi ilgili bir katmandaki *k* sayıda çekirdek ($W^{(1)}, W^{(2)}, ..., W^{(k-1)}, W^{(k)}$) içeren tensörün giriş imgesi ile evrişim işlemi sonucunda *k* sayıda aktivasyon haritası ($A^{(1)}, A^{(2)}, ..., A^{(k-1)}, A^{(k)}$) elde edilmektedir. Tensördeki her bir çekirdek, giriş görüntüsünün yerel bölgelerindeki ilgili bir özelliğin çıkartılmasından sorumludur. Aktivasyon haritasını (özellik haritası) oluşturan hücreler (örnek: $A_1^{(k)}, A_2^{(k)}, ..., A_n^{(k)}$) bir nöronun (hesaplama ünitesi) çıkışını temsil etmektedir. Böylelikle her bir hücre nöronun gördüğü alan ile orantılı bir değere sahip olmaktadır. Nöron tarafından algılanan bu alan, alıcı ya da reseptif alan olarak ifade edilerek yerel öznitelik çıkartma sürecinde büyük bir rol oynamaktadır. Diğer bir yandan, tek bir hücrenin ilgili reseptif alana göre alacağı değerin belirlenmesi Şekil 2.9'un sağında verilen tek katmanlı algılayıcı model ile açıklanabilmektedir.

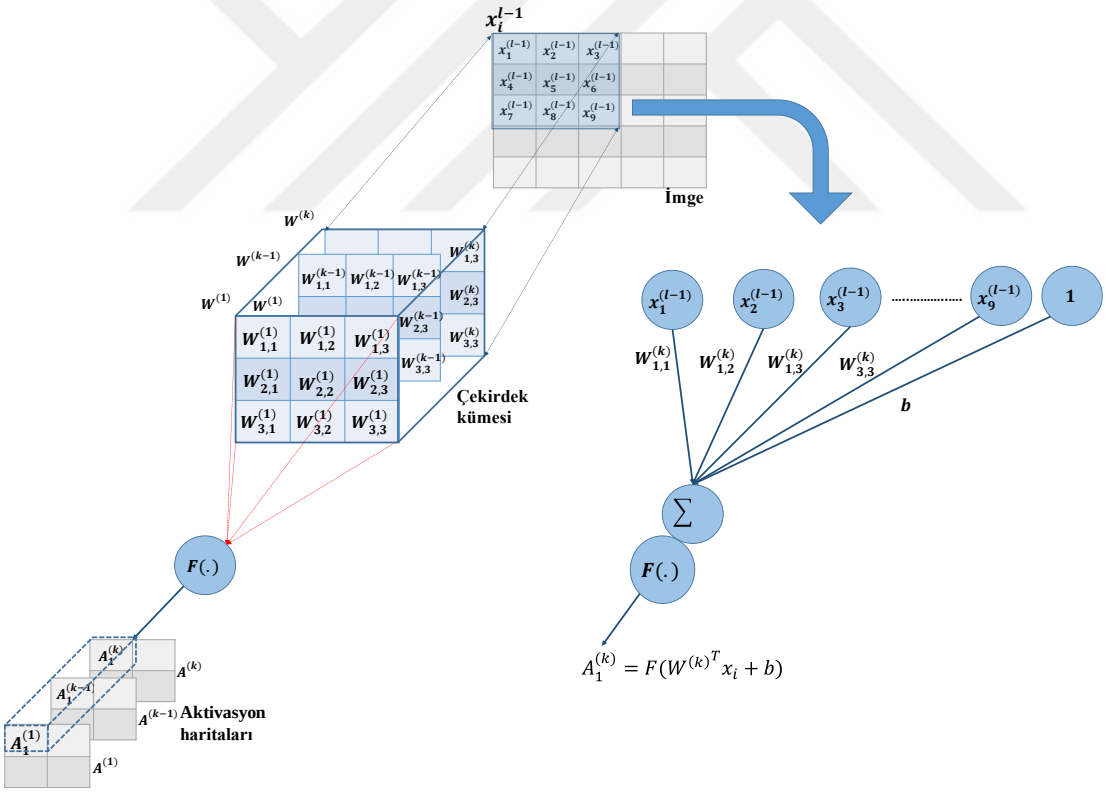

Şekil 2.9. ESA mimarilerinde evrişim işleminin kavramsal olarak gösterimi

Yığın Normalleştirme Katmanı

Evrişimsel sinir ağları daha önce de belirtildiği gibi ilgili görev için tasarlanan birbiri ardına bağlanmış birçok katmandan oluşan uçtan uca eğitilebilir yapılardır. Bu durum,

ağda katman-katman işlenerek ilerleyen verinin dağılımını değiştirebildiğinden ağın öğrenme hızı etkilenebilmektedir. Diğer bir yandan, derin ağ yapılarını oluşturan her bir katmandaki ağırlıklara eğitim öncesinde rastgele olarak başlangıç değerleri atanmaktadır. Bu durum ise ağı ilklendirme işlemlerine duyarlı hale getirmektedir. Gerek katmanlara girdi olan verinin sahip olduğu rastgelelik, gerekse ilklendirme işleminin oluşturduğu rastgelelik sebebiyle ağ eğitimin olumsuz olarak etkilenmesi literatürde dâhili eş-değişken kayması olarak ifade edilmektedir (Ioffe ve Szegedy, 2015). Yığın normalleştirme işlemi derin ağın eğitilmesinde karşılaşılabilen bu problemlerin aşılabilmesi için verinin yeniden merkezlenmesi ve ölçeklenmesini sağlamaktadır (Ioffe ve Szegedy, 2015). Böylelikle derin ağı oluşturan ağırlıkların daha hızlı yakınsaması mümkün olmaktadır. Yığın normalleştirme sürecinin temel işlemleri aşağıdaki eşitliklerde ifade edilmektedir. Eşitlik (2.7)'de verilen B, ağın eğitimi için kullanılacak olan verinin yığın olarak adlandırılan bir bloğunu ifade ederken, μ_B yığın ortalamasını, ${\sigma_B}^2$ ise yığın değişintisini ifade etmektedir.

$$\mu_B = \frac{1}{m}\sum_{i=1}^{m} x_i, \quad {\sigma_B}^2 = \frac{1}{m}\sum_{i=1}^{m}\left(x_i - \mu_B\right)^2 \tag{2.7}$$

Normalleştirme işlemi Eşitlik (2.8)'de verildiği gibi ağın her bir katmanında, katmana girdi olan d boyutlu x_i vektörünün her bir boyutunda Eşitlik (2.7)'deki ifadelerden yararlanılarak gerçekleştirilmektedir.

$$x_i^{(k)} = \frac{x_i^{(k)} - \mu_B^{(k)}}{\sqrt{{\sigma_B}^{(k)^2} + \varepsilon}}, \quad i \in [1,\, m],\ k \in [1,\, d] \tag{2.8}$$

Eşitlik (2.8)'in paydasında yer alan ε ifadesi oldukça küçük bir sabit olup, dikkate alınmadığı durumda elde edilen veri sıfır ortalama ve birim değişintiye sahip olmaktadır. Eşitlik (2.8)'deki m ifadesi ise yığın boyutunu belirtmektedir. Normalleştirmenin son adımı Eşitlik (2.9)'daki gibi verilebilmektedir.

$$y_i^{(k)} = \gamma^{(k)} x_i^{(k)} + \beta^{(k)} \tag{2.9}$$

Buna göre Eşitlik (1.9)'da verilen $\beta^{(k)}$, $\gamma^{(k)}$ eğitilebilir parametreler olup, ağın eğitimi süresince en uygun değerlerine yakınsayarak veri normalleştirilmektedir.

Genel olarak bakıldığında yığın normalleştirme işleminin bir katmana gelen m boyutlu $x^{(k)}_{i=1,2,\ldots,m}$ yığınını, $y^{(k)}_{i=1,2,\ldots,m}$ ifadesine haritalayan bir dönüşümü gerçekleştirdiği söylenebilir. Literatürde yığın normalleştirme işleminin dâhili eş-değişken kaymasını önlemek yerine performansı iyileştirme yönünde etki oluşturan amaç fonksiyonunu yumuşattığına yönelik görüşler bulunmaktadır (Santurkar ve diğ., 2019). Yığın normalleştirmenin bilinen bu olumlu etkileri karşısında (Brock ve diğ., 2021)'deki güncel bir çalışmada yığın normalleştirme işlemine olan gereksinimi azalttığı belirtilen normalleştirmesiz ağlar (NF-Nets) tanıtılmaktadır.

Havuzlama Katmanı

Havuzlama katmanları girişine gelen aktivasyon haritalarındaki baskın bölgeleri çıktı olarak döndürme görevini gerçekleştirmektedir. Havuzlama işlemi, evrişim işlemine benzer şekilde eldeki aktivasyon haritaları üzerinde kayan yerel pencereler ile dolaşılarak gerçekleştirilmektedir. Havuzlama, aktivasyon haritası üzerinde özel bir konuma karşılık gelen yerel pencere içerisindeki en baskın değer (maksimum havuzlama) ya da tüm yerel pencere içerisindeki değerlerin ortalaması (ortalama havuzlama) dikkate alınmak üzere iki yöntemden biri tercih edilerek gerçekleştirilmektedir.

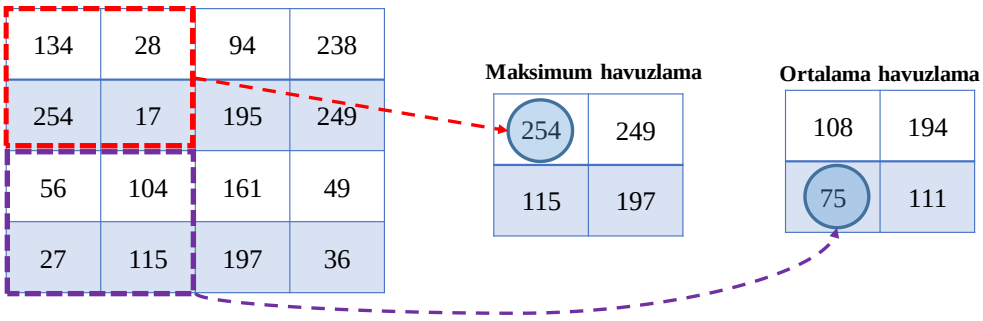

Şekil 2.10. Maksimum ve ortalama havuzlama işlemlerinin örneklendirilmesi

Şekil 2.10'da 4×4 boyutlarına sahip bir matris üzerinde 2×2 boyutlarda bir pencere ile her seferinde 2 atlama yapılacak şekilde gerçekleştirilen maksimum ve ortalama havuzlama işlemleri örneklendirilmektedir. Şekil 2.10'da verilen basit bir örnek durumdan da anlaşılacağı gibi havuzlama işlemleri sonucunda girişteki verinin özeti niteliğine sahip

yeni bir veri elde edilmektedir. Böylelikle veri gereksiz detaylardan arındırılmaktadır. Havuzlama işlemlerinin bu özelliği ağın öğrenilebilir parametre sayısının önemli ölçüde azaltılmasını sağlayarak daha derin ağların eğitilebilmesine olanak tanımaktadır. Sonuç olarak, ağ derinliğinin artması ile daha fazla öznitelik çıkartılarak eldeki görevin performansı da iyileştirilebilmektedir.

Tam Bağlı Katmanlar ve Aktivasyon İşlevleri

Tam bağlı katman, Şekil 2.11'de gösterildiği gibi birbiri ardına dizilmiş bir dizi hesaplama ünitesinden oluşan vektörel forma sahip bir birim olarak tanımlanabilir. Birim içerisindeki her bir hesaplama elemanı kendinden önceki katmandan gelen veriyi girdi olarak almaktadır. Böylelikle, hesaplama birimleri arasındaki bağlantılar sayesinde bir ağ yapısı oluşmaktadır. Ardından, hesaplama birimleri Şekil 2.11'de açıklandığı gibi giriş verisinin ağırlıklı toplamlarını çıkışlarına aktarmaktadır.

Aktivasyon işlevleri ise derin ağlardaki hesaplama birimlerinden sonra ilgili nöronların aktiflik durumunu belirlemek amacıyla kullanılmaktadır. Şekil 2.11'de aktivasyon işlevinin nasıl gerçekleştirildiği gösterilmektedir. Buna göre, her bir hesaplama biriminden elde edilen çıkış aktivasyon işlevine giriş argumanı olarak alınarak yeni bir çıkış elde edilmektedir.

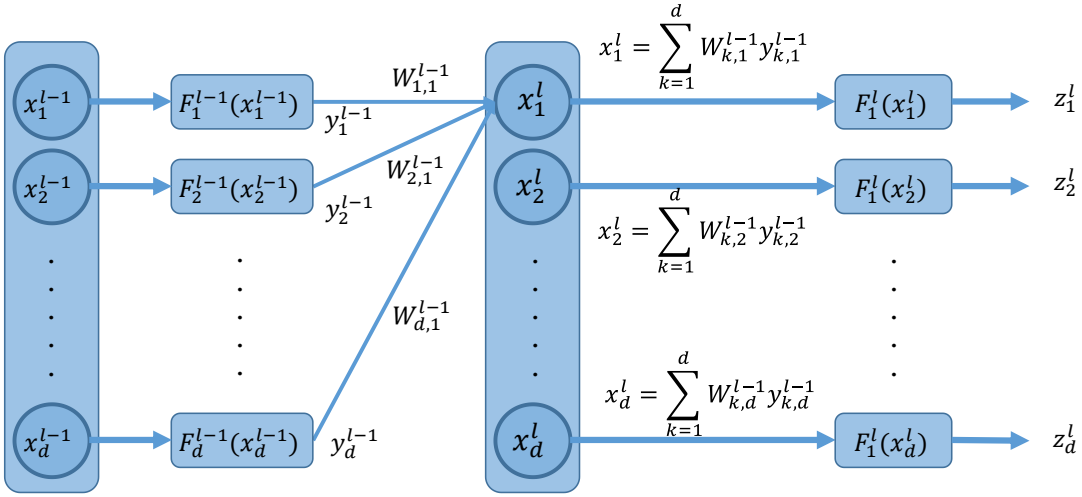

Şekil 2.11. Aktivasyon işlevinin örneklendirilmesi

ESA mimarilerinde yaygın olarak kullanılan aktivasyon işlevlerinden bazıları aşağıda verilmektedir.

Basamak işlevi: Bu işlev eşikleme görevi görerek 0 ya da 1 değerlerinden birini döndürmektedir.

Sigmoid işlevi: Sigmoid işlevi, $y = 1/1 + e^{-x}$ matematiksel ifadesi ile tanımlanarak [0, 1] aralığında değerler üretmektedir.

Tanh işlevi: Hiperbolik tanjant işlevi, $y = e^{x} - e^{-x} / e^{x} + e^{-x}$ matematiksel ifadesi ile tanımlanarak [-1, 1] aralığında değerler üretmektedir.

Doğrultulmuş doğrusal birim (Rectified Linear Unit ya da kısaca ReLU): Giriş işaretindeki negatif değerleri kırparak çıkışa aktarmaktadır. Bu bağlamda, matematiksel olarak $y = \max(0,\ x)$ fonksiyonu ile ifade edilebilmektedir.

Eksponansiyel doğrusal birim (Exponential Linear Unit ya da kısaca ELU): ReLU'ya benzer şekilde girişteki işaretin pozitif değerlerini doğrudan çıkışa aktarmaktadır. Ancak giriş işaretinin negatif değerlerini $y = \alpha(e^{x} - 1)$ ifadesine göre çıkışa aktarmaktadır.

Swish işlevi: Giriş işareti ve sigmoid işlevinin çarpımı olarak ifade edilmektedir. Swish işlevi matematiksel olarak $y = x/1 + e^{-\beta x}$ ile ifade edilebilmektedir. Bu ifadede $\beta = 1$ olması durumunda takviye öğrenmede yaygın olarak kullanılan sigmoid-ağırlıklı doğrusal birim (Ramachandran ve diğ., 2017) adı verilen aktivasyon işlevi elde edilmektedir. $\beta = 0$ olması durumunda ise giriş işareti doğrusal olarak ölçeklenmektedir (Ramachandran ve diğ., 2017). $\beta \to \infty$ için işlev [0, 1] arasında değerler almaktadır.

Softmax: Softmax işlevi matematiksel olarak $y_j = e^{x_j} \Big/ \sum_{j=1}^{N} e^{x_j}$, $\forall j \in \{1, 2, ..., N\}$ ile ifade edilebilmektedir. Böylelikle, ifade gereği N boyutlu x_j vektöründen [0-1] aralığına normalize edilmiş N boyutlu y_j vektörü elde edilmektedir. Bu işlev, özellikle çıkışın olasılıksal bir formda ifade edilmesinin istenildiği durumlarda kullanılmaktadır. Bu açıdan bakıldığında yaygın olarak sınıflandırma görevlerinde tercih edilmektedir.

Softplus işlevi: Softplus işlevi, ReLU işlevine yumuşak bir yaklaşım sağlamaktadır. Softplus işlevi, matematiksel olarak $y = \log(1 + e^{x})$ ile ifade edilmektedir.

ESA mimarilerinde yaygın olarak kullanılan yukarıda özetlenen aktivasyon işlevleri Şekil 2.12'de aynı eksende karşılaştırmalı olarak gösterilmektedir.

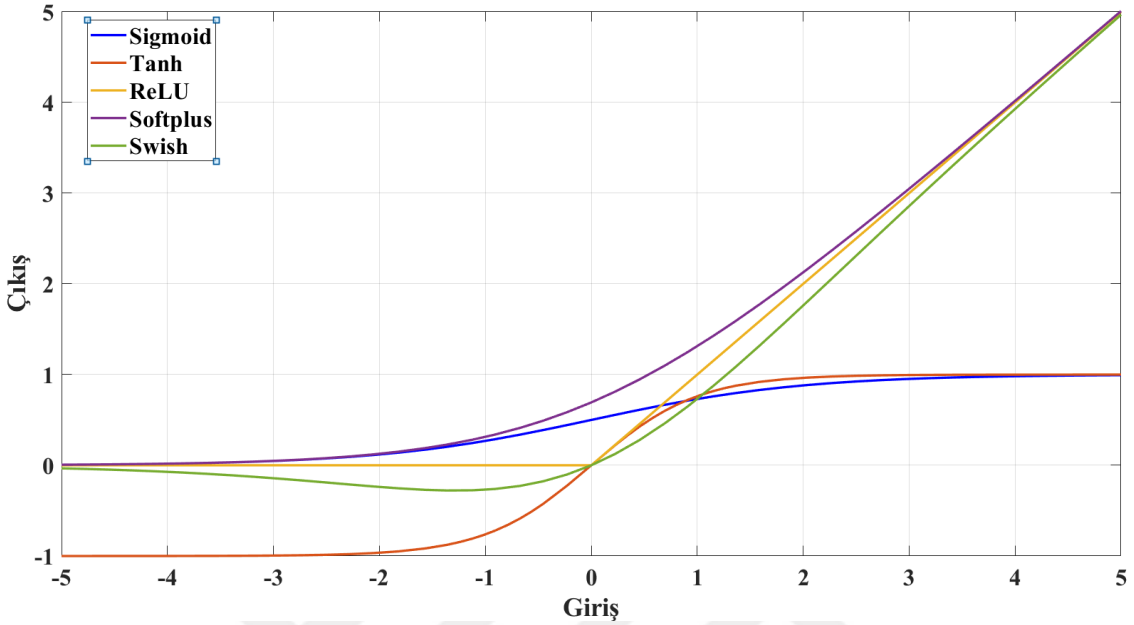

Şekil 2.12. ESA mimarilerinde yaygın olarak kullanılan aktivasyon işlevlerinin karşılaştırılması

Hata Hesaplama İşlevleri

Hata hesaplama işlevleri ESA mimarilerini oluşturan ağırlıkları eniyeleme sürecinin önemli bir adımını oluşturmaktadır. Ağın her bir eğitim döneminde gerçekler ve elde edilen tahminler dikkate alınarak hata işlevleri ile bulunan değerler ağ ağırlıklarının güncellenmesine etki etmektedir. Bu nedenle, yararlanılan hata işlevi ağın eniyilenmesine büyük bir öneme sahiptir. Sınıflandırma, bölütleme ve bağlanım görevleri için yararlanılan hata işlevleri farklılığa sahiptir. Sınıflandırma görevlerinde yaygın olarak kullanılan hata fonksiyonlarından biri,

$$\ell_{entropi} = -\sum_{i} y_i \log \hat{y}_i \tag{2.10}$$

Eşitlik (2.10)'da verilen çarpaz-entropi hatasıdır. Sınıflandırma amacıyla oluşturulan ESA mimarilerinin son katmanında önceki bölümde tanıtılan Softmax aktivasyon işlevinden yararlanılmaktadır. Bu nedenle ağdan elde edilen tahminler ilgili nesnelerin bir sınıfa ait olma olasılığını ifade eden bir vektördür. Böylece, Eşitlik (2.10)'da verilen

y gerçek olasılık dağılımını, $\hat{y}$ ise tahmin edilen olasılık dağımını ifade etmektedir. Çapraz-entropi hata fonksiyonu iki olasılık dağılımı arasındaki farkı ölçmektedir.

Bölütleme bir imgedeki ilgilenilen nesne ya da nesnelerin algılanması amacıyla her bir pikselin bir sınıfa atanması görevi olarak tanımlanabilmektedir. Böylelikle Eşitlik (2.10)'da verilen çapraz-entropi hata işlevi bölütleme görevlerinde yaygın olarak kullanılmaktadır.

Bağlanım görevlerinde ise L_1 (Ortalama-Mutlak-Fark), L_2 (Ortalama-Karesel-Hata) ve Huber hata işlevlerinden yararlanılmaktadır. L_1 hatasının hesaplanmasına ilişkin bağıntılar Eşitlik (2.11)'deki gibi verilebilmektedir.

$$MF(\hat{y}, y) = |\hat{y} - y|, \quad \ell_{L_1} = -\frac{1}{N}\sum_i MF_i \tag{2.11}$$

Eşitlik (2.11)'de verilen MF (Mutlak-Fark) hata vektöründeki $\hat{y}$ ve y sırasıyla, tahmin değerler ile gerçek değerleri temsil etmektedir. Ardından elde edilen MF vektörü tek bir değere indirgenerek L_1 hatası (ℓ_{L_1}) belirlenmektedir. Benzer şekilde, L_2 hatasının hesaplanmasına ilişkin bağıntılar Eşitlik (2.12)'deki gibi verilebilmektedir.

$$KF(\hat{y}, y) = (\hat{y} - y)^2, \quad \ell_{L_2} = -\frac{1}{N}\sum_i KF_i \tag{2.12}$$

Eşitlik (2.12)'de verilen L_2 hatası (ℓ_{L_2}) KF (Karesel-Fark) vektörü üzerinden hesaplanmaktadır. Bağlanım görevlerinde kullanılan bir diğer hata işlevi olan Huber, yukarıda tanımlanan işlevlerden bir miktar farklılığa sahiptir. Huber hata işlevi Eşitlik (2.13)'deki gibi tanımlanmaktadır (Huber, 1964).

$$L_j = \begin{cases} \frac{1}{2}(\hat{y}_j - y_j)^2, & eğer\ |\hat{y}_j - y_j| \le \delta \\ \delta|\hat{y}_j - y_j| - \frac{1}{2}\delta^2, & aksi \end{cases}, \qquad \ell_{huber} = -\frac{1}{N}\sum_j L_j \tag{2.13}$$

Eşitlik (2.13)'deki δ ifadesi hata işlevinin şeklini kontrol etmektedir.

Optimizasyon Algoritmaları

Optimizasyon, her bir iterasyon sonunda hata işlevlerinden elde edilen değerler dikkate alınıp ağdaki öğrenilebilir olan tüm parametrelerin (ağırlıklar) güncellenerek eniyilenmesi süreci olarak tanımlanabilir. Ağırlıkların güncellenmesi ise birinci derece gradyan-temelli optimizasyon algoritmaları ile gerçekleştirilmektedir. Aşağıdaki bölümlerde ağırlık optimizasyonunda yaygın olarak kullanılan algoritmalar özetlenmektedir.

Stokastik En Dik İniş (SGD): Örüntü tanımanın erken evrelerinde, araştırmacılar el-yapımı özellik çıkartma yöntemlerini eğitilebilir olan Çok Katmanlı Algılayıcı (ÇKA) mimariyleriyle değiştirmeyi amaçlamışlardır (Rosenblatt, 1957; Selfridge, 1958). Buna rağmen 1980'lerin ortalarına kadar bu yapıların nasıl eğitilebileceği tam olarak anlaşılamamıştır. Ardından, ÇKA'ların Stokastik En Dik İniş (SGD) algoritması ile eğitilebildiği birbirinden bağımsız araştırmacılar tarafından belirlenmiştir (Werbos, 1974; LeCun, 1985; Rumelhart ve diğ., 1986). SGD, amaç fonksiyonunu eniyilemek için kullanılan iteratif bir optimizasyon algoritmasıdır. Algoritma, gradyanların tüm veri yerine orijinal verinin küçük bir yığını üzerinden kestirilmesi sebebiyle stokastik olarak adlandırılmaktadır. Böylelikle, hesapsal yükü düşürülebilmektedir. SGD algoritması, Geriye Yayılım (BP) algoritması (Goodfellow ve diğ., 2016) ile birlikte ağ ağırlıklarının güncellenmesi amacıyla kullanılmaktadır. SGD algoritmasına göre ağırlıklar her bir iterasyonun ardından Eşitlik (2.14)'den yararlanılarak güncellenmektedir.

$$W_{k+1} = W_k - \eta . \frac{\partial \ell}{\partial W_k} \tag{2.14}$$

Eşitlik (2.14)'de verilen η ifadesi, ağın öğrenme hızını kontrol etmektedir. Eşitlikteki $\partial \ell / \partial W_k$ ifadesi ise BP algoritmasına göre bulunan gradyanları ifade etmektedir. Böylelikle, her bir iterasyonda belirlenen hata işlevine göre bulunan hatalar geriye doğru yayılarak ağdaki tüm ağırlıklar güncellenmektedir. Diğer bir yandan, SGD algoritmasının momentum adı verilen bir yöntem ile uygulandığı farklı bir şekli de bulunmaktadır (Rumelhart ve diğ., 1986). SGDM olarak bilinen bu yönteme göre ağırlıklar Eşitlik (2.15)'te verildiği gibi güncellenmektedir.

$$W_{k+1} = W_k - \eta . \frac{\partial \ell}{\partial W_k} + \alpha . \nabla w, \quad \nabla w = W_{k+1} - W_k \tag{2.15}$$

Eşitlik (2.15)'ten anlaşılaşılabileceği gibi SGDM yönteminde her bir iterasyonda ağırlık güncellemeleri (∇w) de dikkate alınmaktadır. Böylelikle, hata gradyanları ile hatırlanan ağırlık güncellemelerinin doğrusal birleşimi gerçekleştirilecek tüm ağırlık güncellemelerini belirlemektedir. Eşitlikteki α parametresi bozulma (decay) çarpanı olarak bilinmektedir. Bu parametre, ağırlık güncellemelerine mevcut ve önceki gradyanların bağıl katkısını belirlemektedir. SGDM optimizasyon yönteminde tüm iterasyonlar boyunca öğrenme hızı (ya da adım boyu) sabit tutulmaktadır. Bu durum ağın istenilen değerlere yakınsamasını yavaşlatmaktadır. Bu problem, öğrenme hızının bir hiperparametre olarak dikkate alınmadığı Uyarlamalı Moment Kestirimi ve Kök-Ortalama-Kara Yayılımı gibi daha gelişmiş algoritmalar tarafından ele alınabilmektedir.

Kök-Ortalama-Kare Yayılımı (RMSprop): RMSprop (Huang, 2020), derin öğrenmenin öncülerinden Hinton tarafından geliştirilen gradyan temelli bir diğer optimizasyon algoritmasıdır. ESA gibi yapılar açıkça tanımlanamayan karmaşık haritalama fonksiyonlarını öğrenmektedir. Mimari derinliğinin artmasının performansı iyileştirici etkiye sahip olduğu bilinse de bu durum haritalama fonksiyonunun öğrenilmesini güçleştirmektedir. Ağ eğitiminde gradyan değerleri yararlanılan aktivasyon işlevlerine bağlı olarak küçük değerler alabilmektedir. Böyle durumlarda ağ derinliğine bağlı olarak hesaplanan gradyan değerleri ağın ilk katmanlarına doğru eksponansiyel şekilde azalma gösterebilecektir. Sonuç olarak ilk katmanlarda parametre güncellemeleri gerçekleşmeyecektir. Bu durum literatürde *kaybolan gradyanlar* (Informatik ve diğ., 2003) sorunu olarak bilinmektedir. İlgili problemin karşıtı ise *patlayan gradyanlar* olarak adlandırılmaktadır. Bu nedenle belirtilen problemlerin giderilebilmesi için RMSprop yönteminde gradyanlar normalize edilmektedir. Normalizasyon işlemi ise karesel-gradyanların kayan ortalamaları alınarak gerçekleştirilmektedir. Normalizasyon sayesinde adım boyu dengelenebilmektedir. Böylelikle, küçük gradyan genliklikliklerinde adım boyu arttırılabilirken, büyük gradyan genliklerinde ise adım boyu azaltılabilmektedir. RMSprop yöntemine göre ağırlıklar Eşitlik (2.16)'da verildiği gibi güncellenmektedir.

$$W_{k+1} = W_k - \frac{\eta}{\sqrt{E[g^2]}}.g, \quad g = \frac{\partial \ell}{\partial W_k},\ E_{k+1}[g^2] = \beta.E_k[g^2] + (1-\beta)\left(g\right)^2, \tag{2.16}$$

Eşitlik (2.16)'daki $E[g^2]$ karesel-gradyanların hareketli ortalamalarını, β ise hareketli ortalama parametresini ifade etmektedir (Huang, 2020).

Uyarlamalı Moment Kestirimi (Adaptive Moment Estimation: ADAM): Gradyan-temelli yöntemlerden bir diğeri ADAM'dır. ADAM optimizasyon yönteminde ağırlık güncellemesi gradyanların hem kayan ortalamaları hem de ikinci momentleri dikkate alınarak yapılmaktadır (Kingma and Ba 2017). ADAM optimizasyon yöntemine ait bağıntılar Eşitlik (2.17)'de verilmektedir.

$$\begin{aligned} &m_{k+1} = \beta_1.m_k + (1-\beta_1).g_{k+1}, \qquad \upsilon_{k+1} = \beta_2.\upsilon_k + (1-\beta_2).g_{k+1}^2, \\ &\hat{m}_{k+1} = m_{k+1}\big/\left(1-B_1^{k+1}\right), \qquad \hat{\upsilon}_{k+1} = \upsilon_{k+1}\big/\left(1-B_2^{k+1}\right), \\ &W_{k+1} = W_k - \frac{\alpha}{\sqrt{\hat{\upsilon}_n + \varepsilon}}.\hat{m}_n \end{aligned} \tag{2.17}$$

Eşitlik (2.17)'de $\hat{m}$, birinci momentin (yani m) yansız kestirimini; benzer şekilde $\hat{\upsilon}$, ikinci momentin (yani υ) yansız kestirimini ifade etmektedir. Eşitlikteki karesel gradyan ise gradyanın bileşen-temelli çarpımını (yani $g^2 = g \odot g$) ifade etmektedir. ε, sıfıra bölümden kaçınmak için eklenen çok küçük bir sabiti; α, öğrenme hızını; β_1 ve β_2 ise sırasıyla gradyanlara ait birinci ve ikinci moment parametrelerini (ya da unutma çarpanları) ifade etmektedir.

Eşitlik (2.17)'den anlaşılacağı gibi ikinci moment ile normalize edilen birinci moment ($\hat{m}_n\big/\sqrt{\hat{\upsilon}_n + \varepsilon}$) gerçekleştirilecek ağırlık güncellemelerinin yönünü belirlemektedir. ADAM, gradyan-temelli yöntemler içerisinde en hızlı yakınsama sağlayanı algoritmadır.

ESA'nın Eğitimi

ESA, giriş verisinin ağa beslenmesi ile ağ çıkışından verinin elde edilmesi (ileri yayılım), mevcut ağ hatasının hata işlevleri kullanılarak hesaplanması ve hataların geri doğru yayılarak indirgenmesi (geri yayılım) olmak üzere üç aşamada eğitilmektedir. İleri yayılım algoritmasında her bir katmandaki ağırlık matrisi ve ilgili katman girişindeki

vektör çarpımı aktivasyon işlevinin girdileri olmaktadır. Aktivasyon işlevinden elde edilen çıkış değerleri ise bir sonraki katmana giriş olacak şekilde algoritma devam ettirilerek ağ çıkışındaki değerler belirlenmektedir. Bu süreç matematiksel olarak Eşitlik (2.18)'deki gibi ifade edilebilmektedir.

$$\hat{y}(x) = F^{L}(W^{L}.F^{L-1}(.....F^{1}(W^{1}.x))) \tag{2.18}$$

Ardından hata işlevlerinden yararlanılarak Eşitlik (2.19)'da ifade edildiği ağ hatası belirlenmektedir.

$$\ell(y(x),\ \hat{y}(x)) = \ell(y(x),\ F^{L}(W^{L}.F^{L-1}(.....F^{1}(W^{1}.x)))) \tag{2.19}$$

Son olarak geriye yayılım algoritmasından yararlanılarak gradyan hesaplamaları gerçekleştirilip her bir katmandaki ağırlık matrisleri güncellenmektedir. Herhangi bir k katmanındaki ağırlıkların gradyanı Eşitlik (2.20)'de verildiği gibi hesaplanmaktadır.

$$\frac{\partial \ell}{\partial W^{k}} = \delta^{k}.(y^{k-1})^{T},\ \ \delta^{k} = (F^{k})^{'} \circ (W^{k+1})^{T}.\delta^{k+1} \tag{2.20}$$

Eşitlik (2.20)'deki δ^{k} terimi k katmanındaki düğüm sayısı uzunluğunda bir vektör olup katmandaki her bir düğümün sorumlu olduğu hataları içermektedir. Hata terimi δ^{k}, Eşitlik (2.20)'de verildiği gibi ağ çıkışından girişine doğru giderek özyinelemeli olarak hesaplanabilmektedir.

ESA'larda Aşırı Uydurmadan Kaçınma Yöntemleri

Yitim Katmanı

ESA mimarilerinde ağ derinliğinin arttırılması eğitilebilir parametre sayısının artması ve dolayısıyla karmaşıklığın da artmasına neden olmaktadır. Bu durum ise aşırı uydurma riski doğurmaktadır. (Srivastava ve diğ., 2014)'da tanıtılan yitim katmanı her bir eğitim döneminde (epoch) hesaplama birimlerinin belirli bir olasılıkla ağ yapısında bulunmasını sağlamaktadır. Böylelikle, düğüme bağlı bağlantılardan veri aktarımı gerçekleşmemektedir. Bunun bir sonucu olarak her bir eğitim döneminde eğitilebilir parametre sayısı azaltılarak ağ eğitimi hızlandırılabilmektedir. Test aşamasında ise

mimari tüm düğüm ve bağlantıları ile birlikte kullanılmaktadır. Yitim katmanının sağladığı avantajlar aşağıdaki gibi özetlenebilmektedir:

- Her bir eğitim epoch değerinde belirli bir olasılıkla bazı düğümlerin ve dolayısıyla bağlantılarının yitirilmesi her bir epoch değerinde farklı bir model ile eğitim yapılmasına olanak tanımaktadır.

- Yitim katmanları ağı daha gürbüz öznitelikleri öğrenmeye zorlamaktadır. Böylelikle model genelleme yeteneği de iyileştirilebilmektedir.

Düzenlileştirme

ESA'larda aşırı uydurma riskini azaltabilen diğer bir yaklaşım ise düzenlileştirmedir. L_1 ve L_2 normları bu amaçla yaygın olarak kullanılmaktadır (Hastie, Tibshirani, and Friedman 2009). Düzenlileştirme, hata işlevine bir düzenlileştirme terimi λ'nın eklenmesi ile gerçekleştirilmektedir. λ parametresi, ağ eğitimi öncesinde ayarlanan hiperparametrelerden biridir ve daha iyi sonuçların elde edilebilmesi için optimize edilmesi gerekmektedir. Eşitlik (2.21)'de verilen $\|.\|_1$ ve $\|.\|_2$ ifadeleri, sırasıyla L_1 ve L_2 normlarını belirtmektedir.

$$\ell_{yeni} = \ell + \lambda.\|w\|_1, \quad \ell_{yeni} = \ell + \lambda.\|w\|_2 \tag{2.21}$$

Düzenlileştirme ağırlık matrislerindeki değerleri küçültme etkisine sahiptir. Böylelikle tüm model daha kompakt (sıkı) hale getirilerek kompleksite düşürülebilmektedir. L_1 normu için değerler kesin olarak sıfırlanabildiğinden daha iyi bir sıkılaştırma elde etmek mümkündür. L_2 normu için ağırlıklar sıfıra yaklaştırılabildiğinden bu norm bazen ağırlık çürütme (Weight decay) olarak da adlandırılabilmektedir.

Veri Çoğaltma

Veri çoğaltma, orijinal veriyi kullanarak ağ eğitimi için sentetik veri üretme olarak tanımlanabilmektedir. Sentetik verinin üretilmesi için iki farklı yaklaşım izlenebilmektedir. Birinci yaklaşım *Çekişmeli Üretken Ağ* (GAN) (Radford ve diğ., 2016) olarak bilinen bir ağ yapısının kullanılmasıdır. GAN, girişindeki veri ile benzer

karakteristiğe sahip bir sentetik veri üreten derin öğrenme modelidir. GAN ağları, üreteç ve ayırtaç adı verilen ve birbirine paralel olarak eğitilen iki alt ağdan oluşmaktadır. Üreteç ağı, girişine gelen gürültüden eğitim verisi ile aynı karakteristiğe sahip görüntüler elde etmekten sorumluyken, ayırtaç ağı gerçek ve üretilen görüntüleri ayırt etmekten sorumludur. Böylece, ayırtaç ağının görevi üreteç ağının gerçek ve sahte görüntüler arasındaki ayrımı yapmasını zorlaştıracak veriler üretmek olduğundan, üreteç ağının eniyilenmesi ayırtaç ağı tarafından yapılan hataların artması anlamına gelmektedir. Bu durumda ayırtaç ağı da üreteç ağı tarafından aldatılamayacak şekilde eniyilenmektedir. Bu yaklaşım, üreteç ağının temsil gücü yüksek öznitelikleri öğrenmesini sağlamaktadır.

Diğer yaklaşım daha az karmaşıklığı olan geometrik dönüşümlerden (Wolberg, 1992) yararlanılarak orijinal verinin sentetik formlarının üretilmesidir. Veri çoğaltma işlemi eğitim öncesinde ya da ağın eğitildiği her bir epoch değerinde yapılabilmektedir.

Erken Sonlandırma

Aşırı uydurmadan kaçınmak için diğer bir yöntem ise Şekil 2.6'da açıklandığı gibi optimum noktada ağ eğitiminin sonlandırılmasıdır. Bu amaçla, eğitim verisinin bir bölümü ağın geçerlenmesi amacıyla ayrılarak aşırı uydurma kontrol edilebilmektedir.

Görselleştirme

Karmaşık haritalama fonksiyonlarını öğrenen ESA'ların ilgili problem hakkında ne öğrendikleri belirsizdir. Buna rağmen ağ tarafından yapılan tahminler üzerinde öğrenilen hangi özniteliklerin etkili olduğu çeşitli teknikler yoluyla görselleştirilebilmektedir. Örtme (occlusion) duyarlılığı (Zeiler ve Fergus, 2014), LIME (Ribeiro ve diğ., 2016) ve Grad-CAM (Selvaraju ve diğ., 2017) bu amaçla kullanılabilen tekniklerdir. Birçok çalışmada yaygın olarak kullanılan bir teknik olması ve tez çalışması kapsamında geliştirilen ağ tahminlerinin açıklanmasında yararlanılması sebebiyle bu bölümde Grad-CAM tekniğinin işleyişi açıklanmaktadır.

Gradyan Ağırlıklı Sınıf Aktivasyonlarının Haritalanması (Grad-CAM): Eğitilen derin ağlar tarafından döndürülen tahminler üzerinde işlenen görüntünün hangi bölümlerinin etkili olduğunu açıklamak amacıyla yaygın olarak yararlanılan bir görselleştirme tekniğidir. Bu teknikte, kısmi türevlenebilir bir çıkış işlevinin gradyanları dikkate alınarak

derin ağın tahminleri üzerinde her bir nöronun önem seviyesi belirlenmektedir. Tahminler üzerinde hangi özniteliklerin etkili olduğunu belirleyebilmek için genellikle son evrişimsel katman aktivasyonları dikkate alınmaktadır. A_{ij}^{d}, son evrişimsel katman çıkışındaki $d.$ aktivasyon haritasını, $\hat{y}_s$ herhangi bir s sınıfının olabilirlik skorunu ve N aktivasyon haritasındaki toplam piksel sayısını ifade etsin. Buna göre her bir nöronun s sınıfı için sahip olduğu önem ağırlığı (ϕ_d^s) Eşitlik (2.22)'deki gibi belirlenebilmektedir.

$$\phi_d^s = \frac{1}{N} \sum_i \sum_j \frac{\partial \hat{y}_s}{\partial A_{ij}^d} \tag{2.22}$$

Ardından, aktivasyon haritalarının ağırlıklı toplamları alınarak Grad-CAM imgesi Eşitlik (2.23)'deki gibi elde edilebilmektedir.

$$G_{ij} = \max\left(0,\ \sum_d \phi_d^s A^d\right) \tag{2.23}$$

Eşitlik (2.23)'ten görüldüğü gibi, Grad-CAM imgesi G_{ij} elde edilirken ilgili sınıfa yalnızca pozitif katkıda bulunan öznitelikler dikkate alınmaktadır.

Grad-CAM imgeleri, ağ tahminlerini açıklamak adına sıklıkla sınıflandırma görevlerinde kullanılsa da bağlanım görevlerine de uyarlanabilmesi mümkündür.

2.2. Tartışma

Hassas tıp, hastalıkların tedavi edilmesinde ve önlenmesinde bireysel farklılıkların dikkate alınması ve farklı kaynaklardan elde edilen bilgilerin tümleştirilmesini gerektirmektedir (Council ve diğ., 2011). Sayısal görüntü analizi süreci ile çeşitli kanser türleri ve hastalıklar hakkında farklı radyolojik görüntüleme modalitelerinden elde edilen radyomikler hassas tıbbın ilerlemesinde ve hastalık biyolojisinin kavranmasında büyük bir öneme sahiptir. Günümüzde sürekli olarak artan tıbbi veri miktarına paralel olarak ve geliştirilen daha iyi makine öğrenmesi algoritmaları sayesinde hastalıkların daha iyi kavranmasını sağlayacak radyolojik biyobelirteçlerin elde edilmesi mümkün olmaktadır. Dahası, altta yatan hastalığı etkili bir şekilde tanımlayabilen radyomikler ile eğitilen modeller sayesinde sağlık problemlerine invasif olmayan çözümler sağlanabilmektedir.

Bu bağlamda, tez çalışmasının bu bölümünde sunulan modüler OT sistemlerinin öznitelik çıkartma (ya da el yapımı öznitelik çıkartma) adımında eldeki görevin performansını en büyükleyecek en uygun (optimal) öznitelik kümesinin bulunması görevin en kritik adımı olmaktadır. Modüler olarak tasarlanan sistemler ile karşılaşılabilen önemli zorluklardan biri görev ile ilişkili en uygun öznitelik kümesinin bulunamamasının genel performansa bir üst sınır koymasıdır. Bununla birlikte görüntü tanıma alanında el yapımı öznitelikler kullanılarak giriş görüntüsündeki değişimleri (rotasyon, ölçekleme, öteleme, zıtlık vs.) ele alabilecek bir haritalama fonksiyonunun öğrenilmesi oldukça zordur. Bu durum seçicilik-değişmezlik ikilemi (LeCun ve diğ., 2015) olarak da bilinmektedir. Her ne kadar kernel (çekirdek) yöntemlerinden yararlanılarak elde edilen doğrusal olmayan öznitelikler kullanılarak eğitilen modeller ile giriş görüntüsündeki değişimler görece üstesinden gelinebilse dahi (Schölkopf ve Smola, 2002), Gauss gibi çekirdeklerden elde edilen öznitelikler ile eğitilen modellerin genelleme yeteneği düşük olabilmektedir (Bengio ve diğ., 2006).

Klasik yöntemlerin aksine derin öğrenme temelli yöntemler (tümleşik OT sistemleri) her biri girişindeki bilgiyi farklı bir soyutlama seviyesinde ele almaktan sorumlu olan ve giriş-çıkış arasındaki doğrusal olmayan ilişkinin öğrenildiği birbiri ardına gelen katmanlar dizisinden oluşmaktadır (LeCun ve diğ., 2015). Her bir katman girişine gelen temsilleri (representation) ağın seçicilik ve değişmezliğini arttırmak için dönüştürmektedir (LeCun ve diğ., 2015). Sonuç olarak katman sayısının artması sınıflar arası anlık detayları ayırt etmeyi kolaylaştıracak karmaşık bir haritalama fonksiyonun öğrenilmesini sağlayarak modüler sistemlerin üzerinde bir performansın elde edilmesine olanak tanımaktadır. Buna rağmen derin öğrenme temelli yöntemler ile istenilen performansın elde edilebilmesi girişteki bilgiyi uygun şekilde kodlayacak ağ yapılarının geliştirilmesine, eğitim verisi miktarına ve ön ayarlara bağlıdır.

Tez çalışmasının sonraki bölümlerde beyin tümörleri ve COVID-19 hastalığının tıbbi görüntülerden tespiti amacıyla çalışma kapsamında geliştirilen derin öğrenme temelli OT sistemleri tanıtılmaktadır.

3. BEYİN MR GÖRÜNTÜLERİNDEN ÖZNİTELİK ÇIKARTMA VE TÜMÖR SINIFLANDIRMA

Beyin tümörü, beyindeki kanserli dokular tarafından veya metastaz ile üretilen anormal hücreler topluluğu olarak adlandırılmaktadır. Hastaların yaşam kalitesini düşürmekte ve günlük aktivitelerini önemli ölçüde sınırlamaktadır. Dünya genelinde artan ölümlerin başlıca sebeplerinden biridir. (Iqbal ve diğ., 2018)'deki çalışma, beyin tümörü kaynaklı ölüm oranlarının son 30 yılda üç katına çıktığını bildirmektedir. Beyin tümörleri iyi huylu ve kötü huylu (kanserli) olmak üzere iki ana kategoriye ayrılmaktadır.

Beyin tümörlerinin derecelendirilmesinde Dünya Sağlık Örgütü (DSÖ) tarafından önerilen sınıflandırma yöntemi standart olarak kabul edilmektedir. DSÖ, beyin tümörlerini dört sınıfa ayırmaktadır. Evre-1 ve Evre-2 iyi huylu tümör sınıfları olarak kabul edilirken, Evre-3 ve Evre-4 kötü huylu tümör sınıfları olarak kabul edilmektedir. Buna göre tümör derecesinin artması tümörün daha kötü huylu olduğunu göstermektedir (Iqbal ve diğ., 2018).

Farklı tümör türlerinin tedavisi de farklıdır. Cerrahi, kemoterapi, radyoterapi, steroid tedavisi ve diğer tedaviler ana tedavi yöntemleridir (Schroeder ve diğ., 2012). Herhangi bir tedaviye başlamadan önce, tümörlerin mevcut durumunun anlaşılabilmesi için beyin tümörünün yeri ve büyüme hızı gibi faktörlerin bilinmesi bir gerekliliktir. Uzmanlar bu bilgiyi elde edebilmek için cerrahi ve görüntüleme tekniklerinden yararlanmaktadır. Ancak risk ve maliyet göz önünde bulundurulduğunda hastalığın ön tanı, tedavi ve tedavi sonrası koşullarının belirlenmesinde görüntüleme teknikleri tercih edilmektedir (Bauer ve diğ., 2013). Literatürdeki birçok araştırmada beyin tümörlerininin tespit edilebilmesi için PET, BT ve MR gibi çeşitli görüntüleme teknikleri kullanılmıştır. Beyin tümörü tespitinde MR görüntüleme, yüksek doku karşıtlığı vererek tespiti kolaylaştırması ve sıfır iyonize radyasyon gibi hasta dostu bir özelliğe sahip olması sebebiyle yaygın olarak kullanılan bir görüntüleme tekniği olmuştur. Bununla birlikte, uzmanlar tarafından MR görüntüleme dilimlerinin analiz edilmesi ve anlaşılması çok fazla deneyim gerektirerek süreci zaman alıcı ve hataya açık bir hale getirdiğinden, beyin tümörü tespitinde doktorlara yardımcı olmak için otomatik sistemler geliştirmek gereklilik haline gelmiştir. Bu amaca yönelik olarak geliştirilen OT sistemleri tipik olarak ön işleme, bölütleme

öznitelik çıkartma, öznitelik seçme ve sınıflandırma aşamalarından (Iqbal ve diğ., 2018; Sachdeva ve diğ., 2013; Kharat ve diğ., 2012; Sridhar ve Krishna, 2013) oluşmaktadır.

Tümör türünü tanımlama ve sınıflandırma görevi, en zorlu görevlerden biri olarak kabul edilmektedir. Beyin tümörü ve tümörü çevreleyen bölgenin özellikleri, görüntüleme yönteminin özellikleri gibi çeşitli durumlar, görüntülerden çıkartılacak radyomikleri etkilemektedir. Düşük karşıtlık, bilinmeyen gürültü, tümörün bilinmeyen şekli ve boyutu ile hastadan hastaya değişen tümör özellikleri, sınıflandırma problemini zorlaştıran diğer faktörlerdir. Örneğin, gliom tür tümör dokusunun tek bir bölgesi, heterojen alt bölgelerle hem yüksek dereceli hem de düşük dereceli olarak sınıflandırılabilen dokular içerebilmektedir (Chung ve diğ., 2015). Beyin tümörü özellikleri, izo-yoğunluk, hipo-yoğunluk, hiper yoğunluk, tümör heterojenliği ve homojenlik koşullarını ifade etmektedir (Sachdeva ve diğ., 2013). İzo-yoğunluk, farklı tümör dokularının benzer görünüme sahip olduğu bir durumdur. Hipo-yoğunluk, görüntünün gerçek tümör dokularından daha koyu olduğu bir durumdur. Hiper-yoğunluk, tümör dokularının olması gerekenden daha parlak olduğu bir durumdur. Tüm bu belirtilenler, öznitelik çıkarma aşamasını tümör sınıflandırma görevinin zorlu bir aşaması haline getirmektedir.

Tümör sınıflandırma görevi temel olarak iki kategoriye ayrılmaktadır. İlk kategori, görüntünün kanserli doku içerip içermediğine göre normal veya anormal (ikili sınıflandırma) olarak sınıflandırılmasıyla ilgilenmektedir. (Iqbal ve diğ., 2018)'de ikili sınıflandırma problemi için elde edilen sınıflandırma sonuçlarının tatmin edici olduğu ve farklı tür tümörler arasındaki ayrımın yapılmasının (çok sınıflı sınıflandırma) bir gereksinim haline geldiği belirtilmektedir. Beyin tümörü türlerini belirlemek için yapılan çalışmalar şu şekilde üç kategoriye ayrılabilir:

1- Tümör bölgelerinden çıkartılan el yapımı özniteliklerin klasik bir sınıflandırıcı veya sınıflandırıcı topluluğu oluşturmak için kullanıldığı çalışmalar.

2- Hem öznitelik çıkarmanın hem de sınıflandırmanın tek bir ağ tarafından yapıldığı derin öğrenmeye dayalı çalışmalar.

3- Eğitimli bir evrişimsel sinir ağından çıkartılan derin özniteliklerin klasik bir sınıflandırıcının eğitiminde kullanıldığı çalışmalar.

Birinci kategorideki çalışmalar arasında (El Abbadi ve Kadhim, 2017)'de GLC (Haralick ve diğ., Dinstein 1973) ve GLRL (Galloway, 1975) matrislerinden 18 öznitelik çıkartılmış ve ilişkisiz öznitelikler elenmiştir. Daha sonra, sınıflandırıcı olarak bir PNN modeli kullanılmıştır. Birçok çalışmada birinci dereceden istatistiksel özellikler (Selvaraj ve diğ., 2007), DWT (John, 2012) ve Gabor filtreleri (Jiang ve diğ., 2013) yaygın olarak kullanılmaktadır. (M. R. Ismael ve Abdel-Qader, 2018)'de, 2D Gabor filtreleme ve 2D DWT tekniklerinin birleşiminden yararlanılmıştır. Yazarlar, (Cheng, 2017)'de verilen *Brain Tumor* veri kümesi üzerinde çalışmışlardır. Bu çalışmada dalgacık, Gabor ve kaynaşık öznitelik setleri elde edilmiş ve her bir öznitelik seti NN modeli ile test edilmiştir. Çalışmada birleştirilmiş öznitelik seti kullanıldığında, %91.9 doğruluk elde edilmiştir. (Cheng et al. 2015)'deki çalışmada, DVM modeli, (Cheng, 2017)'deki *Brain tumor* veri kümesinden elde edilen yoğunluk histogramı, GLC matris elemanları ve BoW (Bag of Words) öznitelik kümeleri ile eğitilmiştir. Yazarlar, tümör bölgesi büyütme ve tümör bölgesi bölümlemenin, el yapımı özniteliklerde sınıflandırma performansını iyileştirdiğini göstermişlerdir. (El-Dahshan ve diğ., 2010)'da, beyin tümör dokusunun tespiti için hibrit bir sistem önerilmiştir. Bu amaçla toplam 70 MR görüntüsü (anormal = 60, normal = 10) kullanılmıştır. Öznitelikler DWT ile çıkartılmış ve daha sonra önemli öznitelikler PCA (Jolliffe, 2002) kullanılarak tutulmuştur. NN ve k-NN (k-En Yakın Komşular) sınıflandırma modelleri seçilen öznitelikler ile ayrı olarak eğitilmektedir. Bu çalışmada NN ve k-NN modellerinden elde edilen doğruluklar sırasıyla %97 ve %98'dir. Tüm bu çalışmalarda çıkarılacak öznitelik türlerinin önceden bilinmesi ihtiyacı genelleme kapasitesini azaltan önemli bir eksikliktir. Bununla birlikte, ESA'lar geniş bir öğrenme kapasitesine sahiptir ve herhangi bir ön bilgi gerektirmeden giriş görüntüsünün doğasını öğrenebilmektedir.

İkinci kategoriye bakıldığında (Cheng, 2017)'deki beyin tümörü veri setini kullanarak beyin tümörü sınıflandırması için (P. Afshar ve diğ., 2018)'de bir Kapsül ağı (CapsNet) mimarisi sunulmuştur. Yazarlar, tüm beyin görüntüsünü besleme ve ağa yalnızca tümör bölgesini besleme durumlarını test etmişlerdir. Bu çalışmada sadece tümör bölgesinin beslenmesiyle elde edilen doğruluk %86.56 iken tüm beyin görüntüsünün beslenmesiyle elde edilen doğruluk %78'dir. Yazarlar (P.Afshar ve diğ., 2019)'deki çalışmalarında tümör kaba sınırlarını CapsNet mimarilerine dâhil ederek aynı veri kümesi üzerinde doğruluk skorlarını %90.89'a kadar arttırmışlardır. (Swati ve diğ., 2019)'te, önceden

eğitilmiş VGG-19 (Simonyan ve Zisserman, 2015) ağı beyin tümörü tespiti için kullanılmaktadır. Doğruluğun %94.82 olarak bildirildiği bu çalışmada, transfer öğrenmeye dayalı bir ince ayar stratejisi önerilmiştir. (Sajjad ve diğ., 2019)'te çok dereceli bir beyin tümörü sınıflandırma sistemi önerilmiştir. Bu çalışmada kapsamlı veri çoğaltma tekniği kullanılmıştır. Çalışmada VGG-19 ağı ince ayarlı yapılmıştır. Beyin tümörü veri seti (Cheng, 2017) üzerindeki duyarlılık, özgüllük ve doğruluk değerleri sırasıyla %88.41, %96.12 ve %94.58'dir. (Abiwinanda ve diğ., 2019)'de, beyin tümörü veri setinde (Cheng, 2017) üzerinde elde edilen doğruluğun %84.19 olarak bildirildiği bir ESA kullanılmıştır. (Sultan ve diğ., 2019)'te, 16 katmanlı ESA mimarisi kullanılarak %96.13 doğruluk elde edilmiştir. (Ghassemi ve diğ., 2020)'de, Çekişmeli Üretken Ağ (GAN) kullanan derin öğrenmeye dayalı bir beyin tümörü sınıflandırma yöntemi önerilmiştir. Bu çalışmada elde edilen doğruluk %95.60'dır.

Üçüncü kategoriye bakıldığında, (Xu ve diğ., 2015)'deki çalışmada MICCAI 2014 müsabakası için bir sınıflandırma ve bölütleme yöntemi önerilmiştir. Bu çalışmada yazarlar derin özniteliklerin ikinci tam bağlı katmandan çıkarıldığı AlexNet'e (Krizhevsky ve diğ., 2012) benzer bir ESA mimarisi kullanmışlardır. Çalışmada ağın tam bağlı katmanından 4096 boyutlu öznitelik vektörleri elde edilmiştir. Ardından çıkartılan öznitelikler GBM (Glioblastoma Multiforme) ve Düşük Evreli Glioma (DEG) arasındaki farkın derecesine göre seçildiği bir öznitelik seçme sürecinden geçirilmektedir. En büyük farklılıklara sahip ilk 100 öznitelik, nihai derin öznitelikler olarak seçilerek doğrusal DVM modeli eğitilmiştir. Çalışmada ulaşılan sınıflandırma doğruluğu %97.5'tir. (Pashaei ve diğ., 2018)'de yazarlar, (Cheng, 2017)'teki *Brain Tumor* veri kümesini kullanarak beyin tümörlerini menenjiyom, gliom ve hipofiz tümörü olmak üzere sınıflandırmak için iki farklı yaklaşım geliştirmişlerdir. Bu amaçla bir ESA eğitilerek öğrenilen derin öznitelikler ağdan çıkarılmıştır. Çıkarılan öznitelikler, KELM (Kernel Extreme Learning Machines) modeline girdi olarak kullanılmıştır. Bu yaklaşım KE-CNN olarak adlandırılmış ve çalışmada %93.68 doğruluğa ulaşılmıştır. (Deepak ve Ameer, 2019)'de GoogLeNet, beyin tümörü sınıflandırma problemi için ince ayarlı yapılarak öğrenilen öznitelikler çıkartılmıştır. Öznitelik seçme ile belirlenen öznitelik kümesi kullanılarak DVM ve k-NN modelleri eğitilmiştir. Çalışmada ulaşılan en yüksek doğruluk oranı %97.1'dir. (Sethy ve Behera, 2021)'de Kaggle deposundan toplanan 253 MR görüntüsü kullanılarak VGG-16 ağının farklı katmanlarından çıkartılan derin öznitelikler

birleştirilmiştir. Ardından, birleştirilen derin öznitelik kümeleri kullanılarak eğitilen DVM modeli ile %97.9'luk bir doğruluk oranına ulaşılmıştır.

Tablo 3.1'de beyin tümörlerinin sınıflandırılmasına ilişkin olarak geliştirilen yukarıda her bir kategoride özetlenen çalışmalar verilmektedir.

Tablo 3.1. Beyin tümörü sınıflandırma için geliştirilen literatürdeki çalışmaların özeti

	Çalışma	Yöntem	Veri kümesi	Başarım (%)
Kategori-1	(El Abbadi ve Kadhim, 2017)	GLCM & GLRM öznitelikleri + PNN	Hibrit	98,0
	(Selvaraj ve diğ., 2007)	GLCM öznitelikleri + DVM	Bilinmeyen	98,9
	(John, 2012)	DWT öznitelikleri + PNN	Nimhans (URL-4, 2022)	≈100
	(M. R. Ismael ve Abdel-Qader, 2018)	DWT & Gabor öznitelikleri + BPNN	Brain tumor	91,9
	(Cheng ve diğ., 2015)	BoW öznitelikleri + DVM	Brain tumor	91,2
	(El-Dahshan ve diğ., 2010)	DWT öznitelikleri + PCA + kNN	Harvard (URL-5, 2022)	98,0
Kategori-2	(P. Afshar ve diğ., 2019)	Özel kapsül ağı (CapsNet)	Brain tumor	90,8
	(Swati ve diğ., 2019)	İnce ayarlı VGG-19	Brain tumor	94,8
	(Sajjad ve diğ., 2019)	İnce ayarlı VGG-19	Brain tumor	94,5
	(Abiwinanda ve diğ., 2019)	Özel ESA	Brain tumor	84,2
	(Sultan ve diğ., 2019)	16-katmanlı özel ESA	Brain tumor	96,1
	(Ghassemi ve diğ., 2020)	DCGAN	Brain tumor	95,6
Kategori-3	(Xu ve diğ., 2015)	AlexNet öznitelikleri + DVM	TCGA (URL-6, 2022)	97,5
	(Sethy ve Behera, 2021)	VGG-16 öznitelikleri + DVM	Kaggle	97,9
	(Pashaei ve diğ., 2018)	KE-CNN: Özel ESA öznitelikleri+KELM	Brain tumor	93,6
	(Deepak ve Ameer, 2019)	GoogLeNet öznitelikleri + DVM	Brain tumor	97,1

Yukarıda özetlenen birçok çalışmada gliom, menenjiyom ve hipofiz tümörlerini ayırt etmek için MR görüntüsünün tamamını kullanan yöntemler önerilmiştir. Gliomlar, beyin tümörlerinin ana türüdür ve beynin glial hücrelerinden kaynaklanmaktadır (Cha, 2006). Gliom, düşük ve yüksek evreli gliomları içeren genel bir terimdir. DSÖ sınıflandırmasına göre, gliomlar saldırganlıklarına göre dört evreye ayrılmaktadırlar (Kleihues, ve diğ., 1993; Louis ve diğ., 2007). Evre arttıkça tümör daha saldırgan ve daha kötü huylu hale gelmektedir. Evre-1'deki tümörler normal doku görünümüne sahipken, Evre-2'deki tümörler görünümde bazı anormalliklere sahiptir. Ancak, iyi huylu olarak kabul

edilmektedirler. Evre-3 ve Evre-4 tümörler bazı belirgin anormalliklere sahiptir ve kötü huylu olarak kabul edilmektedirler. Evre-2 ve Evre-3 tümörler aynı zamanda düşük evreli gliomlar (DEG'ler: oligodendrogliomalar, astrositomlar ve oligoastrositomlar) olarak sınıflandırılmaktadırlar. Evre-4 ise yüksek dereceli gliomlar (YEG'ler: glioblastoma multiforme) olarak sınıflandırılmaktadır. YEG'lere kıyasla DEG'ler daha az saldırgan tümörlerdir. Bununla birlikte, DEG'ler zamanla YEG'lere ilerleyebilmektedir (Macdonald ve diğ.,1990; Van den Bent ve diğ., 2013). Ek olarak, bazı DEG'ler tedaviye duyarlıdır ve sağkalımları 1 ila 15 yıl arasında değişebilmektedir (Macdonald de diğ.,1990; van den Bent ve diğ., 2013). Mevcut durumda tedavi seçenekleri gözlem, cerrahi, ışın tedavisi ve kemoterapidir. Tümörlerin histolojik derecelendirilmesi tanı için çok önemli olmasına rağmen, genomik biyo-belirteçlerin eksikliği, en uygun tedavi seçeneklerinin belirlenmesini etkileyebilmektedir (Kleihues ve diğ., 1993). Buna göre, tedavi planlamasını iyileştirmek için DEG'lerin moleküler biyo-belirteç testlerinin elde edilmesi gerekmektedir. Bazı çalışmalar, DEG'lerde 1p/19q kromozom kollarının silinmesinin kemoterapi ve radyoterapiye verilebilecek pozitif tümör yanıtının öngörülmesinde güçlü bir moleküler biyo-belirteç olduğunu ortaya koymaktadır (Fellah ve diğ., 2013; Iwadate ve diğ., 2016). Bu biyo-belirtecin daha uzun sağkalım ile ilişkili olduğu da ortaya çıkartılmıştır. Bu nedenle, DEG için etkili bir tedavi planlamasının yapılabilmesinde 1p/19q biyobelirtecinin eş-silinme durumunun tıbbi görüntülerden tahmin edilmesi büyük bir öneme sahiptir. Bu amaçla yapılan (Akkus ve diğ., 2017; Decuyper ve diğ., 2020; Ge ve diğ., 2018; Voort ve diğ., 2019)'deki ilk çalışmalar, DEG'lerin 1p/19q durumunun medikal görüntülerden tahmin edilebileceğini ortaya koymaktadır.

Gliomların yanı sıra menenjiyomlar, yetişkinlerde en sık görülen beyin tümörleridir. Bu tür tümörler beynin ve omuriliğin meningeal kapaklarından kaynaklanmaktadır. Çoğu menenjiyom tür tümörün, genellikle belirti göstermeden yıllar içinde oldukça yavaş bir gelişmeye sahip olduğu belirtilmektedir. Koku kaybı, hafıza kaybı, çift görme veya bulanık görme gibi görme değişiklikleri menenjiyomların belirtilerinden bazılarıdır.

Diğer bir yandan hipofiz tümörleri, hipofiz bezinde gelişen anormal hücre kitleleridir. Hipofiz tümörlerinin çoğu iyi huyludur. Buna rağmen, hipofiz tümörleri bazen vücudun önemli işlevlerini düzenleyen çok fazla hormona neden olabilirken, bazen de hipofiz

bezinin daha düşük hormonlar üretmesine neden olabilmektedir. Baş ağrısı ve görme kaybı, hipofiz tümörlerinin bilinen belirtilerinden bazılarıdır.

Anlaşılacağı üzere farklı tür beyin tümörleri farklı karakteristiğe sahip olup tedavi yöntemleri farklıdır. Bununla birlikte nadir de olsa bazı çalışmalarda (Iyer ve diğ., 2009; E.-J. Lee ve diğ., 2002; Z. Zhang ve diğ., 2018) gliom ve menenjiyom tür tümörlerin aynı anda aynı hastada görülebildiği örnek durumlar bulunmaktadır. (Tunthanathip ve diğ., 2018)'de bir DEG sınıfı tümörü olan diffuz astrositom ile menenjiyom tür tümörün aynı hastada bulunduğu belirtilmektedir. Etkili tedavi planlamasının yapılabilmesi için beyin tümör türünün doğru bir şekilde tespit edilebilmesinde duyarlılığı yüksek bilgisayar destekli sistemlerinin geliştirilmesi bir gerekliliktir. Bilgisayar destekli beyin tümörü tespit sistemlerinin geliştirildiği birçok çalışmada ise tüm MR görüntüsü temelli bir sınıflandırma işlemi benimsenmektedir. Gerçek senaryolarında sınıflandırma için tüm MR görüntüsünü kullanan yöntemler, MR görüntüsü yukarıda belirtildiği gibi farklı tür tümörler içerdiğinde eksik ve hatalı tanımlamalar ortaya çıkabilecektir. Bu sorunu çözmenin bir yolu, uzman müdahalesi ile MR'daki şüpheli görülen alanların işaretlendiği yarı otomatik bir sistem tasarlamaktır. Diğer bir yol ise tümörlü bölgeleri bölütleyecek ve sınıflandıracak tam otomatik bir sistem tasarlamaktır. Tüm bu belirtilenler tez çalışmasının bu bölümünde beyin tümörlerinin tespiti için OT sistemi geliştirilmesinin ardındaki temel motivasyonu oluşturmaktadır. Çalışmada DEG'lerde 1p/19q durumunu tahmin etmenin yanı sıra üç patolojik tümör türü gliom, menenjiyom ve hipofiz tümörlerini ayırt etmek için derin öğrenme temelli yarı otomatik bir sınıflandırma çerçevesi önerilmektedir. Tez çalışmanın bu bölümünün ana katkıları aşağıda verilmektedir.

1- MR görüntüsü daha önce açıklandığı gibi gerçek senaryolarda birden fazla tümörlü bölge içerebileceğinden, yanlış sınıflandırma hatalarını önlemek için ROI temelli sınıflandırma benimsenmiştir.

2- Derin öğrenmede orijinal ROI yerine genişletilmiş ROI kullanılmasının, aynı miktarda eğitim verisi ile sınıflandırma performansını önemli ölçüde arttırdığı ortaya koyulmaktadır. (Cheng ve diğ., 2015)'da tümörü çevreleyen dokulardan el yapımı öznitelikler çıkartılmış olsa da, tez çalışmasında sunulan yöntem aşağıda belirtilen

bazı yönler bakımından (Cheng ve diğ., 2015)'daki çalışmadan farklılıklar içermektedir.

- Belirtilen performans artışının arkasındaki önemli unsurlardan biri de hiç şüphesiz görevle ilgili özniteliklerin derin öğrenme ile öğrenilmesidir.

- Ancak derin öğrenme ile tatmin edici bir performans elde edilmesi, sahip olunan veri miktarına bağlıdır. Özellikle tıp alanındaki veri kıtlığı düşünüldüğünde, orijinal tümör bölgesi ile aynı performansın elde edilebilmesi için çok miktarda sentetik veri üretilmesi bir gerekliliktir. Bu amaçla veri çoğaltma stratejilerinden (örn: afin dönüşümler) yararlanılabilir. (Sajjad ve diğ., 2019)'de kapsamlı veri çoğaltma stratejilerinden yararlanılarak performansın %3.29 iyileştirildiği belirtilmektedir. Bununla birlikte, bir afin dönüşüm (örneğin rotasyon) performans üzerinde olumlu bir etkiye sahip olabilirken, diğer bir afin dönüşüm (örneğin ölçekleme) performansı olumsuz yönde etkileyebilmektedir (Zoph ve diğ., 2020). Veri çoğaltma için performansı iyileştirebilecek afin dönüşümler çapraz gerçeleme ile belirlenmelidir. Bu durum karşısında önerilen yöntem ile kapsamlı veri çoğaltma yapılmaksızın yalnızca ROI genişletmesi ile performans %8.97 oranında arttırılabilmektedir. Bu bağlamda, derin öğrenmede genişletilmiş tümör bölgelerinin kullanılmasının, performansın kapsamlı veri artırma stratejilerine olan ihtiyacı azalttığını ortaya koyulmaktadır.

3- Ağ derinleştikçe, sınıflandırma performansını iyileştiren ayırt edici bilgiler sönümlenebilmektedir. Bu durum, ağ tarafından kodlanan derin özniteliklerin taşıdığı ayırt edici bilgi miktarını azaltabilmektedir. Bu bağlamda, sığ ve derin özniteliklerin birleştirilmesinin, daha derin ağ tarafından kaybedilen düşük seviyeli anlamsal bilgileri telafi ederek sınıflandırma performansını iyileştirdiği ortaya koyulmaktadır.

4- Öznitelik birleştirme ve ROI genişletmenin (yani, genişletilmiş ROI'den çıkartılan sığ ve derin özniteliklerin birleştirilmesi) eşzamanlı kullanılmasının, sınıflandırma performansını önemli ölçüde iyileştirebildiği belirlenmiştir. Konumsal bilgi ve düşük seviyeli bilginin aynı anda dâhil edilmesi ile çıkartılan öznitelikler daha belirgin olmaktadır. Böylelikle, sınıflar doğrusal ayrılabilir hale gelmektedir.

Tez çalışmasının bu bölümü şu şekilde organize edilmektedir. Bölüm 3.1'de, ROI genişletme, öznitelik çıkarma ve öznitelik kaynaştırma aşamalarını içeren önerilen sınıflandırma çatısı tanıtılmaktadır. Bölüm 3.2'de deneysel sonuçlar sunulmaktadır. Bölüm 3.3'de tartışma, Bölüm 3.4'de görselleştirme ve son olarak Bölüm 3.5'de değerlendirme sunulmaktadır.

3.1. Önerilen Yöntem

Önerilen sınıflandırıcı yapısı ayrıntılı olarak Şekil 3.1'de verilmektedir. Şekil 3.1'den görüldüğü gibi önerilen yöntem, çevre dokularının ROI'ye dâhil edildiği bir ROI genişletme adımı, özniteliklerin paralel çalışan iki ayrı ağdan çıkartıldığı bir adım, öznitelik kaynaştırma ve sınıflandırma adımlarından oluşmaktadır.

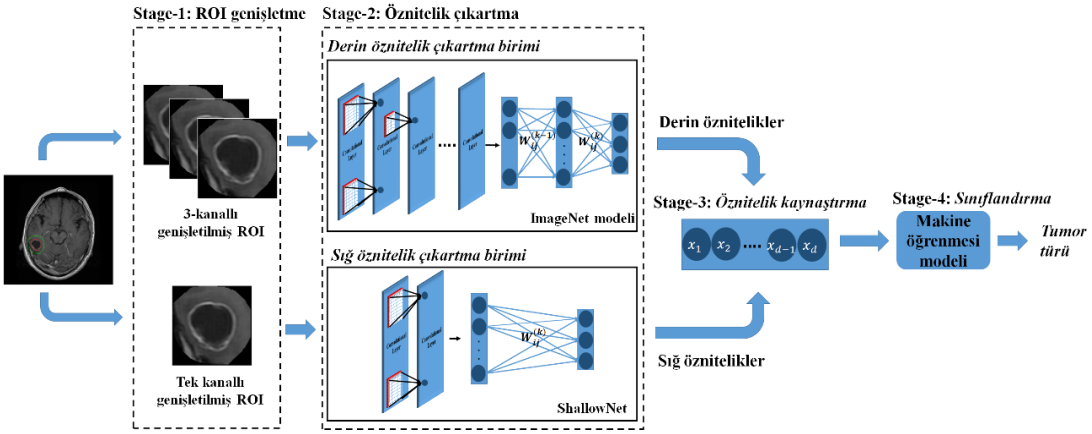

Şekil 3.1. Önerilen sınıflandırma çatısı (Öksüz ve diğ., 2022)

ROI genişletme adımında, tümör bölgesini çevreleyen dokular (genişletilmiş ROI) orijinal tümör bölgesine (ROI) dâhil edilmektedir. Daha sonra, genişletilmiş ROI, derin ağ için üç kanallı ve sığ ağ için tek kanallı (ShallowNet) olacak şekilde düzenlenmektedir. Öznitelik çıkartma adımında, derin öznitelikler derin ağdan ve sığ öznitelikler ise ShallowNet ağından çıkartılmaktadır. Son olarak derin ve sığ öznitelikler kaynaştırılarak sınıflandırmada aşamasında kullanılmaktadır.

3.1.1. Veri Kümeleri

Çalışmada *Brain tumor* ve TCIA'da verilen *LGG-1p19qDeletion* veri kümelerinden yararlanılarak önerilen yaklaşımın etkinliği gösterilmektedir. Veri kümelerine ait detaylar aşağıda verilmektedir.

Brain tumor veri kümesi: (Cheng, 2017)'de verilen veri kümesi 233 hastadan toplanmış T1 ağırlıklı kontrast iyileştirilmiş 3064 MR diliminden oluşmaktadır. Veri kümesi, Glioma (G), Meningioma (M) ve Pituitary (P) olmak üzere üç farklı tümör sınıfı içermektedir. Bölütleme maskeleri her bir dilim için veri kümesiyle birlikte sağlanmaktadır. Aynı zamanda hasta seviyesinde çapraz geçerleme indisleri de paylaşılmıştır. Veri kümesinin herhangi bir katında bulunan hastalara ait MR dilimleri diğer katlarda bulunmamaktadır. Tablo 3.2'de veri kümesinin her bir katında bulunan hasta sayısı ve her bir tümör sınıfının içerdiği kesit sayısı detaylı olarak verilmektedir.

Tablo 3.2. *Brain tumor* veri kümesinin her bir katında bulunan kesit ve hasta sayısı

		Kat-1	**Kat-2**	**Kat-3**	**Kat-4**	**Kat-5**	**Toplam**
Sınıflar	**G**	245	338	231	325	287	1426
	M	112	167	139	124	166	708
	P	185	174	202	179	190	930
#Kesit sayısı		542	679	572	628	643	3064
#Hasta sayısı		45	46	48	47	47	233

LGG-1p19qDeletion veri kümesi: (Akkus ve diğ., 2017; Clark ve diğ., 2013b; B. Erickson ve diğ., 2017; B. J. Erickson ve diğ., 2017)'de verilen veri kümesi DEG'li (DSÖ derece II & III) 159 hastaya ait T1C ve T2 ağırlıklı MR kesitinden oluşmaktadır. Tümör bölütleme maskeleri her bir MR dilimi için sağlanmaktadır. Veri kümesinde hastaların 1p/19q eş silinme durumlarına ait verilen bilgiler biyopsi kanıtlıdır. Bu bilgiler "n/n" ve "d/d" olmak üzere iki kategori içerisinde paylaşılmaktadır. 1p/19q biyobelirtecinin eş silinme durumunun "n/n" olması 1p ve 19q genlerinin silinmemiş olması, "d/d" olması ise her iki geninde silinmiş olması (eş-silinme) anlamına gelmektedir. Tablo 3.3'de her bir kategoride bulunan kesit sayıları verilmektedir.

Tablo 3.3. *LGG-1p19qDeletion* veri kümesinin her bir sınıfında bulunan kesit sayısı

Modalite	**Eş silinme var (d/d)**	**Silinme yok (n/n)**	**Toplam**
T1C	306	172	478
T2	306	172	478
#Kesit sayısı	612	344	956

Şekil 3.2'de (a)-(c) arasında verilen görsellerde *Brain tumor* veri kümesinin sırasıyla gliom, menenjiyom ve hipofiz tümör sınıflarından rastgele seçilen kesit örnekleri

gösterilmektedir. Şekil 3.2'de (d)-(g) arasında verilen görsellerde ise *LGG-1p19qDeletion* veri kümesindeki her bir sınıftan rastgele seçilen T1C ve T2-ağırlıklı örnek kesitler verilmektedir.

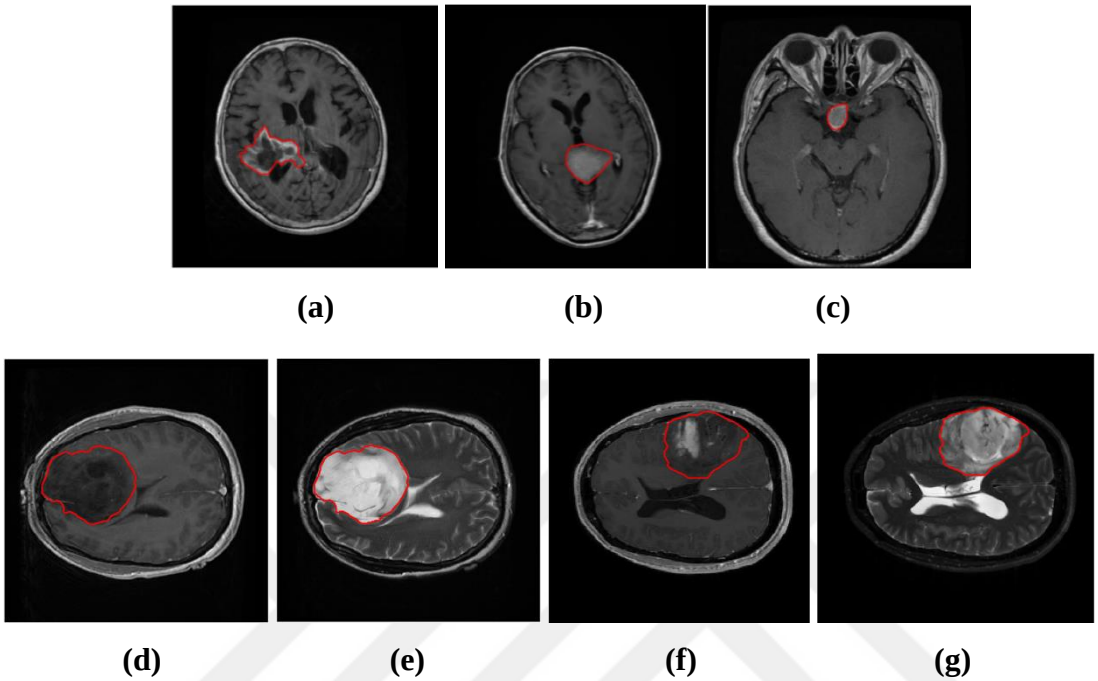

Şekil 3.2. Brain tumor veri kümesinin her bir tümör sınıfından seçilen örnek kesitler: (a) Gliom. (b) Menenjiyom. (c) Hipofiz tümörü. LGG-1p19qDeletion veri kümesinden seçilen örnek kesitler: (d)'de n/n sınıfına ait T1C ağırlıklı MR kesit, (e)'de (d)'de verilen kesitin T2 ağırlıklı karşılığı verilmektedir. (f)'de d/d sınıfından seçilen bir tümör örneğinin T1C ağırlıklı, (g)'de T2 ağırlıklı kesitleri verilmektedir. (f)'de d/d sınıfına ait T1C ağırlıklı kesit, (g)'de ise (d)'de verilen kesitin T2 ağırlıklı karşılığı gösterilmektedir. Her bir kesitte kırmızı ile vurgulanan çevritler tümör sınırlarını göstermektedir (Öksüz ve diğ., 2022)

3.1.2. ROI Genişletme

Bu bölümde tümör çevre dokularının ROI'ye dâhil edilmesi süreci anlatılmaktadır. Çalışmada önceden belirlenen sabit bir miktarda dokunun dâhil edilmesi yaklaşımı yerine performansı enbüyükleyecek miktarda dokunun dâhil edilmesi yaklaşımı benimsenmektedir. Bu amaçla çevre dokuların kademeli olarak ROI'ye dâhil edilmesinin sınıflandırma performansı üzerinde oluşturduğu etki incelenmektedir.

Tümörü çevreleyen dokular, belirli bir yarıçapa (R) sahip disk şeklindeki bir yapısal elemandan yararlanarak ikili ROI maskesini genişletilmesi ile orijinal tümör bölgesine kademeli olarak dâhil edilmektedir.

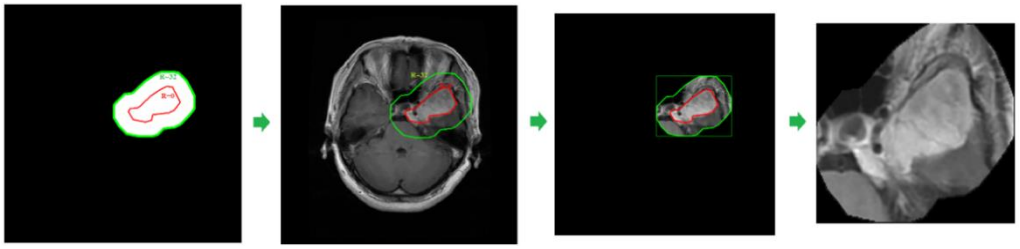

(a)

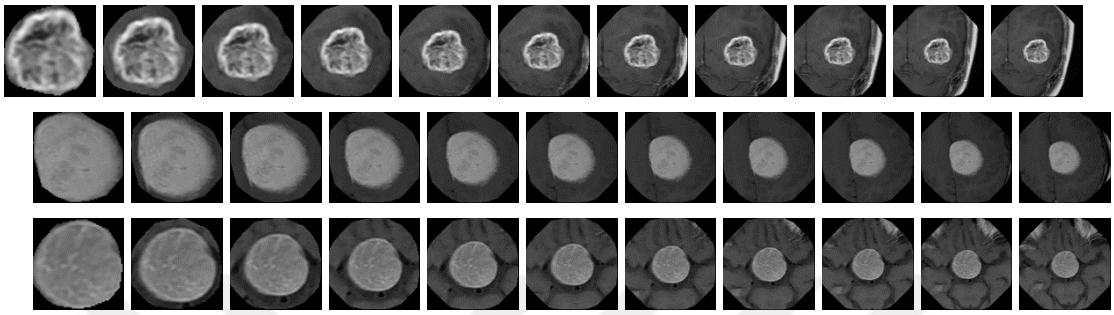

(b)

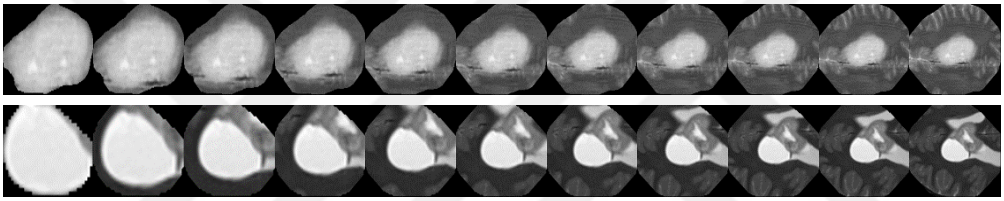

(c)

Şekil 3.3. (a) ROI genişletme süreci: beyin MR diliminden genişletilmiş tümör bölgesinin kırpılması ve ağ giriş çözünürlüğüne göre yeniden boyutlandırılması. En soldaki görüntüde verilen genişletilmiş tümör maskesi (yeşil kontur), orijinal ROI maskesini (kırmızı kontur) genişleterek elde edilmektedir. *Brain tumor* veri kümesinden örnek ROI'ler: (b) İlk sıra gliomayı, ikinci sıra menenjiyomu ve üçüncü sıra hipofiz tümörü sınıflarını göstermektedir. *LGG-1p19qDeletion* veri kümesinden örnek ROI'ler: (c) İlk satırdaki ROI'ler d/d sınıfına, ikinci satırdaki ROI'ler n/n sınıfına aittir. Sütunlar, sırasıyla 0, 8, 16, 24, 32, 40, 48, 56, 64, 72, 80 çeşitli disk boyutları için elde edilen tümör bölgelerini gösterir (Öksüz ve diğ., 2022)

Bunu gerçekleştirebilmek için ilk olarak orijinal tümör maskesi üzerinde sırasıyla R = 8, 16, 24, 32, 40, 48, 56, 64, 72, 80 disk şeklindeki yapısal elemanların kullanıldığı morfolojik yayma işlemi gerçekleştirilerek yeni tümör maskeleri elde edilmektedir. Ardından her bir MR kesiti genişletilmiş maskeler kullanılarak maskelenmektedir. Son olarak, maskelenmiş tümör görüntüsündeki genişletilmiş tümör bölgesi (yani yeni bir ROI), en küçük sınırlayıcı kutu ile kırpılarak özniteliklerin çıkartılacağı ağın giriş boyutuna göre yeniden boyutlandırılmaktadır (AlexNet için 227×227×3, AlexNet için 224×224×3 ResNet-18, GoogLeNet ve ShuffleNet). Şekil 3.3(a)'da disk boyutu R = 32 olduğunda çevre dokuların ROI'ye dâhil edilmesi süreci örneklenmektedir. Bu şekilde,

orijinal tümör maskesi (en soldaki görüntüde kırmızı çevrit) disk boyutu R = 32 kullanılarak genişletilerek yeni tümör maskesi (en soldaki görüntüde yeşil çevrit) elde edilmektedir. Bu işlemin sonunda, Şekil 3.3(b) ve Şekil 3.3(c)'de görüldüğü gibi her disk boyutu için 10 farklı genişletilmiş tümör bölgesi elde edilmektedir.

3.1.3. Öznitelik Çıkartma

Derin Öznitelikler

Tıbbi görüntüleme alanında etiketlenmiş veri miktarı genellikle ESA'yı eğitmek için yetersizdir. Bu sorunun üstesinden gelmek için transfer öğrenme iyi bir alternatif olabilmektedir (Raina ve diğ., 2007). Transfer öğrenmenin bir yolu, eldeki görev için ağın ince ayarlı yapılmasıdır. Diğer bir yol ise önceden eğitilmiş bir ağın ince ayar yapılmaksızın doğrudan öznitelik çıkartıcı olarak kullanılmasıdır. (Petrovska ve diğ., 2018)'de farklı ince ayar stratejileri açıklanmaktadır. Şekil 3.4'te transfer öğrenme aşamaları gösterilmektedir.

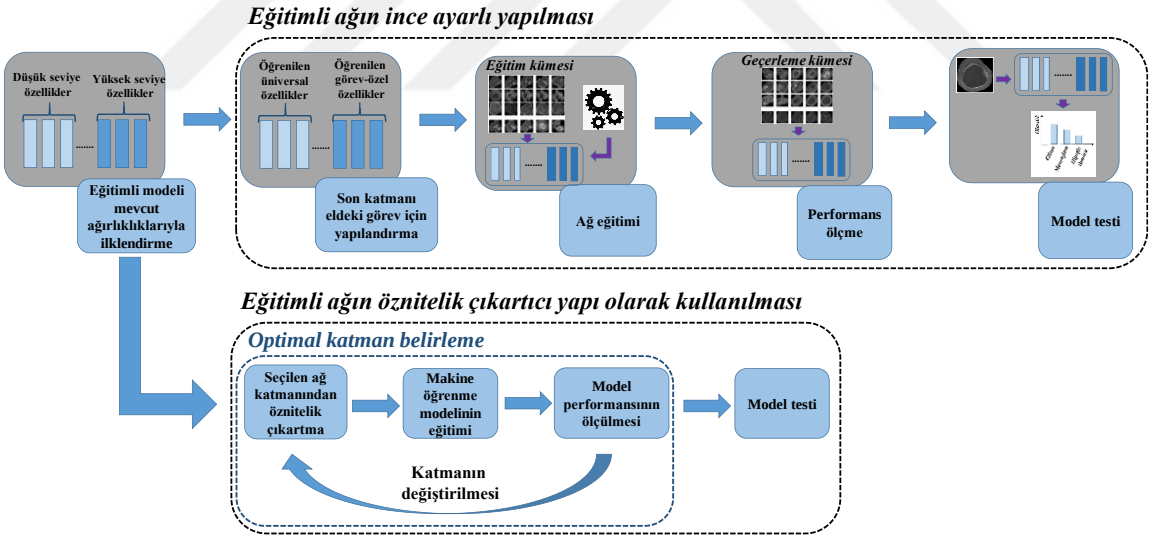

Şekil 3.4. Transfer öğrenmenin aşamaları (Öksüz ve diğ., 2022)

Çalışmada derin öznitelik çıkartma için derinlikleri kademeli olarak artan ve farklı karmaşıklıklara sahip olan AlexNet, ResNet-18, GoogLeNet ve ShuffleNet modellerinden yararlanılmaktadır. Tüm bu önceden eğitilmiş sınıflandırma modelleri, nesneleri 1000 kategoriden birine sınıflandırmak için ImageNet (Russakovsky ve diğ., 2015b) veri tabanı üzerinde eğitilerek birçok önemli düşük ve yüksek dereceli özniteliklerin birleşimini öğrenmişlerdir. Bu çalışmada yararlanılan veri kümeleri için,

tümör görüntüleri ile önceden eğitilmiş ağların başlangıçta eğitildiği görüntüler arasındaki benzerlik oldukça düşüktür. Buna ek olarak yararlanılan veri kümelerindeki örnek sayısı oldukça farklıdır. Bu nedenle, çalışmada iki farklı transfer öğrenme tekniğinden yararlanılmaktadır. Yararlanılan tekniklere ilişkin detaylar aşağıda verilmektedir.

İnce Ayarlı Ağdan Derin Öznitelik Çıkartma: 3064 kesit içeren *Brain tumor* (Cheng, 2017) veri kümesi önceden eğitilmiş ağların ince ayarı için yeterli sayıda örnek içermektedir. Bu nedenle, ağlar bu veri kümesi sıfırdan ince ayarlı yapılmaktadır. Tüm ağların son tam bağlı katmanı üç sınıflı sınıflandırma problemi için yapılandırılmıştır. İnce ayardan sonra, ağlar derin öznitelik çıkartıcılar olarak kullanılmaktadır. Derin öznitelikler her bir ağın son tam bağlı katmanından çıkartılmaktadır.

Hazır Ağdan Derin Öznitelik Çıkartma: *LGG-1p19qDeletion* veri kümesi 956 kesit (T1C ve T2 ağırlıklı dilimler için 478 adet) içermektedir. Bu veri seti için ince ayar yerine önceden eğitilmiş ağ doğrudan öznitelik çıkartıcı olarak kullanılmaktadır. En iyi öznitelik çıkartma katmanı ise deneysel süreç ile bulunmaktadır.

Sığ Öznitelikler

Derin sinir ağlarında, ağın her katmanında farklı soyut düzeyde giriş verileri elde edilmektedir. Ağ derinleştikçe, sınıflandırma performansını artıracak daha karmaşık ve göreve özgü öznitelikler öğrenilmektedir. Bu öznitelikler, üst düzey bilgiler taşımaktadır. Ancak ağın derinleşmesi, düşük seviyeli bilgi kaybına neden olmaktadır. Bu nedenle, çalışmada iki adet evrişimsel ve iki tam bağlı katmandan oluşan bir CNN mimarisi, tümör kenar özniteliklerine ilişkin düşük seviyeli bilgileri öğrenmek için tasarlanmıştır.

Tablo 3.4. Sığ ESA katmanları (Öksüz ve diğ., 2022)

Katmanlar	Açıklama
Giriş katmanı	64×64×1
Evrişimsel Katman-1	3×3×1 boyutlu 64 çekirdek, stride 1×1
Evrişimsel Katman-2	3×3×64 boyutlu 64 çekirdek, stride 1×1
Tam Bağlı Katman-1	800 aktivasyon elemanı
Tam Bağlı Katman-2	3 aktivasyon elemanı

Tasarlanan mimari (P. Afshar, Mohammadi, and Plataniotis 2018)'den çeşitli varyasyonlarla benimsenmiştir. ShallowNet olarak adlandırılmış ve yapılandırması Tablo

3.4'te verilmiştir. Ağın giriş katmanı boyutu, parametre sayısını azaltmak için 64×64 piksel boyutlu blokları ve 1 kanallı görüntüleri kabul edecek şekilde tasarlanmıştır. Eğitimden sonra, ShallowNet ağının son tam bağlı katmanından sığ öznitelikler çıkartılmaktadır.

3.1.4. Öznitelik Kaynaştırma ve Sınıflandırma

Önerilen yaklaşımda, bilgi kaybını telafi etmek için sığ öznitelikler ile derin öznitelikler ile birleştirilmiştir. Öznitelik füzyonu, ince taneli öznitelikleri kaba taneli olanlar ile birleştirmeye olanak tanımaktadır. Kaynaştırılmış öznitelikler, klasik makine öğrenme modellerinin eğitiminde kullanılmaktadır. Bu amaçla çalışmada k-NN ve DVM modellerinden yararlanılmaktadır.

3.2. Deneysel Sonuçlar

3.2.1. Performans Değerlendirme Metrikleri

Birçok çalışmada önerilen sınıflandırıcı modellerin değerlendirilmesinde sınıflandırma doğruluğu ortak metrik olarak kullanılmaktadır. Sınıflandırma doğruluğu (ACC) Eşitlik (3.1)'deki gibi verilebilmektedir.

$$\mathrm{ACC}=\frac{\mathrm{TP}+\mathrm{TN}}{\mathrm{TP}+\mathrm{TN}+\mathrm{FP}+\mathrm{FN}} \tag{3.1}$$

Bununla birlikte, veri kümesinde sınıf dengesizliği olduğunda sınıflandırıcı model çoğunluk sınıfına yanlı hale gelmektedir. Bu nedenle, sınıf dengesizliğine sahip bir veri kümesi ile eğitilmiş bir model için bir değerlendirme metriği olarak yalnızca sınıflandırma doğruluğunun kullanılması gerçekçi sonuçları yansıtmayacaktır. Bu çalışmada kullanılan veri kümeleri dengesiz dağılıma sahip zorlu veri kümeleridir. Daha gerçekçi sonuçlar, kesinlik (PPV), duyarlılık (TPR), özgüllük (SPEC) ve F_1 skoru gibi metrikler kullanılarak elde edilmektedir. TPR, PPV, SPEC ve F_1 skorları Eşitlik (3.2)'den yararlanılarak hesaplanabilmektedir.

$$\mathrm{TPR}=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}},\ \mathrm{PPV}=\frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FP}},\ \mathrm{SPEC}=\frac{\mathrm{TN}}{\mathrm{TN}+\mathrm{FP}},\ \mathrm{F_1\text{-}Score}=2\times\frac{\mathrm{TPR}\times\mathrm{PPV}}{\mathrm{TPR}+\mathrm{PPV}} \tag{3.2}$$

3.2.2. Önerilen Sınıflandırıcı Yapısının Eğitilmesi ve Değerlendirilmesi

Önerilen sınıflandırma çatısı için eğitim parametreleri Tablo 3.5'te verilmektedir. Tablo 3.5'ten görüldüğü gibi ağırlık ve yanlılık öğrenme hızı hiperparametrelerinin her ikisi de son katmanlarda öğrenmeyi hızlandırabilmek için 10 olarak kurulmaktadır. Bu ayar aynı zamanda ilk katmanlarda öğrenilen genel özniteliklerin çok fazla bozulmasını da önleyebilmektedir.

Tablo 3.5. Çalışmada kullanılan hiperparametreler (Öksüz ve diğ., 2022)

Kurulum				
Hiperparametreler	**AlexNet, GoogLeNet, ResNet-18, ShuffleNet**	**ShallowNet**	**DVM**	**k-NN**
Optimizasyon algoritması	SGDM	SGDM	Fonk: Doğrusal Ölçek: 1 Kodlama: Bire karşı bir Hata işlevi.: Hinge	Komşu sayısı: 1 Mesafe metriği: Öklit Mesafe ağırlığı: Eşit
Mini Yığın Boyutu (MBS)	32	32		
Maksimum Epoch	10	20		
Global Öğrenme Hızı	10^{-4}	10^{-3}		
Momentum	0.9	0.9		
L_2 Düzenlileştirme	10^{-5}	10^{-6}		
Ağırlık & Yanlılık Öğrenme Çarpanı	10	-		
Hata işlevi	Çapraz entropi			

Aşırı uydurmadan kaçınmak için her epoch değerinde veri çoğaltma gerçekleştirilmektedir. Böylelikle her bir epoch değerinde eğitim setinin farklı bir formu ağlar tarafından görülmektedir. Çalışmada veri kümeleriyle birlikte verilen hasta seviyesinde 5-kat çapraz geçerleme (CV-5) indisleri kullanıldığından, beş adet eğitim seti ve beş adet test seti bulunmaktadır. Her seferinde eğitim setindeki kesitlerin %90'ı rastgele seçilerek modellerin eğitiminde kullanılmaktadır. Kalan kesitler ise aşırı uydurmayı kontrol etmek için ağın geçerlemesinde kullanılmaktadır. Eğitimden sonra, eğitimde kullanılan görüntüler, sığ ve derin öznitelik kümelerini elde etmek için ShallowNet ve ince ayarlı derin ağa geri beslenmektedir. Ardından çıkartılan öznitelik kümeleri kaynaştırılarak model eğitiminde kullanılmaktadır. Eğitimli model, ayrılmış test katını sınıflandırıcı yapısına besleyerek çıkartılan kaynaşık öznitelikler ile değerlendirilmektedir. Böylelikle her bir test katında hesaplanan hata değerlerinin ortalaması alınmaktadır. Elde edilen son değer, ilgili disk boyutu için önerilen yöntemin CV-5 hatası olmaktadır.

Şekil 3.5'te önerilen yöntemin *Brain tumor* veri kümesi üzerinde geçerlemesi süreci gösterilmektedir. Çalışmada *Brain tumor* veri kümesi üzerindeki en yüksek performans DVM modeliyle elde edilmektedir. Önerilen yöntem daha sonra *LGG-1p19qDeletion* veri kümesi üzerinde geçerlenmektedir. Bu veri kümesi üzerinde DVM modeline kıyasla k-NN modeli ile daha yüksek bir performans elde edildiğinden, sınıflandırma aşamasında k-NN modeli kullanılmıştır. İlk olarak veri kümesinin n/n ve d/d sınıflarının her birinden rastgele 100 örnek seçilerek harici bir test kümesi oluşturulmaktadır. Kalan 756 örnek (d/d: 512, n/n: 244) ise k-NN modelinin eğitiminde kullanılmaktadır.

Ardından modelin 10-kat çapraz geçerlenmesi amacıyla eğitim kümesi örtüşmeyen 10 ayrı kata ayrılmaktadır. Son olarak, en iyi performansı veren model, Şekil 3.6'da gösterildiği ayrılan test kümesi üzerinde değerlendirilmektedir.

3.2.3. ROI Genişletme ve Öznitelik Kaynaştırmanın Sınıflandırma Performansı Üzerindeki Etkisi

Bu bölümde, ROI genişlemesi ve öznitelik füzyonunun sınıflandırma performansı üzerindeki etkisi ortaya koyulmaktadır. Bu amaçla, önerilen yöntem değişen disk boyutlarına bağlı olarak çapraz geçerlenmektedir. Şekil 3.7'de öznitelik füzyonunun etkisini görmek için, kaynaştırılmış özniteliklerle elde edilen DVM model performansı, yalnızca derin veya yalnızca sığ öznitelikler kullanıldığında elde edilen performans ile karşılaştırmalı olarak verilmektedir. Şekil 3.7'de (a)-(d) arasındaki şekillerde, mavi eğri sığ özniteliklerle elde edilen DVM performansını, kırmızı eğri derin özniteliklerle elde edilen DVM performansını ve yeşil eğri, kaynaşmış özniteliklerle elde edilen DVM performansını göstermektedir. Sığ öznitelikler, kaynaşmış özniteliklere eşit ölçüde katkıda bulunduğundan, derin özniteliklerin çıkartıldığı ince ayarlı ağ, genel performansı belirlemektedir. Şekil 3.7'de (a)-(d) arasındaki şekillerdeki kırmızı eğriler, sırasıyla ince ayarlı AlexNet, GoogLeNet, ResNet-18 ve ShuffleNet modelleri tarafından çıkarılan derin öznitelikler ile elde edilen DVM model performanslarını göstermektedir. Şekillerden görülebileceği gibi, öznitelik füzyonu ve ROI genişlemesi birlikte gerçekleştirildiğinde, sınıflandırma performansı daha da iyileştmektedir.

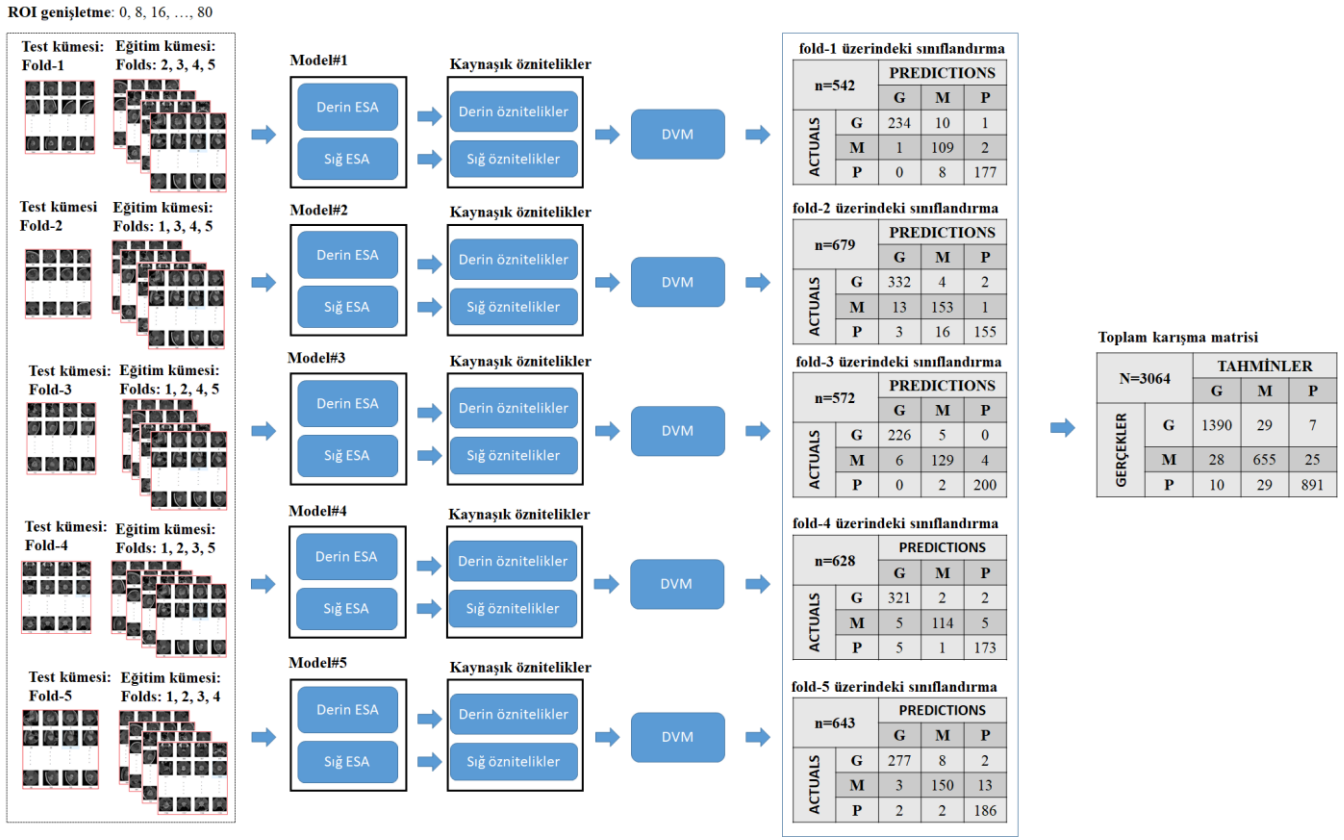

Şekil 3.5. Önerilen sınıflandırıcı yapısının Brain tumor veri kümesi üzerinde değerlendirilmesi. Karışıklık matrisi, en iyi sınıflandırma performansının elde edildiği disk boyutu R için sonuçları temsil etmektedir (Öksüz ve diğ., 2022)

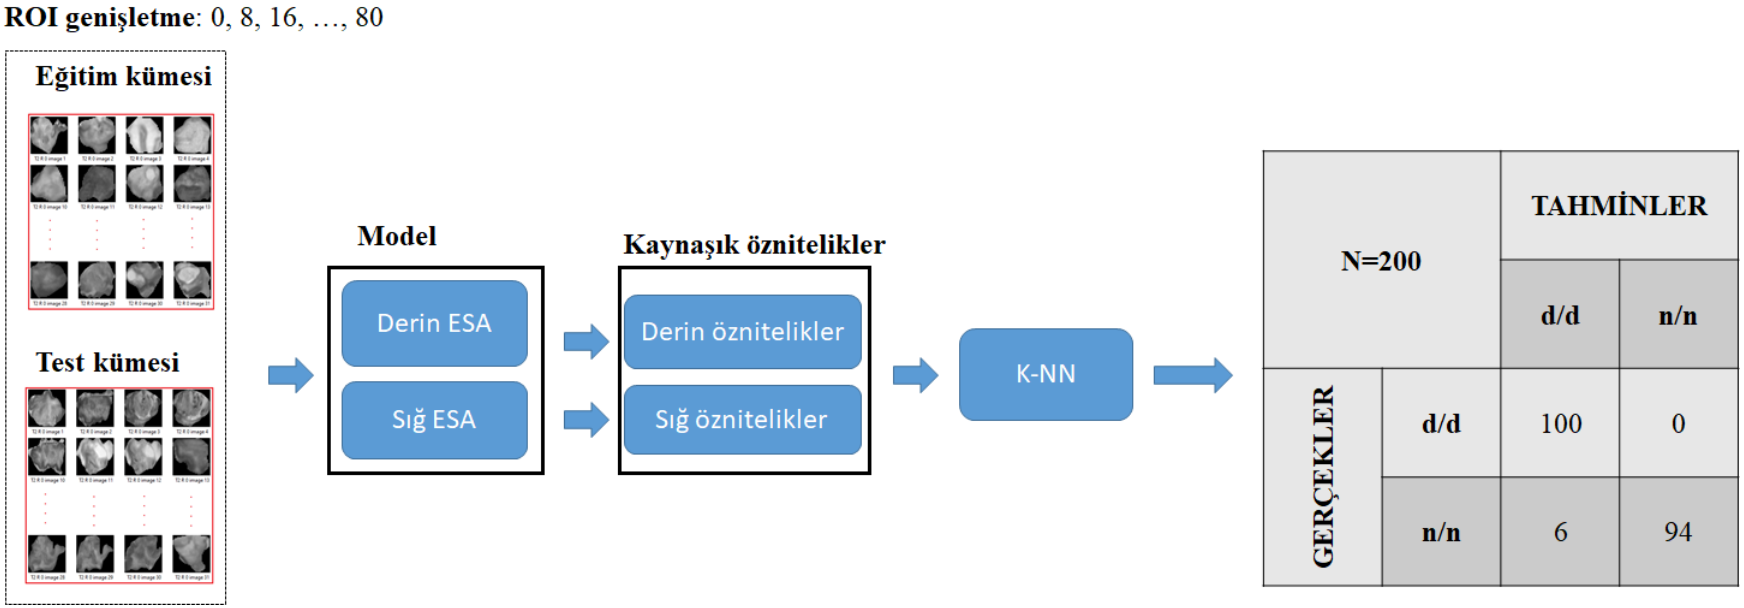

Şekil 3.6. Önerilen yöntemin LGG-1p19qDeletion veri kümesi üzerinde değerlendirilmesi süreci. Karışıklık matrisi, en iyi sınıflandırma performansının elde edildiği disk boyutu R için elde edilen sonuçları temsil etmektedir (Öksüz ve diğ., 2022)

Belirtilmesi gereken diğer bir durum ise sınıflandırma performansının belirli bir disk boyutuna kadar iyileşmesidir. Belli bir disk boyutundan sonra önemli bir iyileşme yoktur veya hiç iyileşme yoktur.Bu, ilişkisiz özniteliklerin devreye girdiğini göstermektedir. AlexNet, önerilen sınıflandırma çatısının derin öznitelik çıkartıcı olarak kullanıldığında, R=56 disk boyutu için maksimum sınıflandırma performansı elde edilmektedir. Öte yandan, GoogLeNet, ResNet-18 ve ShuffleNet modelleri önerilen sınıflandırma çatısının derin öznitelik çıkartıcıları olarak kullanıldığında, sırasıyla R = 80, 56, 72 disk boyutları için maksimum sınıflandırma performansı elde edilmektedir. Performans karşılaştırmaları için herhangi bir ince ayarlı ağdan ve belirli bir disk boyutu *R* için ShallowNet'ten türetilen kaynaştırılmış öznitelikler $[\text{DeepNetwork}_{\text{ft}}+\text{ShallowNet}]^{R}$ ile gösterilmektedir. Belirli bir disk boyutu R için herhangi bir ince ayarlı ağdan türetilen derin öznitelikler ise $[\text{DeepNetwork}_{\text{ft}}]^{R}$ ile gösterilmektedir.

Tablo 3.6. Çalışmada kullanılan yöntemler için *Brain tumor* veri kümesinin her bir katında elde edilen doğruluk skorları (Öksüz ve diğ., 2022)

Yöntem	**Test Set-1**	**Test Set-2**	**Test Set-3**	**Test Set-4**	**Test Set-5**	***Avg.***
$[\text{AlexNet}_{\text{ft}}]^{0}$ +DVM	84,50	91,26	87,76	88,64	89,63	*88,35*
$[\text{AlexNet}_{\text{ft}}+\text{ShallowNet}]^{0}$ +DVM	86,59	91,16	89,04	90,45	90,46	*89,54*
$[\text{AlexNet}_{\text{ft}}]^{56}$ +DVM	95,08	95,29	95,80	96,50	94,19	*95,37*
$[\text{AlexNet}_{\text{ft}}+\text{ShallowNet}]^{56}$ +DVM	96,92	96,37	97,79	96,71	95,23	*96,60*
$[\text{GoogLeNet}_{\text{ft}}]^{0}$ +DVM	84,50	91,26	87,65	89,70	90,36	*88,69*
$[\text{GoogLeNet}_{\text{ft}}+\text{ShallowNet}]^{0}$ +DVM	85,85	91,85	89,16	91,61	91,60	*90,01*
$[\text{GoogLeNet}_{\text{ft}}]^{80}$ +DVM	96,56	95,29	96,15	95,12	93,68	*95,30*
$[\text{GoogLeNet}_{\text{ft}}+\text{ShallowNet}]^{80}$ +DVM	97,42	96,56	97,79	96,92	95,96	*96,93*
$[\text{ShuffleNet}_{\text{ft}}]^{0}$ +DVM	88,68	91,95	90,21	92,14	91,50	*90,89*
$[\text{ShuffleNet}_{\text{ft}}+\text{ShallowNet}]^{0}$ +DVM	89,67	92,93	91,14	92,25	92,12	*91,62*
$[\text{ShuffleNet}_{\text{ft}}]^{72}$ +DVM	96,06	91,95	96,04	95,54	94,19	*94,65*
$[\text{ShuffleNet}_{\text{ft}}+\text{ShallowNet}]^{72}$ +DVM	97,05	95,88	97,90	97,35	95,44	*97,12*
$[\text{ResNet18}_{\text{ft}}]^{0}$ +DVM	89,42	93,03	92,89	91,93	92,85	*92,02*
$[\text{ResNet18}_{\text{ft}}+\text{ShallowNet}]^{0}$ +DVM	89,05	93,32	93,47	91,93	92,95	*92,14*
$[\text{ResNet18}_{\text{ft}}]^{56}$ +DVM	97,66	95,88	97,09	97,24	96,16	*96,76*
$[\text{ResNet18}_{\text{ft}}+\text{ShallowNet}]^{56}$ +DVM	97,29	96,17	98,02	97,88	96,89	***97,25***

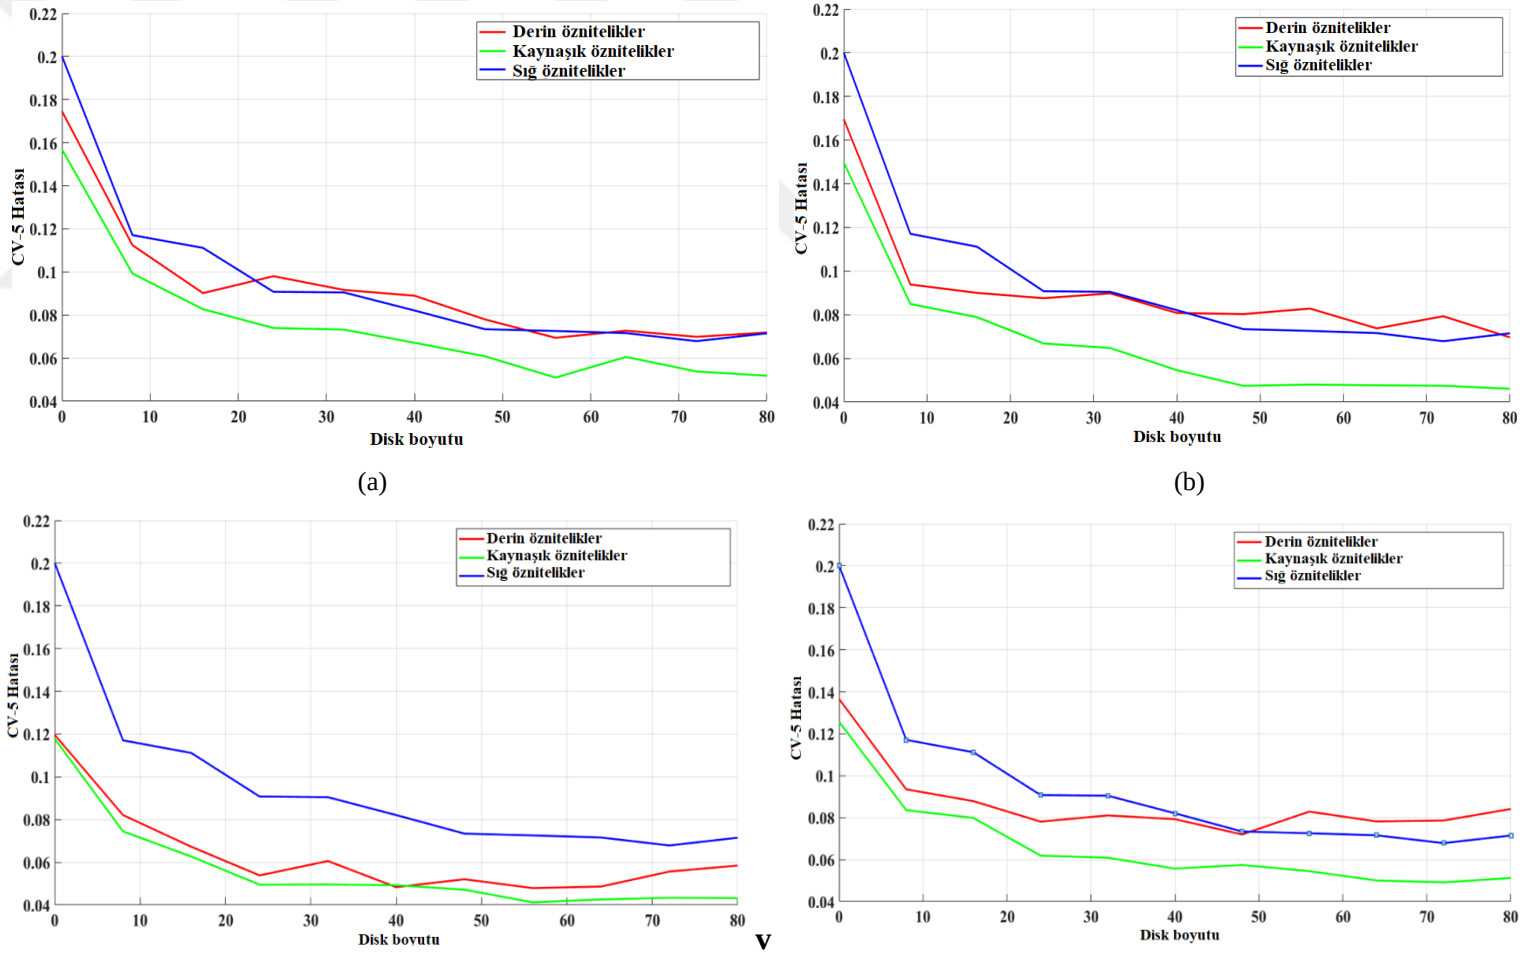

Şekil 3.7. Önerilen sınıflandırıcı yapısında derin öznitelik çıkartıcı olarak farklı ince ayarlı ağların kullanılması durumunda elde edilen performansın karşılaştırılması. Derin öznitelik çıkartıcı olarak (a)'da AlexNet, (b)'de GoogLeNet, (c)'de ResNet-18, (d)'de ShuffleNet kullanılmaktadır (Öksüz ve diğ., 2022)

Önerilen yöntemin etkisini göstermek için her bir mimari ile elde edilen sınıflandırma doğruluk skorları, yalnızca derin öznitelikler kullanılarak elde edilen skorlar ile karşılaştırılmaktadır. Tablo 3.6'da her bir yöntem ile test katlarında elde edilen doğruluk skorları verilmektedir. Tablo 3.6'dan görüldüğü gibi, tek başına öznitelik füzyonu sınıflandırma doğruluğuna yaklaşık %1.14'lik bir katkıda bulunurken, tek başına ROI genişlemesi ortalama olarak yaklaşık %5.84'lik bir katkıda bulunmaktadır. Bunların bir sonucu olarak, ROI genişletme ile öznitelik füzyonu (önerilen yöntem), genel sınıflandırma doğruluğuna ortalama olarak yaklaşık %6.98'lik bir katkıda bulunmaktadır. Öte yandan, en iyi sınıflandırma performansı, ResNet-18 önerilen sınıflandırma çatısının derin öznitelik çıkartıcısı olarak kullanıldığında elde edilmektedir. Şekil 3.5'te her bir test katında elde edilen karışıklık matrisleri bu durum için verilmektedir.

Şekil 3.8'deki saçılım çiziminde, çalışmadaki her bir yöntem ile elde edilen ortalama koşma zamanı karşısında ortalama doğruluk puanları verilmektedir.

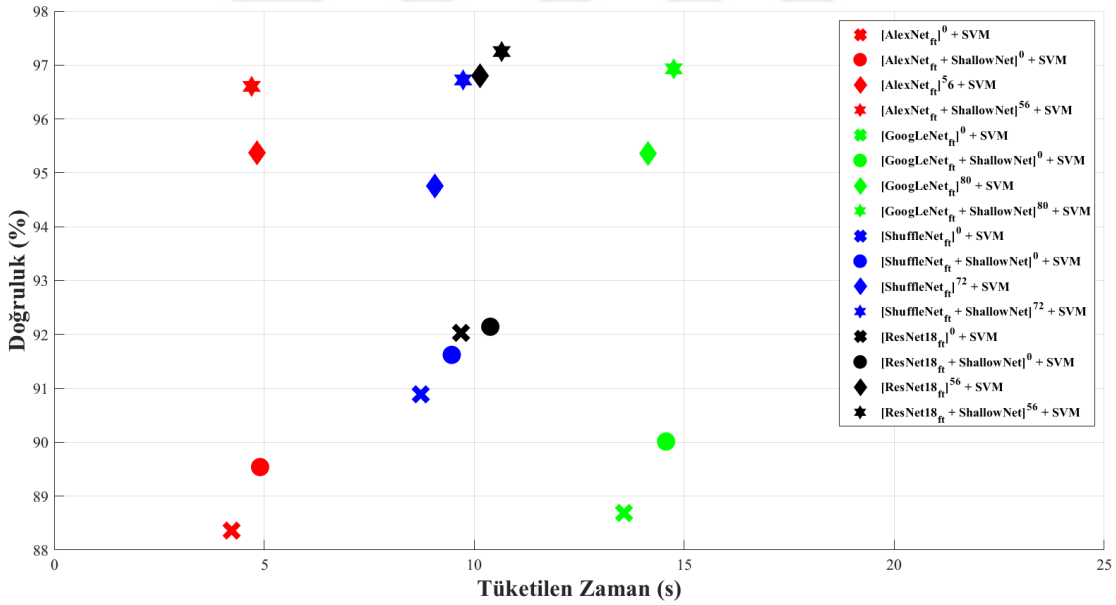

Şekil 3.8. Her bir yöntem ile elde edilen ortalama geçen süreye karşı ortalama doğruluk (Öksüz ve diğ., 2022)

Şekil 3.8'de ROI genişlemesi ve öznitelik füzyonu kullanılarak elde edilen sonuçlar heksagram şekilli işaretler ile gösterilirken, tek başına öznitelik füzyonu ile elde edilen sonuçlar oval şekilli işaretler ile gösterilmektedir. Yalnızca ROI genişletme ile derin öznitelikler kullanılarak elde edilen sonuçlar elmas şekilli işaretler ile gösterilirken, ROI genişletmesi olmadan yalnızca derin öznitelikler kullanılarak elde edilen sonuçlar çapraz-

çapraz şekilli işaretler ile gösterilmektedir. Kırmızı, yeşil, mavi ve siyah renklerde verilen şekiller sırasıyla AlexNet, GoogLeNet, ShuffleNet ve ResNet-18 modelleri kullanıldığında elde edilen sonuçları temsil etmektedir. Şekil 3.8'den görüldüğü gibi, önerilen yönteme (heksagram şekilli işaretler) en yakın sonuçlar, ROI genişleme sonucu elde edilen derin öznitelikler (elmas şeklindeki işaretler) ile elde edilmektedir. Önerilen sınıflandırma çatısındaki sığ öznitelik çıkartma ve öznitelik füzyonu adımları 3064 MRI dilimini işlemek ve sınıflandırmak için geçen süreyi ortalama olarak 0.41 saniye arttırmaktadır. Bununla birlikte, bu ek adım, sınıflandırma doğruluğunu %1.45 oranında arttırmaktadır. Öte yandan, 3064 MRI dilimlerini ortalama %97.25 doğrulukla işlemek ve sınıflandırmak ise yaklaşık olarak 10.6 saniye sürmektedir. Buna göre hız ve doğruluk arasında yeterince iyi bir denge elde edilmektedir.

Tablo 3.7'de çalışma kapsamında uygulanan her bir yöntem ile elde edilen sonuçlar karşılaştırmalı olarak verilmektedir. Öznitelik kaynaştırma ve ROI genişletmenin katkılarını görmeyi kolaylaştırmak için, her mimari ile yalnızca öznitelik füzyonu ve yalnızca ROI genişletmenin gerçekleştirildiği durumlarda elde edilen katkıların ortalaması alınmaktadır. Buna göre, tek başına öznitelik füzyonu PPV, TPR, SPEC, F_1 ve ACC skorlarını sırasıyla %1.73, %1.75, %0.82, %1.74 ve %1.14 oranlarında artırmaktadır. Tek başına ROI genişletmesi ise PPV, TPR, SPEC, F_1 ve ACC skorlarını sırasıyla %9.28, %9.19, %4.23, %9.24 ve %5.84 oranlarında artırmaktadır. Bunların bir sonucu olarak, ROI genişletme ile öznitelik füzyonunun birlikte uygulanması, PPV, TPR, SPEC, F_1 ve ACC skorlarını sırasıyla yaklaşık olarak %11.02, % 10.95, %5.06, %10.98 ve %6.98 oranlarında artırmaktadır. Her iki durum için de en iyi puanlar, ResNet-18 önerilen sınıflandırma yapısının derin öznitelik çıkartıcısı olduğunda elde edilmektedir. Bu durum, ResNet-18 modelinin ağ derinleştikçe atlama bağlantılarıyla düşük seviyeli bilgi akışına izin verdiğini ortaya koymaktadır. Bu nedenle, bu modeli sınıflandırıcı yapısının derin öznitelik çıkartıcısı olarak kullanmak, düşük seviyeli bilgi kaybını maksimum düzeyde telafi etmektedir.

Önerilen yöntemin *Brain tumor* veri kümesi üzerinde geçerlenmesinde en iyi performans ResNet-18 modeli yöntemin derin öznitelik çıkartıcı ağı olarak kullanıldığında elde edilmektedir.

Tablo 3.7. *Brain tumor* veri kümesi üzerinde yöntemlerin sınıflandırma performanslarının karşılaştırılması (Öksüz ve diğ., 2022)

Yöntem	Avg. PPV (%)	Avg. TPR (%)	Avg. SPEC (%)	Avg. F_1 Score (%)	Avg. ACC (%)
$[\text{AlexNet}_{ft}]^{0}$ +DVM	80,83 ±1,39	80,91 ±1,39	91,40 ±0,99	80,87 ±1,39	88,35 ±1,13
$[\text{AlexNet}_{ft}+\text{ShallowNet}]^{0}$ +DVM	82,74 ±1,33	82,70 ±1,33	92,24 ±0,94	82,72 ±1,33	89,54 ±1,08
$[\text{AlexNet}_{ft}]^{56}$ +DVM	92,28 ±0,94	91,97 ±0,96	96,46 ±0,65	92,12 ±0,95	95,37 ±0,74
$[\text{AlexNet}_{ft}+\text{ShallowNet}]^{56}$ +DVM	94,16 ±0,83	94,11 ±0,83	97,41 ±0.56	94,13 ±0,83	96,60 ±0,64
$[\text{GoogLeNet}_{ft}]^{0}$ +DVM	81,64 ±1,37	81,84 ±1,36	91,61 ±0,98	81,74 ±1,36	88,69 ±1,12
$[\text{GoogLeNet}_{ft}+\text{ShallowNet}]^{0}$ +DVM	83,68 ±1,30	83,87 ±1,30	92,63 ±0,92	83,78 ±1,30	90,01 ±1,06
$[\text{GoogLeNet}_{ft}]^{80}$ +DVM	92,07 ±0,95	91,88 ±0,96	96,42 ±0,65	91,98 ±0,96	95,30 ±0,74
$[\text{GoogLeNet}_{ft}+\text{ShallowNet}]^{80}$ +DVM	94,75 ±0,78	94,62 ±0,79	97,64 ±0,53	94,68 ±0,79	96,93 ±0,61
$[\text{ShuffleNet}_{ft}]^{0}$ +DVM	85,05 ±1,26	84,88 ±1,26	93,19 ±0,89	84,96 ±1,26	90,89 ±1,01
$[\text{ShuffleNet}_{ft}+\text{ShallowNet}]^{0}$ +DVM	86,23 ±1,22	86,01 ±1,22	93,72 ±0,85	86,12 ±1,22	91,62 ±0,98
$[\text{ShuffleNet}_{ft}]^{72}$ +DVM	90,96 ±1,01	90,82 ±1,02	95,94 ±0,69	90,89 ±1,01	94,65 ±0,79
$[\text{ShuffleNet}_{ft}+\text{ShallowNet}]^{72}$ +DVM	94,40 ±0,81	94,21 ±0,82	97,48 ±0,55	94,30 ±0,82	97,12 ±0,59
$[\text{ResNet18}_{ft}]^{0}$ +DVM	86,94 ±1,19	86,77 ±1,19	93,99 ±0,84	86,85 ±1,19	92,02 ±0,95
$[\text{ResNet18}_{ft}+\text{ShallowNet}]^{0}$ +DVM	87,06 ±1,18	86,73 ±1,20	94,10 ±0,83	86,89 ±1,19	92,14 ±0,95
$[\text{ResNet18}_{ft}]^{56}$ +DVM	94,59 ±0,80	94,41 ±0,81	97,53 ±0,54	94,50 ±0,80	96,76 ±0,62
$[\text{ResNet18}_{ft}+\text{ShallowNet}]^{56}$ +DVM	**95,25** ±0,75	**95,27** ±0,75	**97,91** ±0,50	**95,26** ±0,75	**97,25** ±0,57

Bu nedenle bu model önerilen yöntemin *LGG-1p19qDeletion* veri kümesi üzerinde geçerlenmesinde önerilen yöntemin derin öznitelik çıkartıcısı olarak kullanılmaktadır. Daha önce de belirtildiği gibi bu durumda hazır ağ doğrudan öznitelik çıkartıcı olduğundan ağın öznitelik çıkartma için en uygun katmanı belirlenmektedir. Çevre dokularının kademeli olarak ROI'ye dâhil edilmesi ile derin öznitelikler, sırasıyla hazır ağın res3a-relu, res3b-relu, res4a-relu, res4b-relu, res5a-relu, res5b-relu katmanlarından çıkartılmaktadır. Tablo 3.8'de CV-10 doğruluk skorları verilmektedir.

Tablo 3.8'den görüldüğü gibi, çevre dokuları ROI'ye dâhil edildikçe her bir katmandan çıkartılan derin öznitelikler sınıflandırma performansını önemli derecede iyileştirmektedir.

Tablo 3.8. Değişen disk boyutlarına bağlı olarak elde edilen CV-10 doğruluk skorları (Öksüz ve diğ., 2022)

			DİSK BOYUTU											
	Katman	**Boyut**	**0**	**8**	**16**	**24**	**32**	**40**	**48**	**56**	**64**	**72**	**80**	**Avg**
CV-10 Accuracy	**res3a-relu**	128	86,8	87,6	89,0	92,3	93,5	93,7	91,5	94,7	94,8	95,5	95,4	*92,2*
	res3b-relu	128	88,9	89,0	91,5	93,7	93,8	92,2	94,6	94,6	95,5	95,2	95,1	*93,1*
	res4a-relu	256	87,3	89,3	94,4	93,9	93,8	93,8	94,4	95,1	96,3	94,6	94,6	*93,4*
	res4b-relu	256	92,7	93,3	94,0	94,3	95,0	95,8	95,1	95,9	95,0	94,4	96,8	*94,7*
	res5a-relu	512	89,4	91,8	94,8	94,2	94,0	95,6	95,9	94,6	94,3	93,5	95,1	*93,9*
	res5b-relu	512	83,2	86,6	88,1	88,4	89,6	91,0	90,2	93,3	92,5	92,9	91,7	*89,7*
	fc1000	1000	78,3	78,7	82,8	83,1	82,5	86,0	88,8	88,9	90,9	90,7	90,5	*85,5*

Bununla birlikte her bir katmanın genel performansını ifade eden ortalama skorlara bakıldığında performansın res4b-relu katmanına kadar kademeli olarak arttığı ancak bu katmandan sonra ise kademeli olarak azaldığı görülmektedir. Şekil 3.9'da her bir katmandan elde edilen ortalama CV-10 hatasının değişimi gösterilmektedir. Bu durum, res4b-relu katmanından sonra performansı düşüren ilişkisiz özniteliklerin devreye girdiğini ortaya koymaktadır.

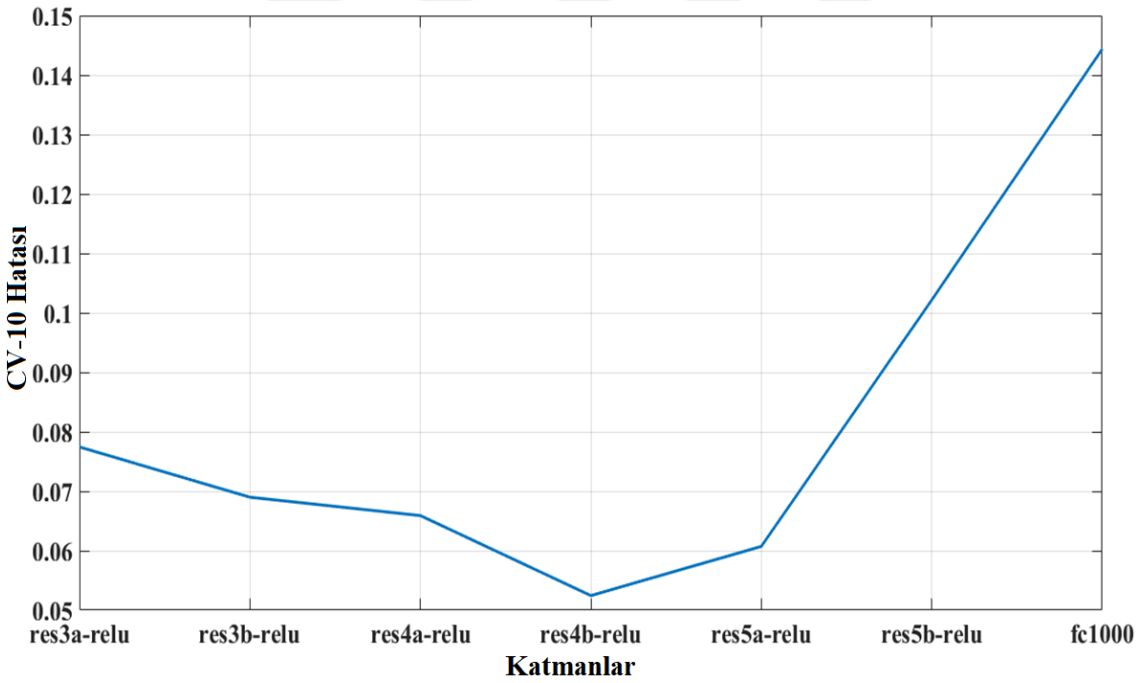

Şekil 3.9. Öznitelik çıkarma katmanına bağlı olarak elde edilen CV-10 hatasının (loss) değişimi (Öksüz ve diğ., 2022)

Son olarak, derin öznitelikler ile ShallowNet öznitelikleri kaynaştırılmaktadır. Böylelikle özel bir R disk boyutu için kaynaştırılan öznitelik kümesi 259 boyutlu olup karşılaştırmalar için $[\text{ResNet18}_{pt}+\text{ShallowNet}]^{R}$ ile ifade edilmektedir. Elde edilen

kaynaşık öznitelik kümesi ile k-NN modeli eğitilmiştir. En iyi performansa R=80 olduğunda ulaşılmaktadır.

Tablo 3.9'da *LGG-1p19qDeletion* veri kümesi üzerinde elde edilen sonuçlar gösterilmektedir. Tablo 3.9'dan görüldüğü gibi, ROI genişlemesiyle öznitelik füzyonu her bir metrik temelinde elde edilen skoru önemli ölçüde artırmaktadır.

Tablo 3.9. *LGG-1p19qDeletion* veri kümesi üzerinde yöntemlerin sınıflandırma performanslarının karşılaştırılması (Öksüz ve diğ., 2022)

Yöntem	PPV (%)	TPR (%)	SPEC (%)	F_1 Score (%)	ACC (%)
$\left[\text{ResNet18}_{pt}\right]^{0}$ +kNN	87,6 ±4,56	87,5 ±4,58	87,5 ±4,58	87,5 ±4,58	87,5 ±4,58
$\left[\text{ResNet18}_{pt}\text{+ShallowNet}\right]^{0}$ +kNN	86,7 ±4,70	91,0 ±3,96	86,0 ±4,80	88,8 ±4,37	88,5 ±4,42
$\left[\text{ResNet18}_{pt}\right]^{80}$ +kNN	96,2 ±2,64	96,0 ±2,71	96,0 ±2,71	96,1 ±2,68	96,0 ±2,71
$\left[\textbf{ResNet18}_{\textbf{pt}}\textbf{+ShallowNet}\right]^{\textbf{80}}$ **+kNN**	**94,3** ±3,21	**100** ±0,00	**94,0** ±3,29	**97,0** ±2,36	**97,0** ±2,36

Tablo 3.10 ile Tablo 3.11'de hataların farklı sınıflara göre nasıl dağıldığını göstermek için bu çalışmada kullanılan veri kümeleri üzerinde elde edilen karışıklık matrisleri verilmektedir. Önerilen yöntemin etkisini karışma matrisi üzerinden göstermek için, değerler ROI genişlemesi olmaksızın çıkartılan derin özniteliklerin kullanıldığı yöntemle karşılaştırmalı olarak verilmektedir. Her bir tabloda eğik çizgiden önce verilen değerler, ROI genişlemesi olmadan elde edilen sonuçları temsil etmektedir. Eğik çizgiden sonra gelen kalın değerler ise önerilen yöntemle elde edilen sonuçları temsil etmektedir. Karışıklık matrislerinin her birinde, ROI genişlemesi ve öznitelik füzyonu, yanlış pozitiflerin (FP'ler) ve yanlış negatiflerin (FN'ler) sayısını önemli ölçüde azalttığı görülmektedir. Böylelikle, toplam yanlış sınıflandırma maliyetinin azaltıldığı söylenebilir. Dahası, bu basit işlem gerçek pozitiflerin (TP'ler) ve gerçek negatiflerin (TN'ler) sayısını artırmaktadır.

Glioma tüm glioma tümörlerinin genel adı olduğundan, beyin tümörü veri kümesi üzerinde eğitilen mimari, $[\text{ResNet18}_{ft}\text{+ShallowNet}]^{56}$+DVM**,** *LGG-1p19qDeletion* veri kümesinin T1C ağırlıklı 478 kesiti üzerinde de test edilmiştir. Sonuç olarak, tüm gliomların %100'ü doğru şekilde sınıflandırılmaktadır.

Tablo 3.10. *Brain tumor* veri kümesi üzerinde önerilen yöntem kullanılarak elde edilen karışma matrisi. Eğik çizgiden sonra gelen ve kalın olarak belirtilen değerler [ResNet18$_{ft}$+ShallowNet]^{56}+DVM mimarisi kullanıldığında elde edilmektedir. Eğik çizgiden önce gelen değerler ise [ResNet18$_{ft}$]^{0}+DVM mimarisi kullanıldığında elde edilmektedir (Öksüz ve diğ., 2022)

N=3064		**TAHMİNLER**		
		G	**M**	**P**
GERÇEKLER	**G**	1333/**1390**	39/**29**	54/**7**
	M	43/**28**	585/**655**	80/**25**
	P	66/**10**	81/**29**	783/**891**

Tablo 3.11. *LGG-1p19qDeletion* veri kümesinde önerilen yöntem kullanılarak elde edilen karışıklık matrisi. Eğik çizgiden sonra gelen ve kalın olarak belirtilen değerler [ResNet18$_{pt}$+ShallowNet]^{80}+kNN mimarisi ile elde edilmektedir. Eğik çizgiden önce gelen değerler ise [ResNet18$_{pt}$]^{0}+kNN mimarisi ile elde edilmektedir (Öksüz ve diğ., 2022)

N=200		**TAHMİNLER**	
		d/d	**n/n**
GERÇEKLER	**d/d**	90/**100**	10/**0**
	n/n	15/**6**	85/**94**

3.3. Tartışma

Çalışmada elde edilen sınıflandırma sonuçları aynı veri kümelerini kullanan literatürdeki diğer araştırmalar ile karşılaştırılmaktadır. Önerilen yöntem ilk olarak Tablo 3.12'de *Brain tumor* veri kümesini kullanan referans çalışmalar ile karşılaştırılmaktadır. El yapımı öznitelikler (M. R. Ismael ve Abdel-Qader, 2018)'de orijinal ROI'den ve (Cheng ve diğ., 2015)'de genişletilmiş ROI'den çıkartılmaktadır. Bu çalışmalarda görevle ilgili çıkartılan özniteliklerin eksikliği, elde edilen performans için üst sınırı belirlemektedir. Öte yandan, uygun bir ESA mimarisi kullanıldığında göreve ilişkin öznitelikler öğrenildiği için performans önemli derecede iyileştirilebilmektedir. (Oksuz ve Gullu, 2020)'de hazır ve ince ayarlı AlexNet ağından çıkartılan derin öznitelikler ile DVM modeli eğitilmektedir. Çalışmada mRMR algoritması tarafından önem skorlarına göre döndürülen ilk 131 öznitelik kullanıldığında %85.53 (Sadece gerçek pozitifler dikkate alınarak verilmiştir.) doğruluk oranı ile veri kümesi üzerindeki en yüksek performansa ulaşılmaktadır. Diğer bir yandan, bu tez çalışması kapsamında uygulanan yöntemlerden biri olan [ResNet18$_{ft}$]^{0}+DVM mimarisi ile elde edilen sonuçlar dahi derin öznitelikler temelli sınıflandırmanın el-yapımı öznitelikler karşısındaki üstünlüğünü göstermektedir. (Abiwinanda ve diğ., 2019)'de MR kesiti, basit bir ESA mimarisinden yararlanılarak

tümör bölütleme yapılmaksızın sınıflandırılmaktadır. Çalışmada umut verici sonuçlar elde edilmekle birlikte ulaşılan performans bazı ayırt edici özniteliklerin çıkartılamaması nedeniyle tasarlanan mimari ile sınırlı kalmaktadır. Benzer şekilde, klasik ESA mimarileri ile yeterli bir şekilde ele alınamayan öteleme ile değişmezlik, rotasyon değişmezliği gibi durumların üstesinden gelebilmek için (P. Afshar ve diğ., 2019)'de özel bir CapsNet mimarisi tasarlanmıştır. Ancak çalışmada da belirtildiği gibi görüntü arka planındaki tüm ilgisiz özniteliklerin CapsNet tarafından dikkate alınması elde edilen performansı sınırlamaktadır. (Sajjad ve diğ., 2019)'de, aşırı veri çoğaltma stratejileri gerçekleştirilerek performans %3.29 oranında artırılmıştır. Bunun yanında, tez çalışması kapsamında uygulanan yöntemlerden [$ResNet18_{ft}$][56]+DVM temelli mimari (geniş alandan çıkartılan derin öznitelikler temelli sınıflandırma) dahi performansı veri çoğaltma stratejilerinden kapsamlı olarak yararlanılmaksızın %5.84 oranında iyileştirebilmektedir. Tablo 3.13'de önerilen yöntem *LGG-1p19qDeletion* veri kümesini kullanan referans çalışmalar ile karşılaştırılmaktadır. 1p/19q kromozomal kollarında eş silinmeye sahip hastalar, silinme olmayan hastalara göre daha uzun genel sağ-kalıma ve daha iyi tedavi yanıtına sahiptir (Voort ve diğ., 2019). Bu nedenle, 1p/19q durumunun tıbbi görüntülerden tahmin edilmesi uygun tedavi planlamasının yapılabilmesi için önem arz etmektedir. (Voort ve diğ., 2019)'da DVM modeli eğitiminde hastanın yaşı ve cinsiyeti ile birlikte görüntü yoğunluğu, tümör dokusu ve tümör konumu gibi el yapımı öznitelikler kullanılmaktadır. (Akkus ve diğ., 2017; Decuyper ve diğ., 2020; Ge ve diğ., 2018; Öksüz ve diğ., 2021a)'deki çalışmalarda 1p/19q eş silinme durumunun tahmin edilebilmesi için derin öğrenme temelli yöntemler önerilmektedir. (Akkus ve diğ., 2017)'da yarı otomatik bir yöntem izlenerek bir yazılım yardımıyla bölütlenen tümör bölgeleri eş silinme durumunu sınıflandırmak için önerilen ESA mimarisine girdi olarak beslenmektedir. Çalışmada %87.78'lik bir doğruluk elde edilmiştir. (Decuyper ve diğ., 2020)'de gliomların bölütlenmesi ve sınıflandırılması için iki aşamalı bir yöntem önerilmektedir. İlk aşamada U-Net modeli ile bölütlenen tümör bölgesi (ROI) ikinci aşamada önerilen sınıflandırıcı yapısına beslenmektedir. Çalışmada ulaşılan doğruluk oranı %83.3'dür. (Ge ve diğ., 2018)'de 1p/19q eş silinme durumunu sınıflandırmak için tüm MR görüntüsünü kullanan bir füzyon ESA modeli önerilmiştir. Çalışmada veri kümesi ile verilen maskelerden yararlanılarak MR görüntüsündeki tümör olmayan alanlar 1/3 oranında bastırılmıştır. (Ge ve diğ., 2018)'deki çalışmada %89.40'lık doğruluğa ulaşılmıştır.

Tablo 3.12. Sınıflandırma sonuçlarının *Brain tumor* veri kümesini kullanan referans çalışmalarla karşılaştırılması

Çalışmalar	**PPV (%)**				**TPR (%)**				**SPEC (%)**				**F_1 Score (%)**	**ACC (%)**
	G	**M**	**P**	**Avg.**	**G**	**M**	**P**	**Avg.**	**G**	**M**	**P**	**Avg.**	**Avg.**	**Avg.**
(Cheng ve diğ., 2015)	-	-	-	-	96,4	86,0	87,3	*89,9*	96,3	95,5	95,3	*95,7*	-	91,28
(M. R. Ismael ve Abdel-Qader, 2018)	-	-	-	-	95,1	86,9	91,2	*91,0*	96,3	96,0	95,7	*96*	-	91,90
(Pashaei ve diğ., 2018)	91,0	94,5	98,3	*94,6*	97,5	76,8	100	*91,4*	-	-	-	-	*93*	93,68
(Abiwinanda ve diğ., 2019)	-	-	-	-	-	-	-	-	-	-	-	-	-	84,19
(P. Afshar ve diğ., 2019)	-	-	-	-	-	-	-	-	-	-	-	-	-	90,89
(Deepak ve Ameer, 2019)	99,2	94,7	98,0	*97,3*	97,9	96,0	98,9	*97,6*	99,4	98,4	99,1	*98,9*	97	97,10
(Sajjad ve diğ., 2019)	-	-	-	-	-	-	-	88,4	-	-	-	96,1	-	94,58
(Swati ve diğ., 2019)	93,2	87,9	87,3	*89,5*	95,9	89,9	96,8	94,2	93,7	96,4	93,9	94,6	91,7	94,82
(Sultan ve diğ., 2019)	97,2	95,8	95,2	*96,06*	94,4	95,5	93,4	94,43	95,1	98,7	97	96,9	-	96,13
(Ghassemi ve diğ., 2020)	-	-	-	*95,29*	-	-	-	94,91	-	-	-	97,6	95,10	95,60
(Oksuz ve Gullu, 2020)	91,8	81,2	79,3	*84,10*	91,6	77,4	82,4	83,79	92,9	94,6	90,6	92,7	83,95	90,35
Önerilen yöntem	97,3 ±0,57	91,9 ±0,96	96,5 ±0,65	*95,25* ±0,75	97,5 ±0,55	92,5 ±0,93	95,8 ±0,71	95,27 ±0,75	97,7 ±0,53	97,5 ±0,55	98,5 ±0,43	97,9 ±0,50	95,26 ±0,75	97,25 ±0,57

(Öksüz ve diğ., 2021a)'de DEG tümörlerde eş silinme durumunun tespiti için öznitelik çıkartıcı ağ olarak kullanılan EfficientNet-B0 modeline kaskat bağlı iki farklı algılama kafasına sahip algılama alt ağından oluşan bir nesne algılayıcı model önerilmektedir. Böylelikle önerilen tek aşamalı nesne algılayıcı model ile MR görüntüsünde gliomalar bulunup aynı zamanda eş silinme durumu tahmin edilmektedir. (Öksüz ve diğ., 2021a)'deki çalışmada önerilen 14,5M parametreli bu yapı ile eş silinme durumunun tespitinde %90.2'lik bir duyarlılık oranına ulaşılmaktadır. Tablo 3.12 ve Tablo 3.13'den görüldüğü gibi, derin radyomikler (öznitelik) temelli sınıflandırma, geleneksel el yapımı radyomikler temelli sınıflandırma karşısında daha yüksek bir performans sağlamaktadır. (Swati ve diğ., 2019; Sultan ve diğ., 2019; Ghassemi ve diğ., 2020; Deepak ve Ameer, 2019), (Ge ve diğ., 2018)'deki çalışmalarda tüm MR kesitinin sınıflandırmada kullanıldığı yöntemler önerilmektedir. Bu çalışmalarda MR diliminin tamamını kullanmak sınıflandırma görevi için ilişkisiz öznitelikleri hesaba katmaktadır. Ayrıca, MR görüntüsü birçok türde tümör içeriyorsa, tüm MR görüntüsüne dayalı olarak tümör sınıflandırma yaklaşımını benimsemek yanıltıcı sonuçlara sebep olabilecektir. Bu nedenle, bölütleme ve sınıflandırmayı birleştiren tam otomatik veya yarı otomatik bir sistem geliştirmeye büyük ölçüde ihtiyaç bulunmaktadır. Tez çalışmasının bu bölümünde önerilen yöntem yalnızca tümör bölgelerini girdi olarak almayı gerektirerek DEG tümörlerde 1p/19q eş silinme durumunun yanı sıra gliom, menenjiom ve hipofiz tümörlerinin sınıflandırılmasında yarı otomatik, basit ve etkili bir sınıflandırma çatısı sunmaktadır.

Tablo 3.13. Sınıflandırma sonuçlarının *LGG-1p19qDeletion* veri kümesini kullanan referans çalışmalarla karşılaştırılması

Çalışma	**PPV (%)**	**TPR (%)**	**SPEC (%)**	**F_1 Score (%)**	**ACC (%)**
(Voort ve diğ.,2019)	78,7	73,2	61,7	69,7	69,3
(Decuyper ve diğ., 2020)	-	86,7	79,2	-	83,3
(Akkus ve diğ., 2017)	84,0	93,3	82,2	88,4	87,7
(Ge ve diğ., 2018)	-	-	-	-	89,39
(Öksüz ve diğ., 2021a)	87,6	88,1	88,1	87,85	88,70
Önerilen yöntem	94,3 ±3,21	100 ±0,00	94,0 ±3,29	97,06 ±2,34	97,0 ±2,36

3.4. Görselleştirme

Bu bölüm, önerilen yöntem ile elde edilen sonuçların görselleştirilmesine ayrılmaktadır. Önerilen yöntemin etkisini göstermek için bu bölümde ilk olarak öznitelik uzayındaki 2B saçılım grafikleri incelenmektedir. Bu amaçla, yüksek boyutlu verileri görselleştirmek için t-SNE (Maaten ve Hinton, 2008) algoritmasından yararlanılmaktadır. İlk olarak, ROI genişletme ve öznitelik füzyonu olmadan çıkarılan derin öznitelik kümesi $[\text{ResNet18}_{\text{ft}}]^0$, Şekil 3.10(a)'da verilmektedir. ROI genişletmesi olmadan elde edilen kaynaşmış öznitelik kümesi, $[\text{ResNet18}_{\text{ft}}+\text{ShallowNet}]^0$, Şekil 3.10(b)'de verilmektedir. Daha sonra, ROI genişletme ile çıkarılan derin öznitelik kümesi olan $[\text{ResNet18}_{\text{ft}}]^{56}$, Şekil 3.10(c)'de verilmektedir. Son olarak, ROI genişletme (önerilen yöntem) ile kaynaşmış öznitelik seti, $[\text{ResNet18}_{\text{ft}}+\text{ShallowNet}]^{56}$, Şekil 3.10(d)'de verilmektedir. Şekil 3.10(c)'deki saçılım çizimi, öznitelik füzyonu olmadan ROI genişlemesinin ayrılabilirliğe bir miktar katkıda bulunduğunu göstermektedir. Özellikle hipofiz tümör sınıfındaki örnekler daha kompakt bir görünüm kazanmaktadır. Şekil 3.10(d)'deki saçılım çizimi, ROI genişlemesi ile öznitelik füzyonunun sınıfları neredeyse tamamen ayrılabilir hale getirdiğini ortaya koymaktadır. Bu durum önerilen yöntemin sınıf içi değişintiyi azaltarak ilgili sınıflardaki örnekleri birbirine yaklaştırdığını, öte yandan yöntemin sınıflar arası değişintiyi ise arttırarak farklı sınıfların örneklerini birbirinden uzaklaştırdığını göstermektedir. Böylelikle sınıflar doğrusal ayrılabilir hale gelmektedir.

Şekil 3.11'de Grad-CAM görsellerine yer verilmektedir. Böylelikle, ROI'ye tümör çevre dokuları dâhil edilerek eğitilen ağ tarafından yapılan tahminler, orijinal ROI'ler kullanılarak eğitilen ağ tarafından yapılan tahminler ile GradCAM görselleri üzerinden karşılaştırılmaktadır. Şekil 3.11'de alt satırda verilen görüntüler üst satırda verilen orijinal tümör bölgelerine çevre dokuların R=56 olduğunda dâhil edildiği duruma aittir. Ayrıca her bir satırdaki ilgili tümör görüntüsünün ardından karşılık gelen ağlar tarafından döndürülen GradCAM görselleri verilmektedir. Her ne kadar uzman yorumu olmadan GradCAM görsellerini değerlendirmek zor olsa da tümör çevre dokuları dâhil edilerek eğitilen ağ tarafından döndürülen görsellerde tümör bölgesine ek olarak çevredeki ödem benzeri alanlarda da sıcak bölgeler döndürüldüğü görülmektedir. Bu durum tümörlere ilişkin çevre dokulardaki bu gibi anormalliklerin ağ tarafından öğrenildiğini ortaya

koymaktadır. Bunun karşısında orijinal tümör bölgeleri ile eğitilen ağ ise tümör bölgesi içerisindeki bazı özel alanlarda sıcak bölgeler döndürmektedir.

3.5. Değerlendirme

Tez çalışmasının bu bölümünde tümör sınıflandırma problemine odaklanılmıştır. Çalışma kapsamında orijinal tümör bölgesinden derin özellikler çıkarmak yerine, genişletilmiş tümör bölgesinden çıkartılan derin ve sığ özniteliklerin füzyonunu kullanan bir sınıflandırma çatısı tanıtılmaktadır. Tasarlanan sınıflandırma çatısı, açık erişimli Brain tumor ve LGG-1p19qDeletion veri kümeleri üzerinde test edilmiştir. Bu çalışmada elde edilen bulgular, çevre dokuların dâhil olduğu ROI'den çıkartılan öznitelikler temelli sınıflandırmanın aynı miktarda veri ile orijinal tümör bölgelerinden çıkartılan öznitelikler temelli sınıflandırmadan önemli derecede yüksek performans verdiğini ortaya koymaktadır. Bununla birlikte ağların derinliği sebebiyle kaybedilebilen düşük seviyeli bilgiyi telafi edebilmek için çıkartılan sığ özniteliklerin derin öznitelikler ile kaynaştırılmasının performansta iyileşme sağladığı gösterilmektedir. Kaynaştırma işlemi ince taneli ve kaba taneli özniteliklerin birleşmesini sağlamaktadır. Deneysel sonuçlarda sunulduğu gibi ROI genişletme ve öznitelik kaynaştırma birlikte uygulandığında sınıflar doğrusal ayrılabilir hale gelmektedir. Önerilen yöntem, manuel bölütleme veya otomatik bölütleme temelli tekniklerle birleştirilerek tam otomatik bir sistem elde edilebilir. Önerilen yöntem, farklı çok sınıflı tümör sınıflandırma görevlerine kolaylıkla genellenebilir. Tümör sınıflandırma görevleri için uygun veri çoğaltma stratejilerini belirleyerek sınıflandırma performansını bir miktar daha iyileştirmek mümkündür. Ayrıca, bu çalışmada kullanılan veri kümelerindeki sınıf dengesizliğini gidermek için bir ÇÜA (Çekişmeli Üretken Ağ) yapısından yararlanılabilir. Gelecek çalışmalarda bu konular üzerinde durulması hedeflenmektedir.

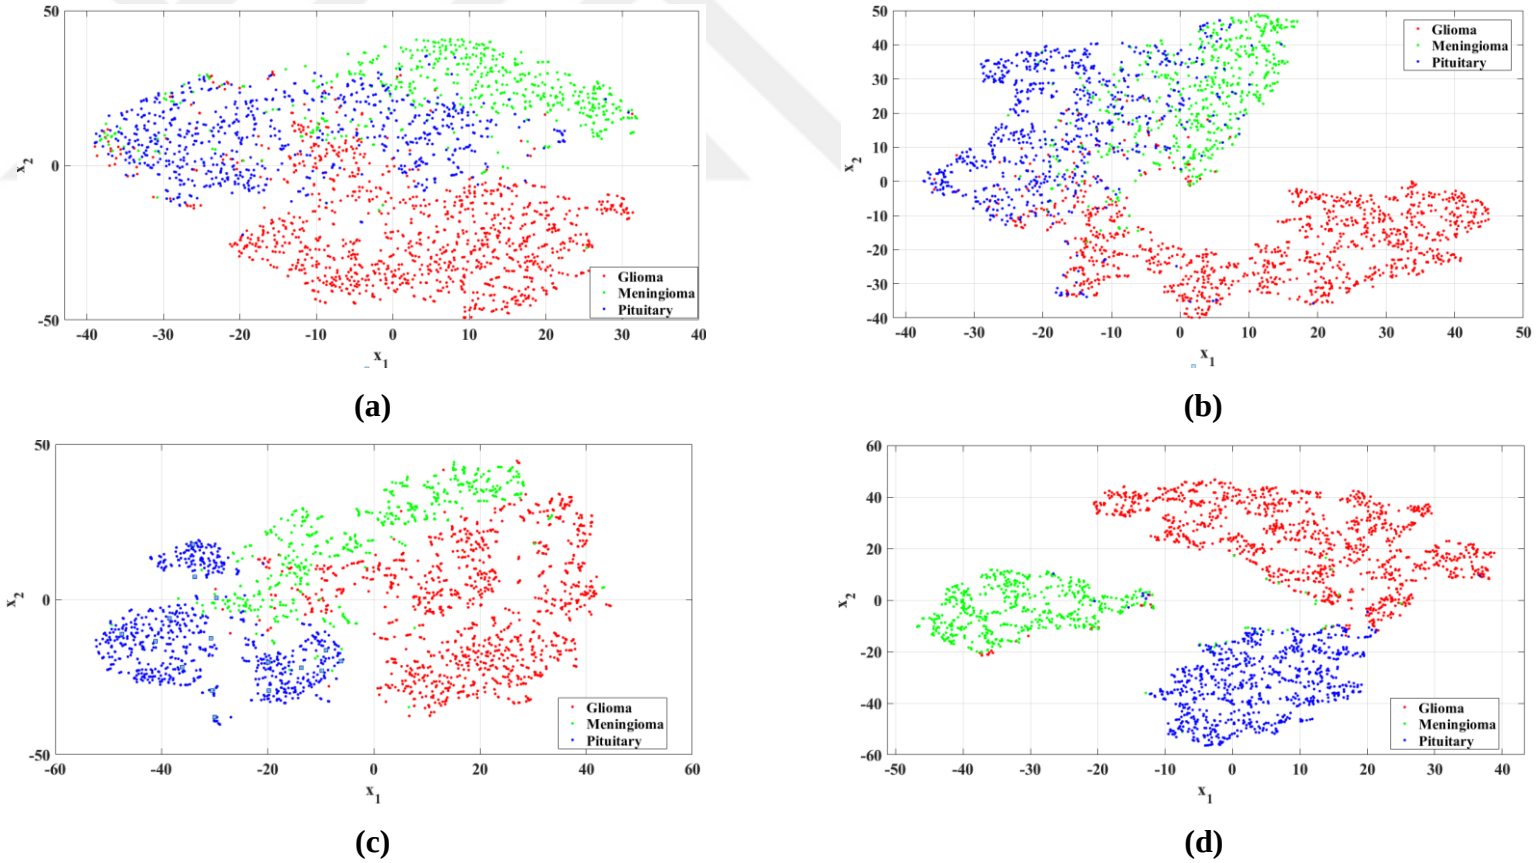

Şekil 3.10. Çıkartılan öznitelik setlerine ait 2B saçılım çizimleri. (a) $[ResNet18_{ft}]^{0}$ öznitelik setine ait saçılım çizimi, (b) $[ResNet18_{ft}+ShallowNet]^{0}$ öznitelik setine ait saçılım çizimi, (c) $[ResNet18_{ft}]^{56}$ öznitelik setine ait saçılım çizimi, (d) $[ResNet18_{ft}+ShallowNet]^{56}$ öznitelik setine ait saçılım çizimi

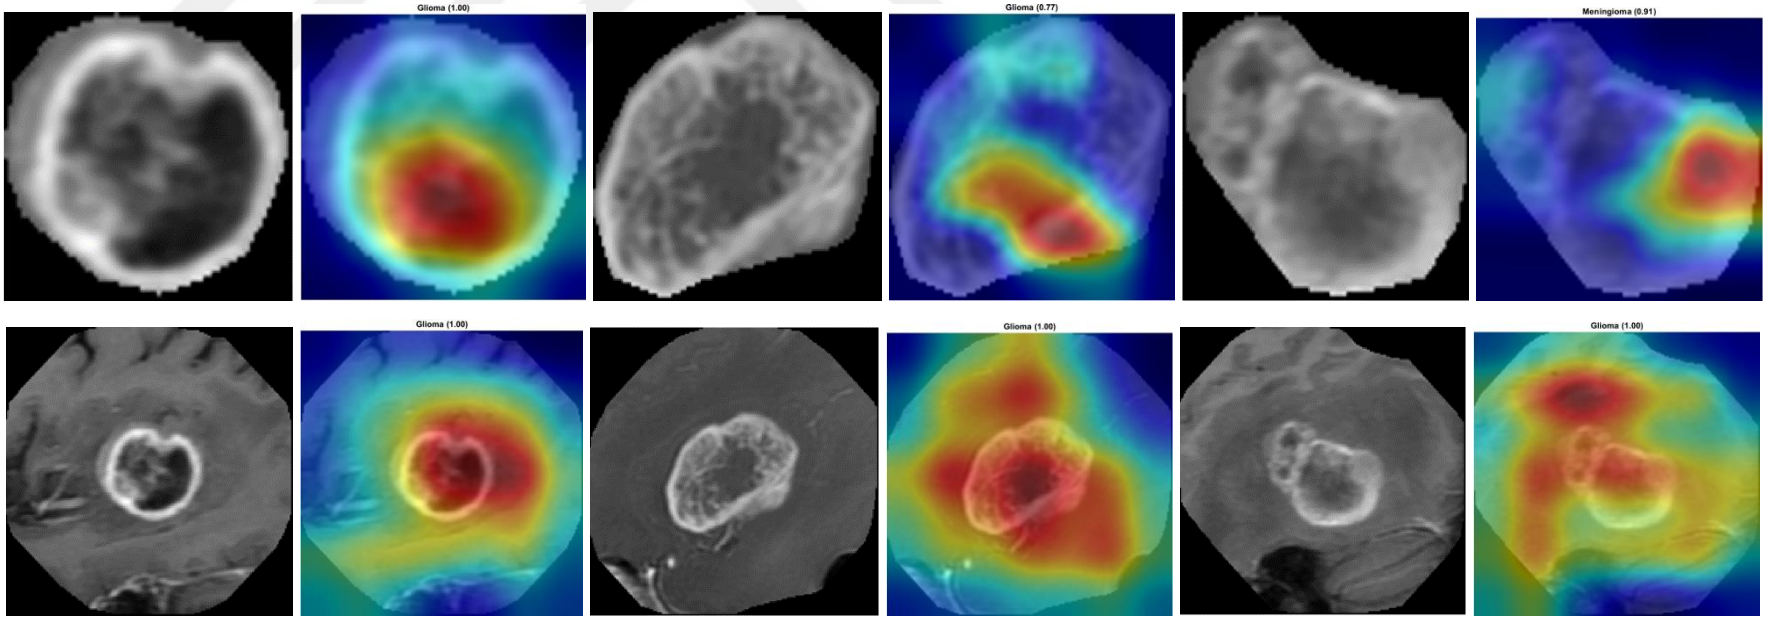

Şekil 3.11. GradCAM görselleri. Üst satırdaki görsellerde orijinal tümör bölgeleri ve karşılık gelen GradCAM görselleri verilmektedir. Alt satırdaki görüntülerde ise üst satırlarındaki orijinal tümör bölgelerine çevre dokularının dâhil edildiği genişletilmiş ROI'ler ve karşılık gelen GradCAM görselleri verilmektedir

4. AKCİĞER GRAFİLERİNDEN ÖZNİTELİK ÇIKARTMA VE SINIFLANDIRMA: COVID-19 HASTALIĞI TESPİTİ

Yeni tip koronavirüs olarak tanımlanan SARS-COV-2 yüksek derecede bulaşıcılığa sahip olarak her geçen gün artan vaka ve ölümlerle tüm dünyayı tehdit etmektedir. Virüs, sosyal yaşamlar ve küresel ekonomi üzerindeki birçok yıkıcı etki bırakmıştır. SARS-COV-2 virüsünün neden olduğu COVID-19 hastalığı, ateş, kuru öksürük, eklem ve kas ağrıları gibi grip benzeri belirtiler göstermektedir. Virüsle mücadele için geliştirilmiş ve geliştirilmekte olan aşılar olmasına rağmen, aşının özellikle kırsal kesimlerdeki insanlara ulaşması zaman almaktadır. Öte yandan, virüs çeşitli mutasyonlardan geçtiği için (Wise 2021), her zamankinden çok daha bulaşıcı hale gelmiştir ve geliştirilen aşıları tehdit etmektedir. Bu nedenle, virüsün küresel çapta yayılımını kontrol etmek için hastaları tespit etmek ve izole etmek büyük önem arz etmektedir. Mevcut klinik rutinde, RT-PCR testi, DSÖ tarafından COVID-19 hastalarını tanımlamak için ana tarama aracı (altın standart) olarak kabul edilmektedir (C. Li ve diğ., 2020). Ancak RT-PCR testinin bazı önemli olumsuzlukları şu şekilde verilmektedir:

(1) Laboratuvarla ilgili hatalar, örnekteki viral materyalin yetersizliği, kontaminasyon ve diğer teknik sorunlar RT-PCR testinin duyarlılığını azaltmaktadır (Yang ve diğ., 2020; Ji ve diğ., 2020; Y. Li ve diğ., 2020). (Xue ve Jin, 2020)'de yanlış negatif tespit oranın %30-50 arasında olduğu belirtilmektedir.

(2) Test tekrarı gerektirebilmektedir. (Williams ve diğ., 2020)'de, RT-PCR testi duyarlılığını belirlemek için hastanede yatan COVID-19 hastalarından alınan üst solunum yolu örnekleri için RT-PCR testi yapılmıştır. Tek bir RT-PCR testinin duyarlılığının %82.2 olduğu, test tekrarlandığında ise duyarlılığın %90.6'ya çıktığı belirlenmiştir.

(3) Hastanın burun ve boğaz süprüntülerinin alınması için bir hekimin müdahalesini gerektirdiğinden invasiftir. Diğer bir yandan uzman ekipman ve uzman sağlık personeli eksikliği nedeniyle özellikle nüfusun az olduğu yerlerde hastalardan alınan örnekler şehir merkezlerindeki laboratuvarlara gönderilmektedir.

(4) İkinci ve üçüncü maddelere bağlı olarak, zaman alıcıdır, pahalı donanım ve biyogüvenlik koşulları gerektirir. Bu nedenle, POC (bakım noktası) için uygun bir test olmadığı söylenebilir (C. Li ve diğ., 2020).

SARS-COV-2'nin yayılmasını engellemek için hastalığın erken dönemde tespit edilmesi bir gereklilik olmuştur. RT-PCR testinin yukarıda söz edilen olumsuzlukları, uzmanları alternatif çözümler aramaya sevk etmiştir. Sonuç olarak Akciğer Grafisi (X-ışını) ve Bilgisayarlı Tomografi (BT) gibi görüntüleme teknikleri ile elde edilen radyolojik görüntülerin hastalığın tespitinde önemli ipuçları taşıdığı belirlenmiştir. Dahası, BT görüntülemenin hastalığın erken aşamada tespitinde yüksek bir duyarlılığa sahip olduğu ortaya çıkmıştır (Yang ve diğ., 2020). (Long ve diğ., 2020)'da COVID-19 olduğu kesinleşmiş olan 36 hasta üzerinde yapılan retrospektif bir çalışmada, hastalığın saptanmasında RT-PCR test duyarlılığı ve BT görüntüleme ile tespit duyarlılıkları karşılaştırılmıştır. Buna göre, hastalığın erken evresinde 36 hastadan 35'inin BT görüntülerinde anormal bulgular mevcutken, sadece 30 hastaya ait RT-PCR testinin pozitif sonuçlandığı görülmüştür. Kalan 6 hastanın her biri için RT-PCR testi sırasıyla 2, 2, 3, 5, 6 ve 8 gün sonra pozitif sonuç vermiştir. BT ile hastalığın erken dönemde tespit duyarlılığı yüksek olmasına rağmen, erken dönemlerinde X-ışını görüntülerinden çıplak gözle COVID-19 tespit etme duyarlılığının düşük olduğu belirtilmektedir (Yang ve diğ., 2020). Hastalık ilerledikçe, akciğer grafisindeki birçok bölgede opaklığa sahip olan alanlar belirgin hale gelmektedir. Bu opak alanlar, hastalığın ilerleyen aşamalarında beyazlamış bir akciğer görüntüsüne dönüşmektedir. (Hui ve diğ., 2020)'da, X-ışını görüntülemenin klinik yararlılığı incelenmiştir. Araştırmada belirtilerin ortaya çıkmaya başladığı güne göre ilk altı ile ilk on gün arasında uygulanan X-ışını görüntülemenin hastalığın şiddetini belirleyen bir faktör olduğu belirlenmiştir. Bununla birlikte, hastalığın ilk altı ile ilk on günü arasındaki X-ışını görüntülemesine ait bulgular karşılaştırıldığında (belirtilerin başlangıcına dayalı olarak), ilk on gün arasında yapılan görüntülemenin hastalığı öngörmede daha fazla öneme sahip olduğu sonucuna varılmıştır.

COVID-19 tespitinde OT sistemlerinin geliştirilmesi bilhassa uzman bir hekimin bulunmadığı nüfusun az olduğu yerlerde de faydalı bir araç olabilmektedir. Hastalığın başladığı ve bir salgına dönüştüğü zamandan beri, araştırmacılar tarafından COVID-19'u

tespit etmek için çok çaba sarf edilmiştir. Literatürde COVID-19 tespiti için önerilen OT sistemlerini aşağıdaki gibi kategorilere ayırmak mümkündür:

- Sadece klinik özellikleri kullanan sistemler,
- BT görüntüleme özniteliklerini kullanan sistemler,
- Klinik öznitelikleri BT görüntüleme öznitelikleriyle birleştiren sistemler,
- X-ışını görüntüleme özniteliklerini kullanan sistemler,

Verilen kategoriler göz önüne alındığında, bazı çalışmalarda makine öğrenimi temelli yöntemler önerilirken, diğerleri COVID-19 hastalığını tespit etmek için derin öğrenme temelli yöntemler önerilmektedir. (Y. Gao ve diğ., 2020)'de, COVID-19 hastalığı olan hastaların ölüm riskini tahmin etmek için makine öğrenimi temelli bir çözüm önerilmiştir. Elektronik sağlık kayıtlarından elde edilen 53 ham özelliğin 34'ü LASSO yöntemi kullanılarak 14'e indirilmiştir. Son olarak, hayatta kalmayanların tespiti için oluşturulan bir topluluk modeliyle harici geçerleme kümesi üzerinde %95.5'lik bir doğruluğa ulaşılmıştır.

BT görüntülerinin hastalığın erken evrelerinde önemli imzalara sahip olması, birçok araştırmacının BT görüntüleme özniteliklerini kullanarak BDT sistemleri önermesinin ardındaki temel motivasyon kaynağı olmuştur. (K. Zhang ve diğ., 2020)'de, BT görüntüleme özniteliklerinin kullanıldığı derin öğrenme temelli bir yöntem önerilmiştir. BT görüntüsündeki akciğer bölgeleri ilk olarak bir bölütleme ağı ile bölütlenmektedir. Ardından bölütlenen bölge COVID-19 pnömonisi, sağlıklı ve diğer pnömoni türleri arasında ayrım yapmak için sınıflandırma ağına beslenmektedir. Çalışmada, C-reaktif protein (CRP), yaş, serum laktik dehidrojenaz (LDH), en yüksek vücut ısısı ve nötrofil-lenfosit oranı gibi klinik özniteliklerin bölütlenen lezyon öznitelikleriyle yüksek ilişkili olduğu ortaya koyulmaktadır. (Ning ve diğ., 2020)'te, klinik özniteliklerin BT öznitelikleriyle birleştirildiği HUST-19 adında bir karma çerçeve önerilmiştir. Bir DNN (Derin Sinir Ağı) tarafından tahmin edilen klinik öznitelikleri ve (Ning ve diğ., 2020)'te BT görüntülerini kullanan bir ESA tarafından tahmin edilen hasta düzeyindeki klinik sonuçları entegre etmek için lojistik regresyon algoritması kullanılmıştır. Çalışmada negatif, hafif ve ağır vakaları ayırt etmek için elde edilen performans sırasıyla 0.944, 0.860 ve 0.884'tür.

Klinik özniteliklerin tasarlanan sınıflandırma çatılarına entegrasyonu tamamlayıcı bir çözüm sağlasa da hangi klinik özniteliklerin performansı iyileştirdiğini bulmak zor ve zaman alıcıdır. COVID-19 ile mücadelede, hastalığın doğrudan görüntüleme özniteliklerinden hızlı ve etkili tespiti daha kullanışlı bir çözüm sunmaktadır. X-ışını görüntülemenin birçok sağlık kuruluşunda bulunan kolay erişilebilir bir teknik olması, bazı araştırmacıları X-ışını görüntüleme özniteliklerini kullanarak yöntemler geliştirmeye yöneltmiştir. Erken evrelerde bir uzman tarafından akciğer grafisinden hastalığı görmek zor olsa dahi, bilgisayarla görü yöntemleri verilerdeki gizli kalıpları öğrenme yeteneğine sahiptir. (A. M. Ismael ve Şengür, 2021)'te, X-ışını görüntüleme özniteliklerini kullanarak COVID-19 hastalığını saptamak için çeşitli yöntemler kullanılmaktadır. Önceden eğitilmiş ImageNet (Russakovsky ve diğ., 2015a) modelleriyle çıkarılan öznitelikler ile DVM sınıflandırması, hazır modellerin ince ayarı, yeni bir derin öğrenme modeli tasarlama bu çalışmada kullanılan tekniklerdir (A. M. Ismael ve Şengür, 2021). (Nour ve diğ., 2020)'da, X-ışını görüntüleme özniteliklerini kullanarak hastalığı tahmin etmek için aktarım öğrenmesi yerine beş katmanlı bir evrişimli ağ önerilmiştir. Eğitimin ardından ağ öznitelik çıkartıcı olarak kullanılmaktadır. Ardından çıkartılan öznitelikler ile k-NN, DVM ve karar ağaçları gibi klasik makine öğrenimi modelleri eğitilmektedir. Bu çalışmada, DVM modeli ile %98.98 doğruluk elde edilmiştir. (Ozturk ve diğ., 2020)'de, YOLO nesne algılayıcı modelinin omurgası olan DarkNet-19 modelinden ilham alınmıştır. Tasarlanan X-ışını temelli model DarkCovidNet olarak adlandırılmıştır. DarkCovidNet tarafından sırasıyla çok sınıflı ve ikili sınıflandırma görevleri için %87.02 ve %98.08 doğruluk elde edilmektedir. (Minaee ve diğ., 2020)'de, ResNet-18, ResNet-50, SqueezeNet ve DenseNet-121 modelleri transfer öğrenme yaklaşımı ile kullanılmıştır. Her bir model ile elde edilen duyarlılık ve özgüllük puanlarının sırasıyla %98 ve % 90 civarında olduğu belirtilmektedir. (Karthik ve diğ., 2020)'da, COVID-19 ile ilgili gizli öznitelikleri öğrenmek için 15M parametreli özel bir ESA mimarisi önerilmiştir. Bu çalışmada ulaşılan doğruluk %97.94'tür. (Farooq ve Hafeez, 2020)'de, hazır ResNet-50 modeli, sırasıyla 128×128×3, 224×224×3 ve 299×299×3 uzamsal çözünürlüklerde görüntüler kullanılarak üç aşamada ince ayarlı yapılmaktadır. Önerilen yöntem COVID-ResNet olarak adlandırılmıştır. Çalışmada 25,6M parametreli COVID-ResNet yöntemi ile elde edilen doğruluk %96.23'tür. (Wang ve Wong, 2020)'de 11,75M parametreli özel bir derin öğrenme modeli olan COVID-Net, COVID-19 tespiti için önerilmiştir. Önerilen

model ile %93.3 doğruluk elde edilmiştir. (Mangal et al. 2020)'de, COVID-19 tespiti için önerilen COVID-AI algılayıcısı modeli ile elde edilen doğruluk %90.5'tir. (Abbas ve diğ., 2020)'te DeTraC (Ayrıştır, Aktar ve Oluştur) olarak adlandırılan başka bir derin öğrenmeye dayalı yaklaşım önerilmektedir. Çalışmada önerilen DeTraC modeli hazır ResNet-18 modeliyle kullanıldığında %95.12 ile en yüksek doğruluk oranına ulaşılmaktadır. (Brunese ve diğ., 2020)'te COVID-19 hastalığını tespit etmek için üç aşamadan oluşan derin öğrenme temelli bir yöntem önerilmiştir. İlk aşamada X-ışını görüntüsünün normal ya da anormal bir vaka olduğu belirlenirken, ikinci aşamada COVID-19 hastalığının diğer anormal vakalardan ayırt edilmesi amaçlanmıştır. Üçüncü aşamada akciğer görüntüsündeki şüpheli alanların görselleştirilmesi amaçlanmıştır. (Brunese ve diğ., 2020)'teki çalışmada VGG-16 modeli kullanılarak %97'lik bir doğruluk oranına ulaşılmıştır. COVID-19 tespitinden %96.69 doğruluğun elde edildiği (Ouchicha ve diğ., 2020)'teki çalışmada yerel ve bütünsel öznitelikleri tespit etmek için bir artık ağ (ResNet) mimarisi önerilmiştir.

Doğru teşhis, insanların gereksiz yere test edilmesini, gereksiz yere ilaç yüklenmesini, gereksiz yere izole edilmesini önleyerek ve doğru tedaviyi hızla almasını sağlayarak COVID-19'un yayılma riskini azaltabilmektedir. Bu bireyler için son derece önemlidir ve zamandan ve kaynaktan tasarruf sağlamaktadır. Tez çalışmasının bu bölümünde COVID-19 vakalarını tespit etmenin yanı sıra hafif ve şiddetli vakaları belirlemek için tüm sağlık kuruluşlarında uygulanabilecek duyarlılığı yüksek, derin öğrenme temelli bir hızlı tarama yöntemi önermek amaçlanmaktadır. BT görüntüleme hasta başına 15 dakikadan (Tabik ve diğ., 2020) fazla sürerken, X-ışını görüntüleme sadece 15 saniye (Wong ve diğ., 2020) gerektirmektedir. Ayrıca, (Mettler ve diğ., 2008)'de verildiği gibi hastaya uygulanan daha düşük etkili radyasyon dozları nedeniyle X-ışını görüntüleme BT görüntüleme karşısında hasta dostudur. BT görüntülemede hastanın iyileşme sürecinin değerlendirilmesi sırasında görüntülemeyi tekrar etme ihtiyacı, hastanın fazladan radyasyona maruz kalması anlamına gelmektedir. Bu amaçla kolay, hızlı, ucuz, yaygın olarak kullanılan bir teknik olması ve hemen hemen tüm sağlık tesislerinde mevcut olması nedeniyle X-ışını görüntülemeye dayalı bir yöntemin geliştirilmesi amaçlanmaktadır.

Çalışma kapsamında aynı zamanda düşük kompleksiteye sahip bir model elde edebilmek amaçlanmıştır. Bu bağlamda her biri farklı derinliklere sahip olan hafif ağırlıklı

SqueezeNet (Iandola ve diğ., 2016), ShuffleNet (X. Zhang ve diğ., 2017), MobileNet-v2 (Sandler ve diğ., 2019) ve EfficientNet-B0 (M. Tan ve Le, 2020) modellerinden yararlanılmaktadır. Her bir ağın farklı derinliğe sahip olması farklı soyut seviyelerde haritaların üretilmesini sağlamaktadır. Böylelikle, derin bir model tarafından üretilen öznitelik haritaları, sığ bir modelin ürettiği haritalardan daha soyut haritalar olmaktadır. Derin bir modelin ürettiği soyut bilgi sınıflandırma performansında ayırt edici olsa da, modelin derinliğine bağlı olarak kaybedilebilen anlamsal bilginin eksikliği performansı düşürebilir. Bu nedenle, derin model tarafından üretilen öznitelik haritalarının daha sığ modellerin öznitelik haritaları ile birleştirilerek sağlamlaştırıldığı derin öğrenme temelli bir topluluk ağı modeli önerilmektedir. İnce taneli haritalar oluşturmak için SqueezeNet, kaba taneli haritalar oluşturmak için ShuffleNet ve daha kaba taneli haritalar oluşturmak için EfficientNet-B0 modellerinden yararlanılmaktadır. Böylelikle ince taneli ve kaba taneli öznitelikleri birleştirmek ve tek başına kullanılan derin modelde bilgi kaybını telafi etmek mümkün olmaktadır. Özetle, tez çalışmasının bu bölümünün ana katkıları şunlardır:

- Derin ağda kaybolabilecek anlamsal bilgi kaybının telafi edilmesi motivasyonu ile öznitelik çıkartıcı olarak derin ağdan daha sığ ağlar tümleştirilmektedir. Elde edilen yapının farklı derinlikteki kodlayıcı ağlarını bir araya getirmesi sebebiyle *topluluk kodlayıcı* olarak adlandırılmaktadır.

- X-ışını görüntülerinden COVID-19 hastalığının tespitinin yanı sıra hafif ve şiddetli vakaların ayırt edilebilmesi için hafif ve uçtan uca eğitilebilir derin öğrenme temelli bir topluluk modeli önerilmektedir.

- Tasarlanan 5,62M parametreli hafif topluluk modeli ile bir X-ışını görüntüsünü işlemek yalnızca 10ms sürmektedir. Bu nedenle hızlı bir tarama aracı olarak kullanılabilir.

Tez çalışmasının bu bölümü aşağıdaki şekilde organize edilmektedir. Bölüm 4.1'de öznitelik çıkartma, öznitelik haritası kaynaştırma ve sınıflandırmayı içeren önerilen sınıflandırma çerçevesi tanıtılmaktadır. Bölüm 4.2'de deneysel sonuçlar sunulmaktadır. Bölüm 4.3 ve Bölüm 4.4, sırasıyla görselleştirme ve tartışmaya ayrılmıştır. Son olarak, Bölüm 4.5'de değerlendirmeler sunulmaktadır.

4.1. Önerilen Yöntem

Önerilen sınıflandırma çerçevesi Şekil 4.1'de gösterilmektedir. Önerilen çerçeve, öznitelik çıkartma katmanlarından ve bunların üstündeki bazı ek katmanlardan oluşmaktadır. Şekil 4.1'den görüldüğü gibi, üç hafif ImageNet (Russakovsky ve diğ., 2015a) modeli, yani SqueezeNet (Iandola et al. 2016), ShuffleNet (X. Zhang ve diğ., 2017) ve EfficientNet-B0 (M. Tan ve Le, 2020), ince ayardan sonra paralel olarak öznitelik çıkarıcılar olarak kullanılmaktadır.

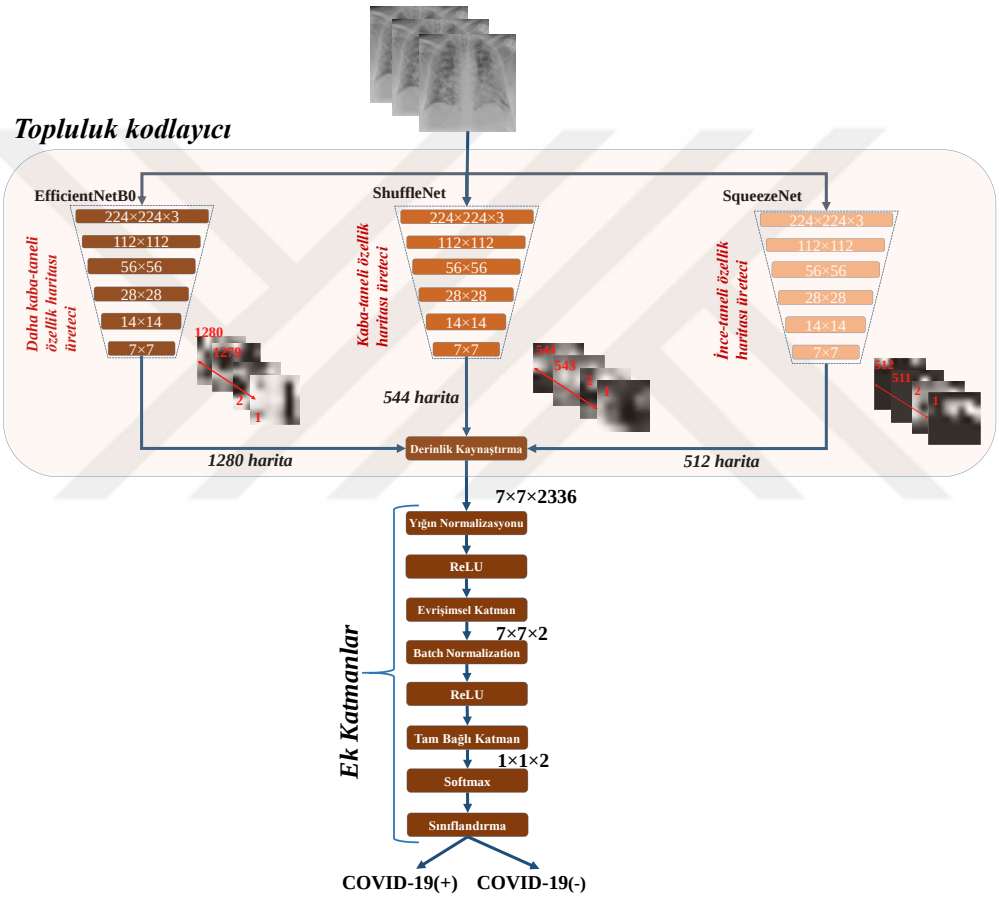

Şekil 4.1. Önerilen hafif ağırlıklı topluluk ağı modeli

Farklı derinliklerdeki ağlar, farklı soyutlama seviyelerinde aktivasyon haritaları oluşturur. Bu amaçla, 22-katman derinliğine sahip SqueezeNet, ince taneli soyut öznitelik haritası üretimi için kullanılır. Diğer modeller, yani 50 katman derinliğine sahip ShuffleNet ve 82 katman derinliğine sahip EfficientNet-B0, sırasıyla kaba taneli ve daha kaba taneli soyut öznitelik haritaları oluşturmak için kullanılır. Her modelden elde edilen aktivasyon haritaları, derinlik birleştirme katmanına beslenir ve daha sonra havuzlama işlemleri

nedeniyle önceki katmanlarla birlikte uzaysal boyut küçültmesinden kaynaklanan bilgi kaybını telafi etmek için birleştirilir. Kanal birleştirmeden sonra, önemli öznitelikleri öğrenmek için birleştirilen kanallar ek katmanlara beslenir.

4.1.1. Topluluk kodlayıcı

Uçtan uca tasarlanan derin öğrenme modelleri, belirli bir amaç işlevini en üst düzeye çıkarmak için eğitilmektedir. Böylelikle, modellerin eldeki görev için sınıflandırma performansını en üst düzeye çıkaran öznitelikleri öğrenmesi sağlanmaktadır. Bununla birlikte, derin öğrenmede bu tür yararlı özniteliklerin öğrenilmesi gerekli verinin medikal alanda yetersizliği ESA yapısının sıfırdan eğitilmesini zorlaştırmaktadır. Neyse ki, milyonlarca veri ile eğitilmiş modeller tarafından öğrenilen öznitelikler, transfer öğrenme sayesinde yeni bir sınıflandırma görevine aktarılabilmektedir (C. Tan ve diğ., 2018). Aktarım öğreniminin bir yolu, önceden eğitilmiş bir ağı ince ayar yapmadan doğrudan öznitelik çıkartıcı olarak kullanmaktır. Diğer yol, önceden eğitilmiş bir ağa ince ayar yapılmasıdır. (Oksuz ve Gullu, 2020)'de, ince ayardan sonra çıkarılan özniteliklerle sınıflandırmanın, görevle ilgili özniteliklerin öğrenilmesi nedeniyle daha iyi genelleme yeteneği sağladığı gösterilmiştir. Bahsetmeye değer bir diğer nokta da ağ derinleştikçe özniteliklerin farklı soyut seviyelerde çıkarılmasıdır. Ağın derinleştirilmesiyle elde edilen derin öznitelikler sınıflandırmada son derece önemli olsa da ağ derinliğine bağlı olarak bazı yararlı bilgiler kaybolabilmektedir.

Bu bağlamda, bilgi kaybını telafi edebilmek için SqueezeNet (Iandola ve diğ., 2016), ShuffleNet (X. Zhang ve diğ., 2017) ve EfficientNet-B0 (M. Tan ve Le, 2020) gibi farklı derinliklere sahip üç hafif önceden eğitilmiş modelden yararlanılmaktadır. Bu ağları paralel olarak birleştirerek, bütünleşik bir öznitelik haritası oluşturucu ağı (topluluk kodlayıcı) elde edilmektedir. Alt bölümlerde, topluluk kodlayıcı ağın nasıl elde edildiği açıklamaktadır.

Öznitelik Haritası Üreteci Olarak ShuffleNet Modeli

ShuffleNet (X. Zhang ve diğ., 2017), noktasal gruplanmış evrişim ve kanal karıştırma işlemlerini kullanan hafif ağırlıklı bir ESA mimarisidir. ShuffleNet, mobil cihazlar için

özel olarak tasarlanmıştır. 50 katman derinliğinden oluşan ShuffleNet ağı 1,4M parametreye sahiptir. Ağın giriş uzamsal çözünürlüğü 224×224×3'tür.

Çalışmada ince ayarlı ShuffleNet modelinin node_198'den sonra gelen tüm katmanları ağdan kaldırılmıştır. Kalan mimari, kaba taneli soyut öznitelik haritası üreteci olarak kullanılmaktadır. Bu öznitelik haritası üretici ağdan 7×7 uzamsal çözünürlükte toplam 544 aktivasyon haritası elde edilmektedir.

Öznitelik Haritası Üreteci Olarak EfficientNet-B0 Modeli

EfficientNet (M. Tan ve Le, 2020) modellerinde, ağ derinliğini, genişliğini ve çözünürlüğünü dikkatlice dengelemenin sınıflandırma performansını iyileştirdiği ortaya koyulmuştur. (M. Tan ve Le, 2020)'de sunulan EfficientNet ağları, bu kriterler dikkate alınarak B0-B7 arasında sekiz ardışık modelden oluşmaktadır. EfficientNet-B0, 82 katman derinliğe sahip 5.3M parametreli temel modeldir. Bu ağın giriş uzamsal çözünürlüğü 224×224×3'tür. Diğer modeller, bu temel modelden yararlanılarak kademeli olarak türetilmiştir. Model karmaşıklığı her türetmeyle birlikte artmaktadır. (M. Tan ve Le, 2020)'de verilen EfficientNet modellerinde her bir modelin giriş uzamsal çözünürlüğü de daha ince taneli öznitelikler yakalamak için kademeli olarak artırılmaktadır. En yüksek ImageNet doğruluğu nihai model B7 ile elde edilmektedir.

Tez çalışması kapsamında, kompleksitesi daha düşük olduğu için EfficientNet-B0 modeli kullanılmaktadır. Model ince ayarlı yapıldıktan sonra *Efficientnet-b0|model|head|MulLayer* katmanından sonra gelen tüm katmanlar ağdan kaldırılmaktadır. Böylelikle, kalan mimari daha kaba-taneli-soyut öznitelik haritası üreteci olarak kullanılmaktadır. Çalışmada bu ağın son katmanından 7×7 çözünürlükte 1280 adet aktivasyon haritası elde edilmektedir.

Öznitelik Haritası Üreteci Olarak SqueezeNet Modeli

SqueezeNet (Iandola et al. 2016), 18 katman derinliğine sahip 1,24M parametreli bir ağdır. Bu ağın giriş uzamsal çözünürlüğü 227×227×3'tür. SqueezeNet ağının tasarımının ardındaki ana motivasyon, daha az parametre yükü ile yüksek performans sağlayan bir ağ oluşturulmasıydı. Nihai olarak, SqueezeNet ağı ile ImageNet (Russakovsky ve diğ.,

2015a) veri kümesi üzerinde 50 kat daha az parametre yükü ile AlexNet (Krizhevsky ve diğ., 2017) modelinin sağladığı doğruluğa ulaşılmıştır.

Tez çalışmasında SqueezeNet ağının giriş uzamsal çözünürlüğü, diğer ağlarla uyumluluk sağlanması için ince ayardan önce 224×224×3 olarak ayarlanmaktadır. Ardından ince ayarlı SqueezeNet modelinin *fire9-concat* katmanından sonra gelen tüm katmanlar ağdan kaldırılmaktadır. *fire9-concat* katmanından 13×13 uzamsal çözünürlükte 512 aktivasyon haritası elde edilmektedir. Çalışmada kullanılan diğer ağların çıkış uzamsal çözünürlüklerine uyumluluk için *fire9-concat* katmanı ardına bir maksimum havuzlama katmanı (stride: 2×2, pooling: 2×2) bağlanmaktadır. Böylelikle 7×7 uzamsal çözünürlükte 512 aktivasyon haritası veren bir öznitelik haritası üretici bloğu elde edilmektedir.

4.1.2. Topluluk Ağının Oluşturulması

Bu bölümde, Şekil 4.1'de verilen önerilen topluluk ağının oluşturulma süreci anlatılmaktadır. Öznitelik haritası üreteci blokların girişleri, tek girişli bir ağ elde edebilmek için birbirine bağlanmaktadır. Bu şekilde, 224×224×3 uzamsal çözünürlüklerde girdi alan ve paralel olarak işleyen üç ayrı öznitelik haritası üretici bloğu elde edilmektedir.

4.1.2.1. Öznitelik Haritası Kaynaştırma

Bu bölümde, Şekil 4.1'de verilen önerilen ağın oluşturulma süreci açıklanmaktadır. Öznitelik haritası üreteci bloklarının girişleri, tek girişli bir ağa sahip olacak şekilde birbirine bağlanmıştır. Bu şekilde 224×224×3 uzamsal çözünürlükte girdi alan ve paralel olarak işleyen üç ayrı öznitelik haritası üreteci bloğu elde edilmektedir.

4.1.2.2. Ek Katmanlar

Topluluk kodlayıcı yapısından elde edilen tensör farklı ağlardan geldiği için farklı aralıklardadır. Bu nedenle hem verileri normalleştirmek hem de sağlamlaştırılmış haritaları daha fazla işlemek için bazı ek katmanlar kullanılmaktadır. Ek katmanlar birbiri ardına gelen Yığın Normalleştirme, ReLU, Evrişim, Yığın Normalleştirme, ReLU, tam bağlı katman, Softmax ve sınıflandırma katmanlarından oluşmaktadır. İlk olarak,

öznitelik haritası füzyonundan sonra elde edilen 7×7×2336 boyutundaki tensör, Normalleştirme ve ReLU katmanları izlenerek Evrişimsel katmana aktarılmaktadır. Parametre sayısının azaltılması için Evrişimsel katmanda 2 çekirdek kullanılmaktadır. Böylelikle bu katmanın çıkışında elde edilen tensör 7×7×2 boyutundadır. Ardından, tensör, sırasıyla Yığın Normalleştirme ve ReLU katmanların tarafından işlenerek Tam Bağlantılı Katmana taşınmaktadır. Tam bağlı katmanda aktivasyon elemanlarının sayısı sınıfların sayısına eşit olduğundan, elde edilen ESA kodları 1×1×2 boyutundadır. ESA kodları, sınıf tahmin puanlarını elde etmek için Softmax katmanına beslenir. Son olarak, Softmax katmanından sonra sınıflandırma katmanı kullanılmaktadır. Sınıflandırma görevi için çapraz entropi kaybı bu katmanda hesaplanmaktadır. Tüm bu adımların sonunda tek girişe ve çıkışa sahip bir derin öğrenme modeli elde edilmektedir.

4.2. Deneysel Sonuçlar

4.2.1. Veri Kümesi

COVID-19 pandemisi başladığından bu yana hastalığın medikal görüntülerden tespitine yönelik birçok çalışma yapılmıştır. Geliştirilen modellerin önemli bir bölümünde hastalığın tespitinde ulaşılan performansın %90'ının üzerinde oluduğu belirtilmektedir. Veri kümeleri önemli derecede yanlılık içerdiğinde elde edilen performans aşırı iyimser olabilmektedir (Roberts ve diğ., 2021). Bu bölümde çalışmada yararlanılan veri kümelerinin tanıtılmasından önce, veri kümesi seçiminde önemli olan bazı etkenler kısaca gözden geçirilmektedir.

Hasta demografiklerindeki tutarsızlıklar: COVID-19 hastalığının tıbbi görüntülerden tespitine yönelik olarak yayınlanmış çalışmaların önemli bir çoğunluğunda derleme veri kümelerinden yararlanılmaktadır. Derleme veri kümeleri farklı veri kümelerinin harmanlanması ile elde edilmektedir. Derleme veri kümelerinde hasta demografikleri sınıflar arasında önemli farklılıklar içerebileceğinden bu veri kümelerinin model eğitimlerinde kullanılmasının ön yargılı öğrenme gibi önemli bir sakıncası bulunmaktadır (Cruz ve diğ., 2021). Derleme veri kümelerinin önemli birçoğunda bulunan ve kontrol grubu olarak kullanılan *UCSD-Guangzhou* veri kümesi (Kermany ve diğ., 2018) çocuk yaşlardaki hastalardan toplanmış viral pnömoni örnekleri ve sağlıklı örneklerden oluşmaktadır. Bununla birlikte veri kümelerindeki COVID-19 hastalığı içeren tıbbi

görüntüler çoğunlukla yetişkin insanlardan elde edilmektedir. Örnek bir durum COVID-19 pnömonisini sağlıklı ve viral pnömoni vakalardan ayırmak amacıyla oluşturulan derleme veri kümelerinden olan *COVID-19 Radiography Dataset* (Chowdhury ve diğ., 2020) üzerinden verilebilmektedir. *COVID-19 Radiography* veri kümesinde sağlıklı ve viral pnömoni sınıflarına ait örnekler *UCSD-Guangzhou* veri kümesinden, *COVID-19* hastalığına ait örnekler ise *COVID-19 Image Data Collection* (Cohen ve diğ., 2020) veri kümesinden toplanmıştır.

Yüksek heterojenite: Heterojenite çeşitlilik ya da farklılık olarak tanımlanabilmektedir. Küresel pandemi sürecinde, dünyanın birçok bölgesinde farklı sağlık kurumlarından elde edilen tıbbi görüntüler bir araya getirilerek oluşturulan veri kümeleri yüksek derecede heterojenite içermektedir. Bilhassa toplanan verilerin hangi kaynaklardan elde edildiği belirsiz olabilmektedir. Bu gibi durumlar eğitilen modellerin COVID-19 hastalığına ilişkin örüntülerin dışındaki gereksiz detayları öğrenmelerine sebep olmaktadır. Pandemi sürecinde yaygın olarak kullanılan popüler veri kümelerinden biri olan *COVID-19 Image Data Collection* (Cohen ve diğ., 2020), COVID-19 hastalığına ilişkin en az 15 ülkeden toplanmış olan görüntülerden oluşmaktadır. *COVID-19 Image Data Collection* (Cohen ve diğ.,) veri kümesinden yararlanılarak yapılan (Maguolo ve Nanni, 2021)'deki çalışmada COVID-19 hastalığının tespitinde akciğer bölgesinin dâhil edilmesi ve edilmemesi durumlarında anlamsız olarak elde edilen benzer sonuçlar yüksek heterojenitenin oluşturabileceği sakıncaları örneklemektedir. Bu durum, COVID-19 hastalığına ilişkin örüntülerin modeller tarafından uygun şekilde öğrenilemediğini ortaya koymaktadır.

Meta Veriden Yoksunluk: Veri kümeleri ile ilgili olan bir diğer bir önemli sorun ise veri kümelerinin kaç hastadan oluştuğunun bilinmemesidir. Bunun bir sonucu olarak, veri kümesi hasta seviyesinde parçalara ayrıştırılamamaktadır. Bu durum veri sızması sorununu oluşturarak modellerin yanlı olarak öğrenmesine sebep olmaktadır.

Belirsiz Etiketleme Protokolü: Yararlanılan veri kümelerindeki COVID-19 hastalığı için pozitif vakaların nasıl etiketlendiğine ilişkin belirsizliğin bulunması şüphe vericidir. Etiketleme protokollerindeki bu belirsizlik eğitilen modellerin hastalıkla ilişkin örüntüleri öğrenip öğrenmediği konusunu da tartışılabilir hale getirmektedir. Bunun sonucunda önerilen yöntemlerin klinik anlamda kullanılabilirlik şansı azalmaktadır.

Hastalığın Ağır Formlarına Ait Verinin Çokluğu: COVID-19 hastalığı, X-ışını görüntülerinde hafif, orta ve ağır olarak kategorilendirilebilen imzalara sahiptir. Bununla birlikte yararlanılan veri kümelerinin önemli bir çoğunluğu COVID-19 hastalığının ağır formlarına ait görüntülerden oluşmaktadır (Kundu ve diğ., 2020). X-Işını görüntülerinde hastalığın ağır formlarına ait imzaların belirgin bir şekilde olması eğitilen modellerin performansının önemli derecede yüksek olması ile sonuçlanmaktadır. Bununla birlikte, bu şekilde eğitilen modeller hastalığın hafif ve orta şiddette bulunan formlarının tespit edilmesinde başarısız sonuçlar vermektedir.

Veri kümeleri hakkında yukarıda açıklananlara dikkat edilerek, çalışmada bilinen kaynaklardan derlenen çapraz kurumsal bir veri kümesi kullanılmaktadır. Çalışmada kullanılan veri kümeleri: COVIDGR-1.0 data set, ML-Hannover data set, COVID-19-AR data set, Tuberculosis Chest X-Ray Data set.

COVIDGR-1.0 veri kümesi oldukça iyi açıklanmış bir etiketleme protokülüne sahiptir. Hasta demografikleri de veri kümesi ile birlikte paylaşılmaktadır. Bu veri kümesi iyi eğitimli dört radyolog ile işbirliği içerisinde oluşturulmuştur. Veri kümesi COVID-19 hastalığı için pozitif olan 426 (236 erkek, 190 kadın) ve negatif olan 426 X-Işını (187 erkek, 239 kadın) görüntüsü içermektedir. Veri kümesindeki tüm görüntülerin aynı makine kullanılarak elde edildiği belirtilmektedir. Hastaya ait RT-PCR testi ve 24 saatten daha önce radyolog görüşü pozitif olduğunda bir hastaya ait X-ışını görüntüsü pozitif olarak işaretlenmiştir. Bununla birlikte radyolog görüşü negatif iken RT-PCR testi pozitif ise ilgili durum Normal-PCR+ olarak işaretlenmiştir. Hastalığın hafif, orta ve şiddetli formlarının sınıflandırılmasında ise radyologlar tarafından RALE (Radiographic Assessment of Lung Edema) skorları temel alınmıştır (Warren ve diğ., 2018). *COVIDGR-1.0* veri kümesine URL-8'den ulaşılabilmektedir.

ML-Hannover (URL-7, 2021) veri kümesi 71 COVID-19 hastasından toplanan 243 X-ışını görüntüsünden oluşmaktadır. Hastalara ait demografik öznitelikler veri kümesi ile birlikte meta veri olarak verilmektedir. Veri kümesindeki 71 hastanın 24'ü kadın, 47'si ise erkektir. Veri kümesindeki görüntüler değişen boyutlarda olup PNG formatında verilmektedir. *ML-Hannover* veri kümesine URL-6'dan ulaşılabilmektedir.

COVID-19-AR (Desai ve diğ., 2020; Jenjaroenpun ve diğ., 2020) veri kümesi CIA'da bulunmaktadır (Clark ve diğ., 2013a). Bu veri kümesi COVID-19 için pozitif olan 105 hastadan (53 erkek, 52 kadın) toplanan 262 ait X-ışını görüntüsünden oluşmaktadır. Veri kümesindeki tüm görüntüler DICOM formatında verilmektedir.

COVID-19 Image Data Collection (Cohen ve diğ., 2020) 44 erkek ve 36 kadın hastadan toplanan 94-X-ışını görüntüsünden oluşmaktadır. Bu koleksiyondaki hastaların yaş ortalaması 56±14,8 olduğu belirtilmektedir. 94 görüntünün her biri için önem skorları, her biri en az 20 yıllık deneyime sahip üç kör uzman tarafından atanmıştır.

Tuberculosis Chest X-Ray (Jaeger ve diğ., 2014.; Candemir ve diğ., 2014) veri kümesi Shenzhen ve Montgomery County veri kümelerinden oluşmaktadır. *Shenzhen veri kümesi* 326 Normal, 336 Tuberküloz belirtileri içeren toplamda 662 X-Işını görüntüsünden oluşmaktadır. Benzer şekilde, *Montgomery County veri kümesi,* Tuberküloz belirtileri içeren 58 ve normal bulgulara sahip 80 X-Işını görüntüsünden oluşmaktadır. Veri kümesindeki görüntüler değişen boyutlarda olup PNG formatında verilmektedir. Her bir veri kümesi için hastaların yaş ve cinsiyet bilgilerini içeren meta veri sağlanmıştır. Veri kümelerine URL-9'dan ulaşılabilmektedir. Tablo 4.1'de yukarıda açıklanan veri kümeleri özetlenmektedir.

Tablo 4.1. Çalışmada kullanılan veri kümelerinin özeti

Veri kümesi	Sınıflar	Cinsiyet			Şiddet	Toplam Hasta
		Kadın	Erkek	Belirsiz		
COVIDGR-1.0	COVID-19 (+)	190	236	-	Normal-PCR+: 76 Mild: 100 Moderate: 171 Severe: 79	426
	NORMAL	239	187	-	-	426
ML-Hannover	COVID-19 (+)	24	47	-	-	71
COVID-19-AR	COVID-19 (+)	53	52	-	-	105
Shenzhen	NORMAL	105	221	-	-	326
Montgomery County	NORMAL	53	26	1	-	80
COVID-19 Image Data Collection	COVID-19 (+)	36	44	-	Normal-PCR+: 15 Mild: 30 Moderate: 31 Severe: 18	80

Veri Kümesi-1

Tablo 4.1'den görüldüğü gibi, *COVIDGR-1.0* veri kümesindeki COVID-19 (+) vakalarının %81'i hastalığın ağır formlarının dışındadır. Bu durum bu veri kümesini zorlu hale getirmektedir. Çalışmada hastalığın farklı formlarının da öğrenilebilmesini mümkün

kılmak amacıyla *COVIDGR-1.0* veri kümesi eğitim kümesi olarak ayrılmaktadır. Bunun yanında, *ML-Hannover* (*COVID-19 Image Repository,* 2021) veri kümesinden rastgele olarak 35 COVID-19 hastası seçilmektedir. Böylelikle, 35 hastadan elde edilen 106 X-ışını görüntüsü eğitim kümesine dahil edilmektedir. Son olarak *Shenzhen* veri kümesinin Normal sınıfındaki 326 hastadan rastgele 106 hasta seçilmiştir. Böylelikle, 532 normal, 532 COVID-19 bulguları içeren toplamda 1064 X-Işını görüntüsünden oluşan Veri Kümesi-1 elde edilmektedir.

Veri Kümesi-2

ML-Hannover (*COVID-19 Image Repository*, 2021) veri kümesindeki kalan 36 COVID-19 hastasından gelen 137 X-ışını görüntüsü test seti olarak ayrılmıştır. *COVID-19-AR* (Desai ve diğ., 2020; Jenjaroenpun ve diğ., 2020) veri kümesindeki 105 hastadan gelen 262 X-Işını görüntüsü diğer bir test seti olarak ayrılmıştır. *COVID-19 Image Data Collection* (Cohen ve diğ., 2020) diğer bir test kümesi olarak tutulmaktadır. (Wong ve diğ., 2020) ve (Cohen ve diğ., 2020)'da akciğer konsolidasyonu için tanımlanan aralıklara dayanarak, PCR+, hafif, orta ve şiddetli vakalar için sırasıyla 15, 30, 31 ve 18 görüntü bulunmaktadır. Shenzen ve Montgomery veri kümelerinin Normal sınıfından sırasıyla 220 ve 80 X-ışını görüntüsü seçilmiştir. Böylelikle toplamda 793 X-ışını görüntüsünden oluşan Veri Kümesi-2 elde edilmektedir.

4.2.2. Hiperparametreler ve Veri Çoğaltma

Eğitim verisi her bir epoch değerinde çoğaltılmaktadır. Eğitim ön ayarları (hiperparametreler) Tablo 4.2'de verilmektedir. SqueezeNet, ShuffleNet ve EfficientNet-B0 modelleri için eğitim süresi sırasıyla 5, 6 ve 12 dakikadır. Ensemble-CVDNet modeli oluşturulurken, ilk olarak EfficientNet-B0 ağı SqueezeNet ağı ile birleştirilmektedir. Bu birleşimin sonucunda elde edilen ağ Ensemble-CVDNet#1 olarak adlandırılmış olup eğitim süresi yaklaşık olarak 13 dakikadır. Ardından, ShuffleNet ağının Ensemble-CVDNet#1 ağına entegre edilmesi ile önerilen model elde edilmektedir. Önerilen model için eğitim süresi yaklaşık olarak 19 dakikadır. MobileNetV2 (Sandler ve diğ., 2019) 53-katman derinliğine sahip ve 3.5M parametreden oluşan diğer bir hafif ağırlıklı ağdır. Deneylerde, ShuffleNet modeli ile katman sayısı anlamında karşılaştırılabilir olduğundan önerilen modelin oluşturulmasında kaba-taneli öznitelik haritası üreteci olarak

MobileNetV2 modeli de kullanılmaktadır. Elde edilen bu yeni birleşim ise Ensemble-CVDNet#2 olarak adlandırılmıştır. MobileNetV2 ve Ensemble-CVDNet#2 modelleri için eğitim süreleri yaklaşık olarak sırasıyla 8 ve 35 dakikadır. Çalışmada her bir tekli model için son tam bağlı katman ağırlık ve yanlılık öğrenme oranı çarpanı 10 olarak kurulmuştur. Diğer bir yandan oluşturulan her bir topluluk modeli için Şekil 4.1'deki ek katmanlarda bulunan evrişimsel ve tam bağlı katmanlar için ağırlık ve yanlılık öğrenme oranı çarpanı 10 olarak kurulmuştur. Çalışmada hiç bir ağ katmanı dondurulmamıştır.

Tablo 4.2. Çalışmada kullanılan eğitim hiperparametreleri ve veri çoğaltma teknikleri

Ön Ayarlar			
Hiperparametreler	SqueezeNet, ShuffleNet, MobileNet-v2, EfficientNet-B0	Ensemble-CVDNet #1, Ensemble-CVDNet #2, Ensemble-CVDNet #3	Veri çoğaltma
Optimizasyon algoritması	ADAM	ADAM	- Yatayda ve düşeyde rastgele aynalama
Mini yığın boyutu	10	10	
Maksimum Epoch	10	10	- [0,75 1,25] arasında rastgele ölçekleme.
Global Öğrenme Oranı	10^{-4}	10^{-4}	
L_2 Düzenlileştirme	10^{-4}	10^{-4}	- $[-30^{\circ}\ 30^{\circ}]$ arasıda rastgele döndürme.
Ağırlık & Yanlılık Öğrenme Oranı Çarpanı	10	10	- Yatayda ve düşeyde rastgele [-3 3] piksel öteleme.

4.2.3. Performans Metrikleri

Çalışmanın bu bölümünde Bölüm 2.2.1'de tanıtılan performans metrikleri kullanılmaktadır.

4.2.4. Performans Karşılaştırma

Bu bölümde, önerilen yöntem çalışma kapsamında uygulanan diğer yöntemler ve literatürdeki benzer çalışmalar ile karşılaştırılmaktadır.

4.2.4.1. Derin Öğrenme Temelli Topluluk Modeli Oluşturma (DÖT)

Veri kümesi-1, veri sızması probleminin önüne geçebilmek için hasta seviyesinde örtüşmeyen beş ayrı kata ayrılmaktadır. Şekil 4.2'de her bir eğitim ve test katında kaç hastanın dâhil edildiği özetlenmektedir. Her bir zaman bir kat test kümesi olarak tutulurken diğer katlar modelin eğitiminde kullanılmaktadır. Aşırı uydurmadan kaçınmak adına eğitim aşamasında ilgili eğitim kümesi örneklerinin %10'luk bölümü rastgele tutularak modelin geçerlenmesinde kullanılmaktadır. Model eğitildikten sonra karşılık

gelen test katı üzerinde değerlendirilmektedir. Bu süreç beş kez tekrarlandıktan sonra her bir test katı üzerinde elde edilen karışıklık matrisleri toplanarak model genel performansı gözlenmektedir. Tablo 4.3'te çalışmada kullanılan modeller ile test katları üzerinde elde edilen ortalama çapraz geçerleme skorları verilmektedir. Tablo 4.3'ten görüldüğü gibi, tekli modeller arasında en iyi ortalama sınıflandırma duyarlılığı EfficientNetB0$_{ft}$ modeli ile elde edilmektedir. Diğer bir yandan, SqueezeNet$_{ft}$ modeli diğer tekli modeller karşısında en düşük performansı vermektedir.

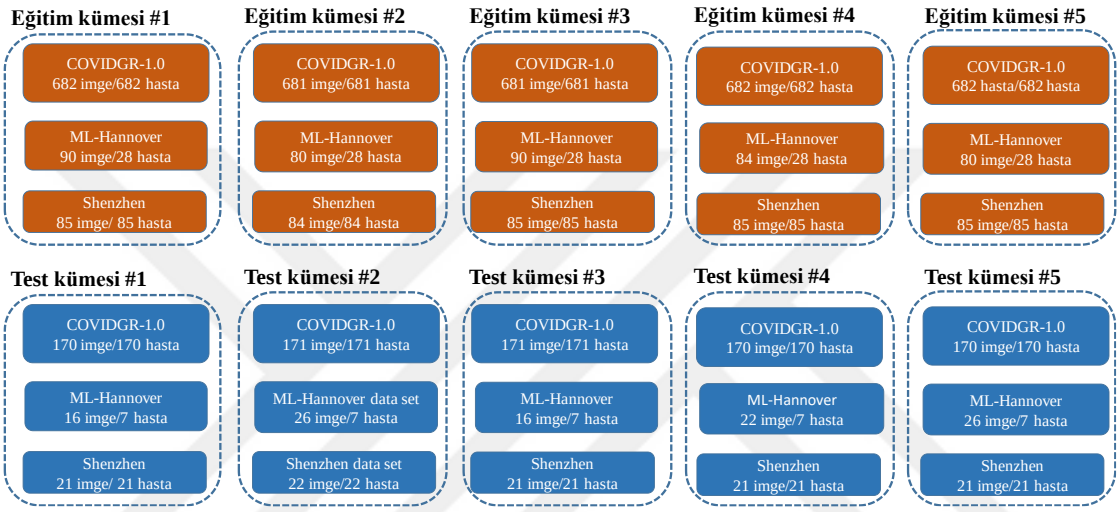

Şekil 4.2. Eğitim ve test kümelerine dâhil edilen hasta sayıları

Dahası, ShuffleNet$_{ft}$ modeli MobileNetV2$_{ft}$ ve EfficientNet-B0$_{ft}$ modelleri karşısında daha düşük performans vermektedir. Tüm bunlar sınıflandırma için daha ayırt edici özniteliklerin daha derin ağlar tarafından çıkartılabildiğini ortaya koymaktadır. Çalışmada önerilen derin öğrenme temelli topluluk ağının performansı üzerinde SqueezeNet$_{ft}$ modelinin etkisini gösterebilmek için oluşturulan Ensemble-CVDNet#1 modeli ortalama TPR skorunda %0.57 artış sağlamaktadır. Ardından, kaba taneli öznitelik çıkartıcı olarak düşünülen ağlar Ensemble-CVDNet#1 yapısına tümleştirilmiştir. Tablo 4.3'ten görüldüğü gibi Ensemble-CVDNet#1'e MobileNetV2 modelinin tümleştirilmesi elde edilen Ensemble-CVDNet#2 modeli sınıflandırma performansında %1.22'lik düşüşe neden olmaktadır.

Son olarak Ensemble-CVDNet#1 modelinin ShuffleNet$_{ft}$ modeli ile tümleştirilmesi ile Ensemble-CVDNet (önerilen model) elde edilmektedir. Tablo 4.3'ten görüldüğü gibi önerilen model ortalama duyarlılık skorunda %0.75'lik bir artış sağlamaktadır. Önerilen

model, tekli modeller arasında en iyi performansın elde edildiği model olan EfficientNet-$B0_{ft}$ karşısında ise ortalama duyarlılık skorunda 1.32%'lik performans artışı sağlamaktadır.

Tablo 4.3. *Veri kümesi-1*'in her bir test katı üzerinde elde edilen model performansları

Yöntem	**Avg. TPR (%)**					
	Fold-1	Fold-2	Fold-3	Fold-4	Fold-5	*Avg.*
$SqueezeNet_{ft}$	76,71	79,95	75,40	74,59	75,37	*76,50*
$ShuffleNet_{ft}$	78,22	77,49	78,11	77,07	80,00	*78,10*
$MobileNetv2_{ft}$	78,21	78,96	81,39	79,38	80,09	*79,51*
$EfficientNetB0_{ft}$	80,77	80,98	81,39	80,23	79,39	*80,73*
Ensemble-CVDNet#1	81,39	79,08	81,65	80,75	83,16	*81,30*
Ensemble-CVDNet#2	79,80	78,80	83,77	79,20	79,03	*80,08*
Ensemble-CVDNet	81,75	83,61	82,49	81,65	80,60	*82,05*

Şekil 4.3'te önerilen model ile hataların nasıl dağıldığı her bir test katı üzerinde elde edilen karışma matrisleri ve toplam karışma matrisi üzerinden gösterilmektedir.

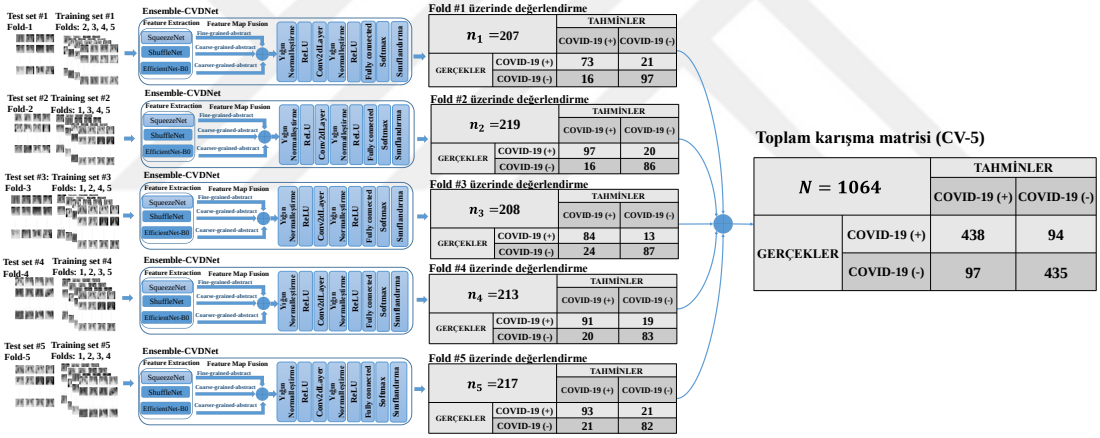

Şekil 4.3. Önerilen sınıflandırma çerçevesinin beş-kat-çapraz-geçerleme süreci kullanılarak değerlendirilmesi

4.2.4.2. Klasik Topluluk Modelleri (KT) Karşısında DÖT

Bu bölümde, derin öğrenme temelli topluluk modelleri klasik topluluk modelleri ile karşılaştırılmaktadır. Bu amaçla, probleme özel özniteliklerin öğrenilmiş olması sebebiyle ince ayarlı hazır modeller SqueezeNet, ShuffleNet, MobileNetV2, EfficientNetB0 öznitelik çıkartıcı yapılar olarak kullanılmaktadır. Hazır ağlardan çıkartılan öznitelik kümelerinin yanı sıra çıkartılan öznitelik kümelerinin birleşiminden oluşan kaynaşık öznitelik kümeleri de elde edilmektedir. Bu bağlamda, SqueezeNet/EfficientNet-B0 öznitelikleri kaynaştırılarak Kaynaşık öznitelikler#1,

SqueezeNet/MobileNetV2/EfficientNetB0 öznitelik kümeleri kaynaştırılarak Kaynaşık öznitelikler#2, SqueezeNet/ShuffleNet/EfficientNetB0 öznitelik kümeleri birleştirilerek ise Kaynaşık öznitelikler#3 türetilmiş öznitelik kümeleri elde edilmektedir. SqueezeNet ağının *fire9-concat* katmanından 512, ShuffleNet ağının *node_199* katmanından 544, MobileNetV2 ağının *out_relu* katmanından 1280 ve son olarak EfficientNet-B0 ağının *efficientnet-b0|model|head|MulLayer* katmanından 1280 öznitelik çıkartılmaktadır. Ardından, elde edilen öznitelik kümeleri kullanılarak klasik topluluk modelleri eğitilmektedir. Elde edilen her bir öznitelik kümesi üzerinde en iyi performansı sağlayan klasik topluluk modeli optimizasyon süreci ile bulunmaktadır. Topluluk yöntemi, öğrenici sayısı (ÖS), öğrenme hızı (ÖH), maksimum ayrım sayısı (MAS), maksimum değişken sayısı (MD) gibi parametreler optimize edilmektedir. Bagging, GentleBoost, LogitBoost, AdaBoost ve RUSBoost gibi klasik topluluk modelleri çalışmada kullanılmaktadır. En uygun hiperparametrelerin bulunmasında Bayes optimizasyon algoritmasından yararlanılmaktadır.

Tablo 4.4. Çalışmada sunulan her bir yöntem ile *Veri kümesi-1* üzerinde elde edilen CV-5 skorları

	Yöntem	TPR (%)	PPV (%)	SPEC (%)	F_1 (%)	ACC (%)
KT	SqueezeNet öznitelikleri + GentleBoost, *NL:38, LR:0.072, MNS:1059*	74,81	74,81	74,81	74,81	74,81
	ShuffleNet öznitelikleri + Bagging, *NL:495, NMS: 860, NPS: 33*	78,57	78,57	78,57	78,57	78,57
	MobileNetV2 öznitelikleri + LogitBoost, *NL: 227, LR:0.93, MNS: 9*	77,07	77,10	77,07	77,08	77,07
	EfficientNetB0 öznitelikleri + GentleBoost, *NL: 499, LR: 0.69, MNS: 27*	79,89	79,89	79,89	79,89	79,89
	Kaynaşık öznitelikler#1 + GentleBoost, *NL: 33, LR: 0.038, MNS: 1018*	78,10	78,10	78,10	78,10	78,10
	Kaynaşık öznitelikler#2 + LogitBoost, *NL:87, LR: 0.26, MNS:1*	79,23	79,25	79,23	79,24	79,23
	Kaynaşık öznitelikler#3 + GentleBoost, *NL: 217, LR: 0.26, MNS: 10*	80,45	80,45	80,45	80,45	80,45
İnce Ayar	$SqueezeNet_{ft}$	76,50	76,51	76,50	76,51	76,50
	$ShuffleNet_{ft}$	78,10	78,22	78,10	78,16	78,10
	$MobileNetv2_{ft}$	79,14	79,14	79,14	79,14	79,14
	$EfficientNetB0_{ft}$	80,73	80,73	80,73	80,73	80,73
DÖT	Ensemble-CVDNet#1	81,30	81,40	81,30	81,35	81,30
	Ensemble-CVDNet#2	80,08	80,25	80,08	80,16	80,08
	Ensemble-CVDNet	82,05	82,05	82,05	82,05	82,05

Tablo 4.4'te, DÖT ile elde edilen sonuçlar KT ile elde edilen sonuçlar ile karşılaştırmalı olarak verilmektedir. Buna göre, DÖT performansta ortalama %1.61 iyileştirme sağlamaktadır. Diğer bir yandan, en iyi skorlar Ensemble-CVDNet ile elde edilmektedir.

Bu nedenle, bu model ile her bir test katında elde edilen karışma matrisleri Şekil 4.3'te sağlanmaktadır.

COVID-19 için pozitif olan bir hastanın sağlıklı olarak sınıflandırılması (Yanlış Negatif), sağlıklı bir hastanın COVID-19 olarak sınıflandırılmasından (Yanlış Pozitif) daha önemli bir hatadır. Bu durum, özellikle SARS-COV-2 virüsünün bulaşılığı dikkate alındığında hastalığın hızla yayılmasına sebep olabilecektir. Bu nedenle, COVID-19 hastalığını tespit etmek için geliştirilecek bir modelin duyarlılığının yüksek olması son derece önem arz etmektedir. Tablo 4.4'ten görüldüğü gibi, tekli modeller ile karşılaştırıldığında daha iyi skorların önerilen Ensemble-CVDNet modeli ile elde edildiği görülmektedir. Bu bulgular derin öğrenme temelli topluluk modelinin tekli ağdaki bilgi kaybını telafi ederek hatalı sınıflandırma maliyetini düşürdüğünü göstermektedir.

Bu durum aynı zamanda Tablo 4.5'te verilen karışma matrisi üzerinden de karşılaştırmalı olarak gösterilmektedir. Tablo 4.5'te görüldüğü gibi, toplam yanlış sınıflandırma maliyeti, tekli model EfficientNet-B0 karşısında Ensemble-CVDNet#1 ile öncelikle 205'ten 199'a, ardından Ensemble-CVDNet ile 199'dan 191'e indirgenmektedir. Öte yandan önerilen yöntem ile klasik topluluklara karşı toplam yanlış sınıflandırma maliyeti 208'den 191'e düşürülmüştür.

Tablo 4.5. Çalışmada sunulan yöntemler için karışma matrisi. Sıralama: Fused features #3 + GentleBoost/EfficientNet-B0/Ensemble-CVDNet#1/**Ensemble-CVDNet**

		TAHMİNLER	
N_{CV5}=1064		COVID-19 (+)	COVID-19 (-)
GERÇEKLER	COVID-19 (+)	424/428/417/**438**	108/104/115/**94**
	COVID-19 (-)	100/101/84/**97**	432/431/448/**435**

Şekil 4.4'te verilen dağılım grafiğinde, çalışmadaki farklı yöntemlerin parametre sayıları karşısında sağladıkları TPR skorları gösterilmektedir. İnce ayarlı tekli mimariler, dağılım grafiğinde pentagram şeklindeki kırmızı işaretlerle gösterilirken, topluluk olanlar heksagram şeklindeki mavi işaretlerle gösterilir. Şekil 4.4'te görüldüğü gibi, $ShuffleNet_{ft}$, $SqueezeNet_{ft}$'e kıyasla ek 0,09M parametre ile ortalama TPR puanını yaklaşık %1.6 arttırmaktadır. Benzer şekilde, $ShuffleNet_{ft}$'e kıyasla ek 1,38 milyon parametreye sahip $MobileNetV2_{ft}$, ortalama TPR'ye yaklaşık %1.04 katkıda bulunmaktadır. $EfficientNet\text{-}B0_{ft}$ için $MobileNetV2_{ft}$'e kıyasla ek 1,79M parametre performansı %1.59 arttırmaktadır.

Öte yandan, uygun bir kombinasyon bulunduğunda, Şekil 4.4'te heksagram şeklindeki işaretleyicilerle gösterildiği gibi, tekli modellerle elde edilen ortalama TPR puanları, topluluk kodlayıcı modelleri ile artırılabilmektedir. Buna göre, EfficientNet-$B0_{ft}$'ye 0,92M ek parametre yükü getirerek oluşturulan Ensemble-CVDNet#1, ortalama TPR puanında yaklaşık %0.57'lik bir artış sağlamaktadır.

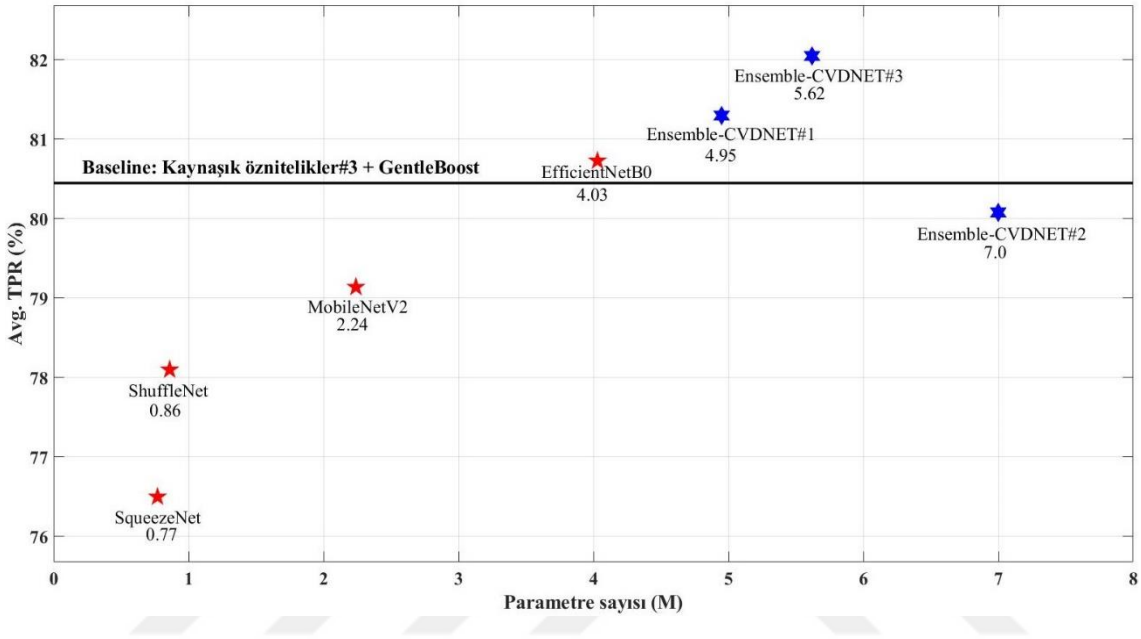

Şekil 4.4. Yöntemlerin toplam öğrenilebilir parametre sayısı karşısında elde edilen doğrulukları gösterir 2B saçılım çizimi

Ayrıca, $ShuffleNet_{ft}$'in Ensemble-CVDNet#1'e eklenmesiyle oluşturulan Ensemble-CVDNet, ek 0,67M parametre yükü getirerek, Ensemble-CVDNet#1'e kıyasla ortalama TPR'yi yaklaşık %0.75 artırmaktadır. $MobileNetV2_{ft}$, tasarlanan sınıflandırma şemasının (yani, Ensemble-CVDNet#2) kaba taneli özellik çıkarıcısı olarak kullanıldığında, elde edilen ortalama TPR, fazladan 1,38M parametre yükü getirerek Ensemble-CVDNet modelinin gerisinde kalmaktadır. $MobileNetV2_{ft}$ ve EfficientNet-$B0_{ft}$ tarafından çıkarılan bazı öznitelik haritalarının oldukça benzer olması bu durumun temel nedeni olarak açıklanabilmektedir. Bu, sınıflandırma performansını düşüren gereksiz özniteliklerin devreye girmesine neden olmaktadır. Sonuç olarak, en iyi performans, yine hafif olan 5,62M parametre ile Ensemble-CVDNet ile elde edilmektedir. Önerilen model ile gelen ek 1,58 milyon parametre yükü (SqueezeNetft ve $ShuffleNet_{ft}$'in toplam parametre sayısı), EfficientNet-$B0_{ft}$ ile karşılaştırıldığında sırasıyla ACC, TPR, PPV, SPEC ve F_1 puanlarında %1.32 iyileşme sağlamaktadır.

Son olarak, önerilen yöntem önceden oluşturulmuş *Veri kümesi-2* üzerinde değerlendirilmektedir. *Veri kümesi-2* üzerinde elde edilen sınıflandırma sonuçları Tablo 4.6'da verilmektedir. Tablo 4.6'da anlaşılabildiği gibi, model tarafından görülmeyen veriler üzerinde elde edilen yaklaşık %80'lik duyarlılık (393/493) ile çapraz geçerleme sonuçları ile tutarlı olan (438/532) bir skor elde edilmektedir. Elde edilen sonuçlar, modelin görünmeyen veriler üzerinde iyi bir genelleme yaptığını göstermektedir.

Tablo 4.6. *Veri kümesi-2* üzerinde elde edilen sınıflandırma sonuçları

		TAHMİNLER	
	N=793	COVID-19 (+)	COVID-19 (-)
GERÇEKLER	COVID-19 (+)	393	100
	COVID-19 (-)	4	296

Çalışma kapsamında her bir yöntem için ortalama çıkarım süresi de değerlendirilmektedir. Bu amaçla, her bir yöntem için çapraz doğrulamada en iyi performans gösteren modeller kullanılmaktadır. Tutarlı sonuçlar elde etmek için ilgili test katındaki X-ışını görüntüleri ağlara 10 kez beslenerek elde edilen yanıt sürelerinin ortalaması alınmaktadır. Buna göre, önerilen yöntemle bir giriş X-ışını görüntüsünün işlenmesi ve sınıflandırılması yaklaşık 10,3 ms sürmektedir. Ensemble-CVDNet#1 ve Ensemble-CVDNet#2 için bir görüntünün işlenmesi sırasıyla yaklaşık 7,8ms ve 10,1ms sürmektedir. İnce ayarlı tekli modeller, SqueezeNet_{ft}, ShuffleNet_{ft}, MobileNet-v2_{ft} ve $\text{EfficientNet-B0}_{ft}$ için sırasıyla yaklaşık 7,5ms, 7,8ms, 7,7ms ve 7,9ms sürmektedir.

4.3. Görselleştirme

Bu bölüm, COVID-19 tespitinde önerilen model tarafından verilen sınıflandırma kararlarını görüntünün hangi bölümlerinin etkilediğini ortaya çıkarmayı amaçlamaktadır. Buna amaçla önerilen modelin aktivasyon haritalarının elde edildiği son evrişim katmanı kullanılmıştır. Şekil 4.5'te hafif, orta ve ağır vakalar için Grad-CAM görüntüleri verilmektedir.

Şekil 4.5(a)'da verilen görüntüler hafif vakalara aittir. Şekil 4.5(b)'de verilen görüntüler orta dereceli vakalara aitken, Şekil 4.5(c)'de verilen son iki resim ağır vakalara aittir. Model tarafından döndürülen bu şüpheli alanların uzman olmadan yorumlanması mümkün değildir. Ancak modelin döndürdüğü şüpheli alanların beklendiği gibi hafif

vakalarda tüm akciğer bölgesinin küçük bir yüzdesini kapsadığı, orta ve özellikle ağır vakalarda şüpheli alanların arttığı görülmektedir.

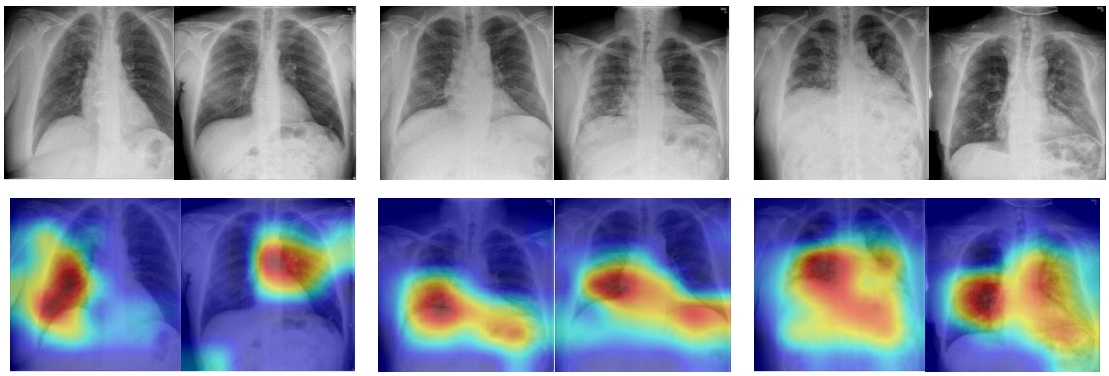

(a) **(b)** **(c)**

Şekil 4.5. Önerilen model tarafından döndürülen GradCAM imgeleri COVID-19 hastalığının sırasıyla hafif (a), orta (b) ve ağır (c) formlarını açıklamaktadır

4.4. Tartışma

Tablo 4.7'de önerilen model, COVIDGR-1.0 veri setini tanıtan (Tabik ve diğ., 2020)'deki referans çalışma ile karşılaştırılmaktadır.

Tablo 4.7. Sınıflandırma sonuçlarının COVID-19 hastalığının şiddet düzeyine göre sınıflandırma performansını analiz eden referans çalışma ile karşılaştırılması

Yöntem	ACC_{PCR+} (%)	ACC_{hafif} (%)	ACC_{orta} (%)	$ACC_{şiddetli}$ (%)	$TPR_{covid19(+)}$ (%)	ACC (%)
COVID-SDNet (Tabik ve diğ., 2020)	-	46,00 ±7,0	85,38 ±1,85	97,22 ±1,86	72,59 ±6,77	76,18 ±2,70
$SqueezeNet_{ft}$	**40,80** ±11,04	53,00 ±9,78	84,80 ±5,38	96,20 ±4,21	70,00 ±4,35	70,77 ±3,05
$ShuffleNet_{ft}$	34,21 ±10,66	68,00 ±9,14	90,64 ±4,36	98,72 ±2,47	68,50 ±4,41	72,65 ±2,99
$EfficientNetB0_{ft}$	35,53 ±10,76	**69,00** ±9,06	87,72 ±4,91	97,44 ±3,48	77,20 ±3,98	76,53 ±2,84
Ensemble-CVDNet	35,53 ±10,76	67,00 ±9,21	**93,60** ±3,66	**98,72** ±2,47	**77,46** ±3,95	**77,70** ±2,79

COVID-SDNet adlı bir derin öğrenme modelinin önerildiği (Tabik ve diğ., 2020)'deki çalışmada COVID-19 hastalığı şiddet düzeylerine göre analiz edilmektedir. Yazarlar, tüm veri kümesini kullanılarak elde ettikleri çapraz geçerleme skorlarını vermektedir. RT-PCR testinin pozitif olduğu ancak röntgende hastalığın görsel belirtisinin uzman tarafından görülmediği durumlar için skor vermemektedir. Tez çalışması kapsamında *COVIDGR-1.0* veri kümesi tamamen kullanıldığı için, Tablo 4.7'de veri kümesi üzerinde

elde edilen çapraz doğrulama puanları verilmektedir. Önerilen yöntem ve çalışma kapsamındaki diğer yöntemlerle elde edilen sonuçlar, X-ışını görüntülerinin hastalığın hafif öncesi evrelerinin imzasını taşımayabileceğini doğrulamaktadır. Öte yandan, (Weinstock ve diğ.,, 2020)'de sağlık kuruluşlarına başvuranların önemli bir çoğunluğunun (%89) hafif normal bulgulara sahip olduğu belirtilmektedir. Mevcut mutasyonlarla birlikte hastalığın artan bulaşıcılığı göz önüne alındığında, özellikle hafif vakaların mümkün olduğunca erken evrelerde yakalanması, virüsün yayılımının kontrol altına alınması açısından kritik önem taşımaktadır. Bununla birlikte, (Tabik ve diğ., 2020)'de açıklandığı gibi, hastalığın hafif ve orta formlarına ilişkin imzalar kolaylıkla yakalanmamaktadır. Belirtilen ifadeyi doğrulayacak şekilde (Tabik ve diğ., 2020)'de hafif vakaların tahmin edilmesinde oldukça zayıf bir skor (rastgele tahminden bile daha kötü) elde edilmektedir, bu da modelin hastalığın hafif formlarına ilişkin imzaların öğrenilemediğini göstermektedir. Buna karşılık, tez çalışması kapsamında önerilen yöntem hafif vakaları sınıflandırmada %21 daha iyi performans göstermektedir. Tablo 4.7'de verildiği gibi, referans çalışma ve hatta bu çalışmada kullanılan tüm diğer yöntemler, hastalığın orta ve şiddetli formlarının sınıflandırılmasında, hastalığın hafif formlarının sınıflandırılmasına kıyasla daha iyi performans göstermektedir. Hastalığın orta ve şiddetli formlarının sınıflandırılmasında önerilen yöntemle en iyi performans elde edilir. Bu durum hastalığın hafif formlarına ilişkin imzalara kıyasla orta ve şiddetli formlarına ilişkin imzaların daha kolay yakalanabildiğini göstermektedir.

Tablo 4.8. *COVID-19 Image Data Collection* veri kümesindeki her bir şiddet düzeyi için önerilen yöntemin değerlendirilmesi

Yöntem	ACC_{PCR+} (%)	ACC_{hafif} (%)	ACC_{orta} (%)	$ACC_{şiddetli}$ (%)	$TPR_{covid19(+)}$ (%)
Ensemble-CVDNet	66,67 ±23,85	73,33 ±15,82	83,87 ±12,94	88,89 ±14,51	78,72 ±8,27

Tablo 4.8'de verilen *COVID-19 Image Data Collection* veri kümesi üzerinde elde edilen sonuçlar da bu durumu doğrulamaktadır. Tablo 4.8'de sunulan PCR+ vakalarının aşırı iyimser sonuçlarının en olası nedeni, küçük test seti boyutunun küçüklüğü ile açıklanabilir.

4.5. Değerlendirme

Tez çalışmasının bu bölümünde, COVID-19 tespiti için X-ışını görüntülerini kullanan ve üç hafif modelin birleşiminden oluşan hafif bir topluluk ağı modeli önerilmiştir. COVID-19 hastalığının tespitine yönelik olarak yapılan birçok çalışmada, hangi modelin en iyi performans gösterdiğini belirlemek adına çeşitli ImageNet modelleri ince ayar stratejisi ile kullanmaktadır. Bazı diğer çalışmalarda ise tasarlanan ağlar sıfırdan eğitilmektedir. Karmaşık özellik kalıplarının öğrenilmesi nedeniyle, bu çalışmada da ince ayar stratejisinden yararlanılarak önceden eğitilmiş ImageNet modelleri kullanılmaktadır. Bununla birlikte her bir ImageNet modeli farklı bir derinliğe sahiptir. Model derinliğinin artması, ayırt edici bilgileri içeren daha soyut özniteliklerin çıkartılmasını sağlamaktadır. Bu çalışmada, tek modeller arasında en iyi sınıflandırma performansı, en derin hafif model olan ince ayarlı EfficientNet-B0 ile elde edilmektedir. Model derinliğinin artması ise bazı anlamsal özniteliklerin sönümlenmesine neden olabilmektedir. Bu nedenle, en derin modeldeki anlamsal bilgi kaybını telafi etmek için 22 kat derinliğe sahip ince ayarlı SqueezeNet ve 50 katman derinliğe sahip ince ayarlı ShuffleNet modelleri 82 katman derinliğe sahip ince ayarlı EfficienNet-B0 modeli ile birleştirilmiştir. Deneysel sonuçlar, bu üç modeli birleştirmenin bilgi kaybını telafi ettiğini doğrulamaktadır. Dahası, en iyi sonuçlar hafif topluluk ağı modeli ile elde edilmektedir. Bu çalışmada önerilen yöntemin klinisyenler veya tıp uzmanları için faydalı olabileceği değerlendirilmektedir.

5. AKCİĞER GRAFİLERİNDEN COVID-19 ŞİDDET SKORU TAHMİNİ İÇİN ÖZNİTELİK ÇIKARTMA

Bölüm 3'de değinildiği gibi tıbbi görüntülerin COVID-19 hakkında çeşitli bilgiler taşıdığı uzmanlar tarafından belirlendikten sonra birçok araştırmacı RT-PCR tekniğine alternatif olabilecek hızlı tarama araçları geliştirmeyi amaçlamıştır (Cozzi ve diğ., 2020). Tez çalışması kapsamında Bölüm 3'te sunulan topluluk modeli de dâhil olmak üzere tüm bu çalışmalarda hastalığın varlığına ve yokluğuna odaklanıldığı için hastalığın ne kadar şiddetli olduğuna dair bilgi almak mümkün olmamaktadır. Hastalığın şiddeti hakkında elde edilecek bilgiler, hastalığın seyri hakkında önemli ipuçları sağlayacaktır. Böylelikle hastaya olan bakımı azaltmak veya arttırmak için fikir edinilebilmektedir.

COVID-19 hastalığının ciddiyetini belirlemek için literatürde çeşitli çalışmalar yapılmıştır. (Cozzi ve diğ., 2020)'te, SARS-COV-2 virüsü ile enfekte olduğundan şüphelenilen tüm hastalar üzerinde RT-PCR testi uygulanmış ve X-ışını görüntülemesi yapılmıştır. Çalışmada hesaplanan RALE skorunun, COVID-19 pnömonisinin ciddiyeti hakkında fikir veren önemli bir sayısal değer olduğu ve acil bakımın gerekliliği hakkında bilgi sağlayabileceği sonucuna varılmıştır. (C. Zhang ve diğ., 2020)'da, COVID-19'un ciddiyetini belirlemek için bir puanlama sistemi geliştirilmiştir. (C. Zhang ve diğ., 2020)'daki çalışmada hastalığın şiddetli geçmesine neden olan risk faktörleri, SARS-COV-2 ile enfekte olmuş hasta popülasyonu üzerinde uygulanan bağlanım modeli ile belirlenmektedir. Bu çalışmada geliştirilen skorlama sistemi, yüksek risk grubundaki hastaların ağır hastalığa yakalanma olasılığının düşük risk grubunda bulunan hastalara göre 20.24 kat daha fazla olduğunu ortaya koymaktadır. (Tang ve diğ., 2021)'de, COVID-19 hastalık şiddetini değerlendirmek için niceleyici ve radyomik özniteliklerin yanı sıra laboratuvar indeksleri kullanılarak Rassal Ormanlar modeli eğitilmiş ve umut verici sonuçlar elde edilmiştir.

Etkili, güvenilir ve düşük maliyetli tanı araçlarının geliştirilmesi, COVID 19 ile mücadelede bir gerekliliktir. Bu motivasyonla tez çalışmasının bu bölümünde COVID-19 hastalığı için şiddet skorlarının tahmin edilebilmesinde düşük hesapsal yüke sahip ve etkili bir yöntemin geliştirilmesi amaçlanmıştır.

Bu bölümün başlıca katkıları şu şekildedir:

1- COVID-19 pnömonisinin ciddiyetini açıklayan akciğer tutulumu ve opaklık skorları, uçtan uca eğitilebilir bir derin öğrenme modeli ile eş zamanlı olarak tahmin edilebilmektedir.

2- Önerilen model, hemen hemen tüm sağlık kurumlarında mevcut olan X-ışını görüntüleme tekniğinden elde edilen görüntüler üzerinde eğitilen 2,19M parametreye sahip hafif bir ağdır.

Çalışma aşağıdaki şekilde organize edilmektedir. Bölüm 5.1'de önerilen yöntem sunulmaktadır. Bölüm 5.2, deneysel sonuçlara ayrılmaktadır. Bölüm 5.3, görselleştirmeye ayrılmıştır. Bölüm 5.4'te tartışma ve son olarak Bölüm 5.5'te değerlendirmeler sunulmaktadır.

5.1. Önerilen Yöntem

Önerilen derin öğrenmeye dayalı önem skoru tahmin çerçevesi Şekil 5.1'de verilmektedir. Şekil 5.1'den görüldüğü gibi, önem skoru tahmin çerçevesi Öznitelik Çıkarma Ağı (ÖÇA) ve Önem Skoru Tahmin Alt Ağı (ÖSTA) iki ana bölümden oluşmaktadır. Buna göre, ÖÇA'dan elde edilen aktivasyon haritaları ÖSTA'ya beslenmektedir. Son olarak, akciğer tutulumu ve opaklık skorları ÖSTA tarafından tahmin edilmektedir. Her iki ağa ilişkin ayrıntıları alt bölümlerde verilmektedir.

5.1.1. Öznitelik Çıkarma Ağı (ÖÇA)

Önceki bölümlerde belirtildiği gibi, tıbbi görüntü analizi alanındaki temel sorunlardan biri eğitim verilerinin yetersizliğidir. Derin transfer öğrenme stratejisi (C. Tan ve diğ., 2018) bunun üstesinden gelebilecek bir tekniktir. Bu stratejide, daha büyük bir veri kümesi üzerinden eğitilmiş bir ağ tarafından öğrenilen öznitelikler yeni göreve aktarılmaktadır. Çalışmada, farklı derinliklerde önceden eğitilmiş ImageNet (Russakovsky ve diğ., 2015a) modelleri, hangi modelin iyi performans gösterdiğini görebilmek için önerilen çerçevenin öznitelik çıkartıcı ağları olarak kullanılmıştır. Buna göre, çalışmada kullanılan modeller sırasıyla ResNet-18 (He ve diğ., 2016), SqueezeNet (Iandola ve diğ., 2016), GoogLeNet (Szegedy ve diğ., 2015), ShuffleNet (X. Zhang ve

diğ., 2017), MobileNetv2 (Sandler ve diğ., 2019) ve EfficientNet-B0 (M. Tan ve Le, 2020) olmaktadır. ÖÇA olarak kullanılacak her modelin tüm ağırlıkları, aşırı uydurmayı önlemek için dondurulmuştur.

5.1.2. Önem Skoru Tahmin Alt Ağı (ÖSTA)

Önem skoru tahmin ağı, opaklık ve akciğer tutulumu ile ilgili göreve özgü özniteliklerin öğrenilebilmesi için paralel olarak çalışan katmanlardan oluşacak şekilde yapılandırılmaktadır. İlk olarak, ÖÇA'dan elde edilen aktivasyon haritaları (ya da öznitelik haritaları) ÖSTA'nın her bir paralel dalının başlangıcında bulunan 3×3 boyutunda 64 çekirdeğe sahip bir evrişimsel katman tarafından işlenmektedir. Daha sonra, elde edilen aktivasyon haritaları bir ara katmandan gelen ince taneli haritalarla bir derinlik kaynaştırma katmanı aracılığıyla kaynaştırılmaktadır. Tablo 5.1'de çalışmada yararlanılan modellerin son ve ara katman isimleri verilmektedir.

Tablo 5.1. Öznitelik haritalarının çıkartıldığı katmanlar ve karşılık gelen tensörler (Öksüz ve diğ., 2021b)

Model	Son katman	Tensör	Ara katman	Tensör
ResNet-18	res5b_relu	7×7×512	res4b_relu+maxpool	7×7×256
SqueezeNet	fire9-concat	13×13×512	fire6-concat	13×13×384
GoogLeNet	inception_5b-output	7×7×1024	inception_4b-output+maxpool	7×7×528
ShuffleNet	node_199	7×7×544	node_163	7×7×544
MobileNetv2	out_relu	7×7×1280	block_15_add	7×7×160
EfficientNet-B0	Model|Head|MulLayer	7×7×1280	model|blocks_14|Add	7×7×192

Elde edilen öznitelik haritaları, sırasıyla Batch Normalization, ReLU, Convolutional, Batch Normalization ve ReLU katmanları aracılığıyla işlenmektedir. Her bir paralel birimde gerçekleştirilen bu işlemlerin ardından daha baskın özniteliklerin çıkartılabilmesi için genel maksimum havuzlama katmanı (Global Maximum Pooling) kullanılmaktadır. Buna göre 64 kanalın her birinden bir öznitelik seçilerek 1×1×64 boyutlu bir vektör elde edilmektedir. Ardından, uzman tarafından tanımlanan tavan değerlerini aşan opaklık ve akciğer tutulumu skorlarını eşikleme için kırpılmış ReLU (Clipped ReLU) katmanından yararlanılmaktadır. Son olarak, her bir daldaki skorları tahmin etmek için tam bağlı katman (Fully Connected Layer) kullanılmaktadır.

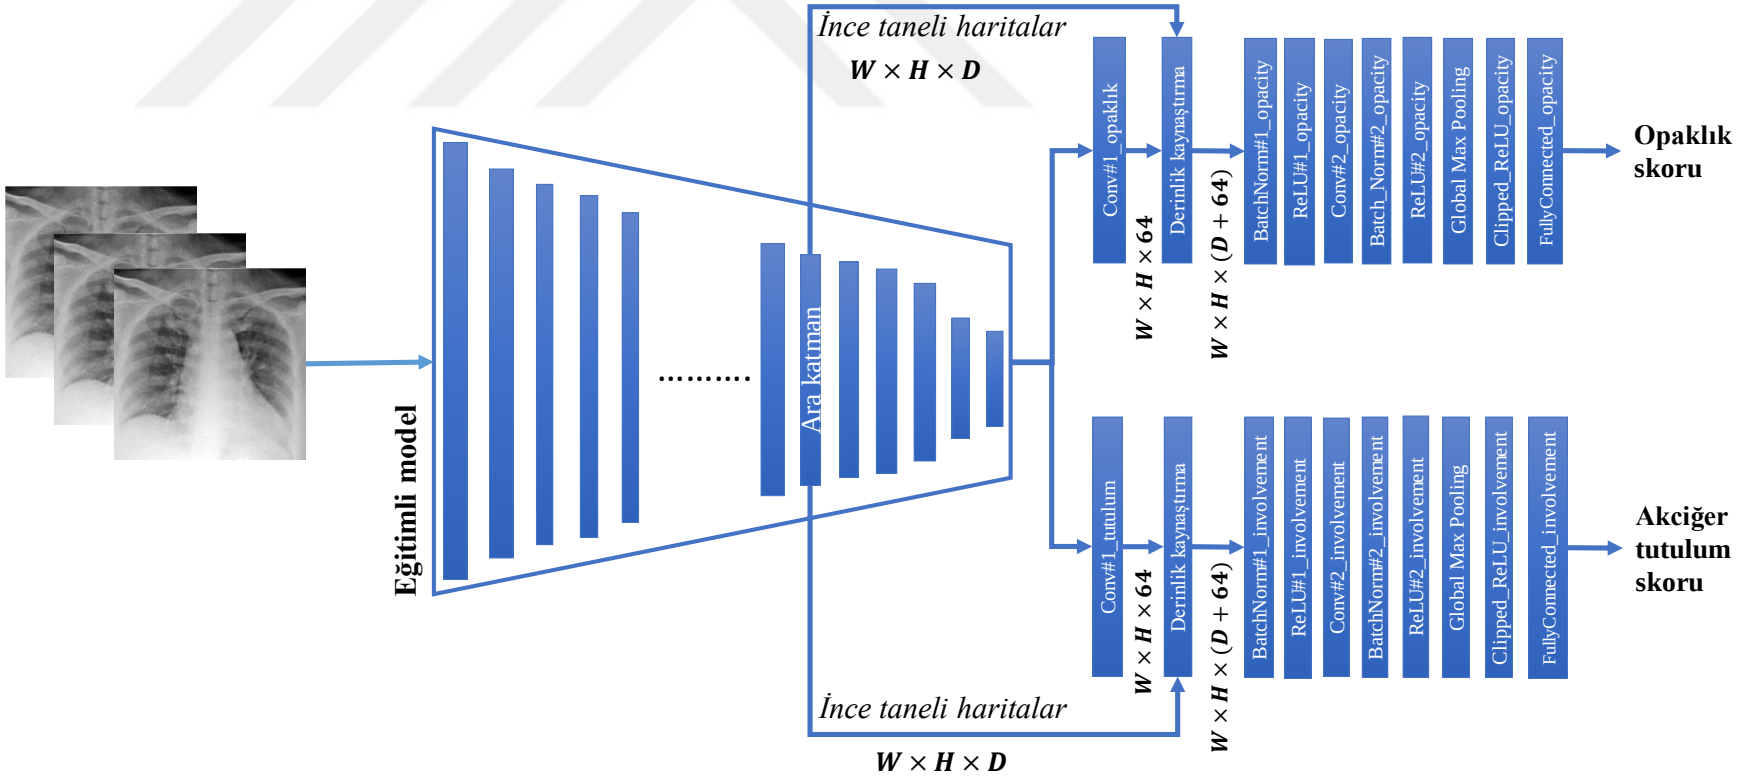

Şekil 5.1. Önerilen önem skoru tahmin çerçevesi (Öksüz ve diğ., 2021b)

5.2. Deneysel Sonuçlar

5.2.1. Veri kümesi

Çalışmada, (Cohen ve diğ., 2020)'de verilen açık erişimli bir veri kümesi kullanılmıştır. Veri kümesi, her biri COVID-19 hastalığına ait imzalar içeren 94 X-ışını görüntüsünden oluşmaktadır. Veri kümesindeki akciğer tutulumu ve opaklık derecesi, üç bağımsız uzman tarafından bir skorlama sisteminden yararlanılarak tahmin edilmiştir (Wong ve diğ., 2020). Skorlama, her bir akciğer için 0-4 aralığında gerçekleştirilmiştir. Buna göre '0', '1', '2', '3', '4' skorları sırasıyla 'tutulum yok', '<% 25 tutulum', '%25 %50 tutulum', '50% -%75 tutulum' ve '>%75 tutulum' durumlarına karşılık gelmektedir (Cohen, Dao, et al. 2020). Buna göre, genel akciğer tutulumu sol ve sağ akciğeri kapsayacak şekilde 0-8 arasında atanmaktadır (Cohen ve diğ., 2020). Veri kümesinde opaklık skorları her bir akciğer için 0-3 aralığında atanmıştır. Buna göre '0', '1', '2' ve '3' dereceleri sırasıyla 'opaklık yok', 'buzlu cam opaklığı', 'konsolidasyon' ve 'beyazlaşma' gibi anlamlara gelmektedir. Sonuç olarak, toplam opaklık derecesi 0-6 aralığında atanmıştır (Cohen, Dao, et al. 2020). Bu nedenle, Şekil 5.1'de verilen önerilen çerçevenin her bir kolundaki kırpılmış ReLU katmanının tavan eşiği,

$$\text{Kırpılmış ReLU tutulum}=\begin{cases}0, & x<0\\ x, & 0<x\le 8\\ 8, & x>8\end{cases}$$
$$\text{Kırpılmış ReLU opaklık}=\begin{cases}0, & x<0\\ x, & 0<x\le 6\\ 6, & x>6\end{cases} \tag{5.1}$$

Eşitlik (5.1)'de olduğu gibi ayarlanmaktadır. Böylelikle ağın yakınsaması da kolaylaşmaktadır.

5.2.2. Hiperparametreler, Veri Çoğaltma ve Hata Fonksiyonu

Çalışmada kullanılan modeller, SGDM (Stochastic Gradient Descent with Momentum) optimizasyon algoritmasından yararlanılarak 200 epoch için eğitilmektedir. Öğrenme hızı, L_2 düzenlileştirme ve Momentum gibi diğer hiperparametreler ise sırasıyla 10^{-3}, 10^{-4} ve 0.9 olarak ayarlanmaktadır. Ağların eğitiminde rotasyon, ölçekleme, yansıtma ve

çevirme gibi veri çoğaltma tekniklerinden yararlanılarak her bir epoch değerinde veri çoğaltılmaktadır. Böylelikle her bir epoch değerinde orijinal eğitim verilerinin farklı bir versiyonu ağlar tarafından görüldüğünden, veriler toplamda 200 kat artırılmaktadır. Çalışmada ağların eğitiminde Eşitlik (5.2)'de verilen yarı ortalama karesel hata fonksiyonundan yararlanılmaktadır.

$$\mathcal{L}_{opaklık,\ tutulum} = \frac{1}{2}\underbrace{\frac{1}{N}\sum_{i=1}^{N}\left(h_{\varphi}(x^i)-y^i\right)^2}_{MSE} \tag{5.2}$$

Eşitlik (5.2)'deki N, h_{φ} ve y sırasıyla gözlem sayısını, kestirilen skorları ve gerçek skorları göstermektedir. Buna göre, ağın her bir başında elde edilen hata değerleri, yani akciğer tutulum hatası ($L_{tutulum}$) ve opaklık hatası ($L_{opaklık}$),

$$\mathcal{L}_{toplam} = \mathcal{L}_{opaklık} + \mathcal{L}_{tutulum} \tag{5.3}$$

Eşitlik (5.3)'te verildiği gibi toplam hatayı (L_{toplam}) elde etmek için toplanmaktadır. Son olarak, elde edilen toplam hata değeri kullanılarak gradyan güncellemeleri yapılmaktadır.

5.2.3. Performans metrikleri

Çalışmada kök-ortalama-kare hatası (RMSE), belirtme katsayısı (R^2) ve ortalama mutlak hata (MAE) performans ölçütleri olarak kullanılmaktadır. RMSE, R^2 ve MAE ölçümleri Eşitlik (5.4)'te verildiği gibi hesaplanmaktadır.

$$RMSE = \sqrt{MSE},\quad R^2 = 1 - \frac{\sum_{i=1}^{N}\left(h_{\varphi}(x^i)-y^i\right)^2}{\sum_{i=1}^{N}\left(y^i-\bar{y}\right)^2},\quad MAE = \frac{1}{N}\sum_{i=1}^{N}\left|h_{\varphi}(x^i)-y^i\right| \tag{5.4}$$

5.2.4. Performans karşılaştırma

Bu bölümde, her bir modelin performansı RMSE ölçüsü kullanılarak değerlendirilmektedir. Değerlendirme süreci Şekil 5.2'de gösterilmektedir.

Veri kümesiden 50 imge test kümesi (hold-out), kalan imgeler ise eğitim kümesi olarak rastgele bölünmektedir. Daha sonra, eğitim kümesi beş kat çapraz geçerleme için

örtüşmeyen beş ayrı test kümesine (katlar) bölünmektedir. Böylelikle her bir model, beş kat çapraz geçerleme ile geçerlenmektedir. Buna göre, genel performansı ortaya çıkarmak adına opaklık ve akciğer tutulumu için her bir test katında elde edilen RMSE skorlarının ortalaması alınmaktadır. Son olarak, en iyi performans gösteren model harici test kümesi (hold-out) üzerinde değerlendirilmektedir.

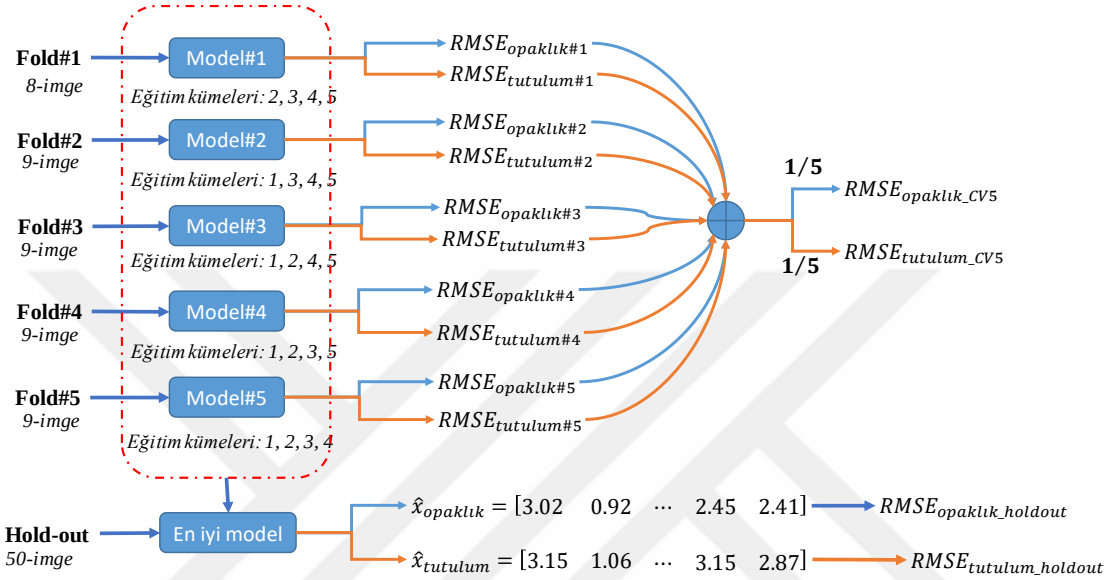

Şekil 5.2. Önerilen yöntemin değerlendirilme süreci

Tablo 5.2'de, her bir yöntem ile test için ayrılan katlar üzerinde elde edilen RMSE çapraz geçerleme skorları, ortalama skorlar ile birlikte verilmektedir.

Tablo 5.2. Performans karşılaştırma

Öznitelik çıkartıcı	**RMSE**						
	Fold-1 8-imge	Fold-2 9-imge	Fold-3 9-imge	Fold-4 9-imge	Fold-5 9-imge	*Avg.*	Hold-out 50-imge
SqueezeNet	2,89/2,80	2,92/2,14	2,30/1,99	2,69/1,95	1,58/2,18	2,47/2,12	2,17/1,79
ShuffleNet	2,14/0,93	1,09/0,93	1,46/0,71	1,24/1,04	1,17/1,59	1,42/1,04	**1,73/1,22**
MobileNetv2	2,83/1,38	1,43/1,51	1,56/1,78	2,33/1,63	2,27/2,22	2,08/1,70	2,09/1,63
ResNet-18	2,37/1,02	1,71/1,29	2,90/1,48	1,99/1,77	1,72/1,19	2,13/1,35	2,13 /1,40
GoogLeNet	1,97/1,55	2,13/1,47	2,37/1,39	2,88/2,03	1,17/0,87	2,10/1,41	2,27/1,36
EfficientNet-B0	3,40/1,14	1,37/1,79	1,56/1,09	1,66/1,38	1,36/1,06	1,87/1,29	2,21/1,42

Aynı zamanda her bir yöntem ile harici test kümesi (hold-out) üzerinde elde edilen skorlar da verilmektedir. Tablo 5.2'den görüldüğü gibi, her bir test katında elde edilen sonuçların sapması ShuffleNet ve ResNet-18 temelli modellerle diğer modeller karşısında görece düşük olduğundan daha istikrarlı performans elde edildiği söylenebilir. Şekil 5.3'te çalışmadaki yöntemler ile elde edilen MAE, R^2 ve RMSE'ye dayalı sonuçları kolayca

karşılaştırmak adına elde edilen ortalama CV-5 skorları bir çubuk grafik olarak verilmektedir.

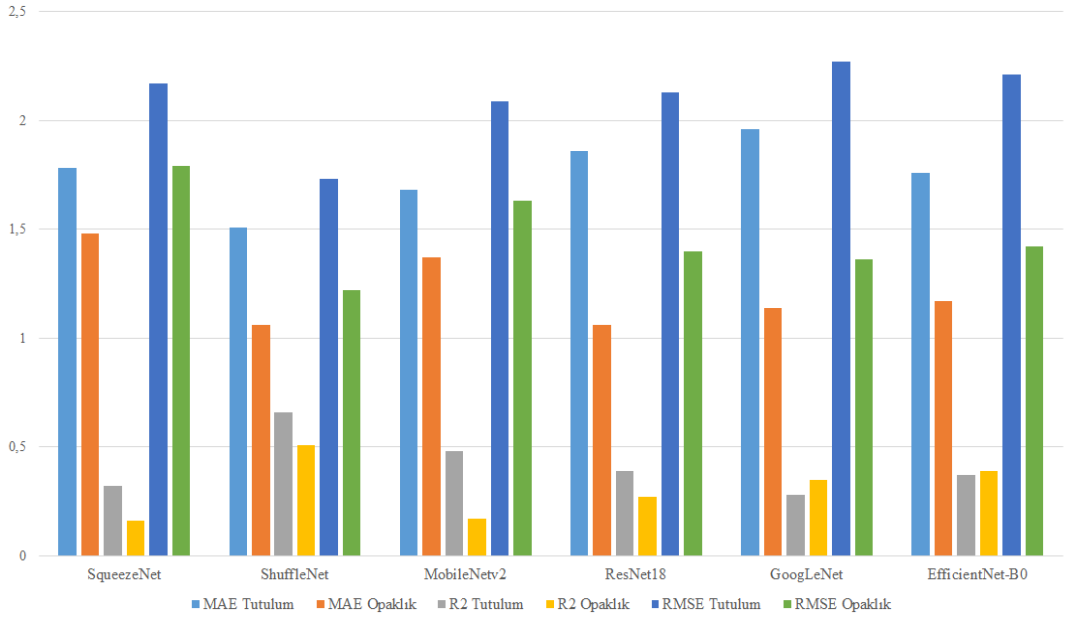

Şekil 5.3. Yöntemlerin MAE, RMSE ve R^2 metriklerine göre karşılaştırılması

Şekil 5.3'ten görüldüğü gibi hem akciğer tutulumu hem de opaklık tahmini için minimum MAE ve RMSE skorları, ShuffleNet temelli model ile elde edilmektedir. Çalışmada ShuffleNet temelli model ile en iyi performans elde edildiğinden, bu modelin hold-out kümesi üzerindeki tahminleri gerçek skorlar karşısında çizilmektedir.

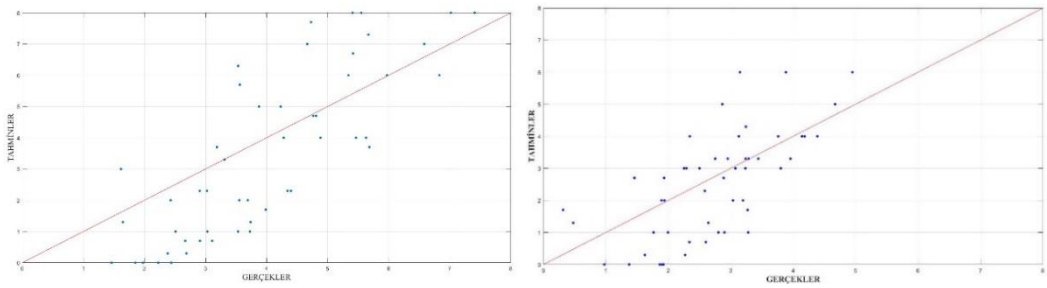

(a) **(b)**

Şekil 5.4. Ağın her bir şiddet tahmin başından kestirilen skorlar karşısında gerçek değerler. (a) Tutulum skoru tahminleri. (b) Opaklık skoru tahminleri (Öksüz ve diğ., 2021b)

Şekil 5.4(a)-5.4(b)'deki saçılım çizimleri sırasıyla akciğer tutulum başlığına ve opaklık skor başlığına karşılık gelen gerçek skorlara karşı tahminler gösterilmektedir. Şekil 5.4(a) ve Şekil 5.4(b)'de çizilen kırmızı ile gösterilen kesikli çizgi mükemmel tahmin çizgisini

göstermektedir. Şekil 5.4(a) ve Şekil 5.4(b)'de görüldüğü gibi, tahmin edilen noktalar mükemmel tahmin çizgisi ile birlikte uzanmaktadır.

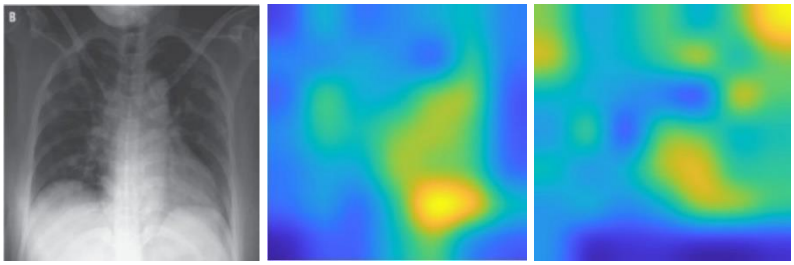

Gth: 2,7; Tahmin: 2.86 **Gth: 2,0; Tahmin: 2,41**

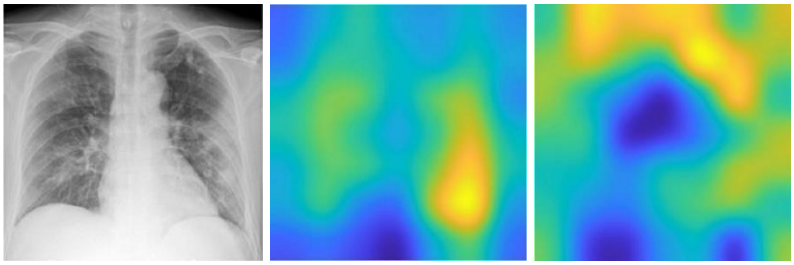

Gth: 3,0; Tahmin: 3,14 **Gth: 2,3; Tahmin: 2,45**

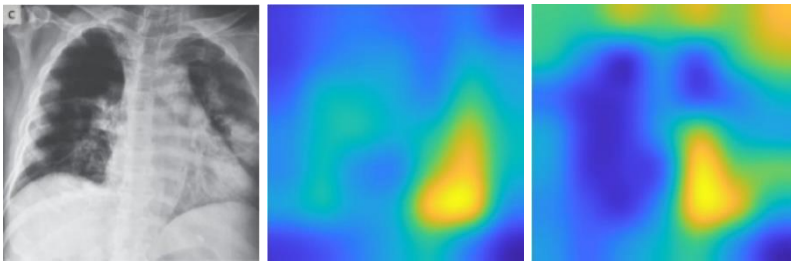

Gth: 4,7; Tahmin: 4,05 **Gth: 3,0; Tahmin: 2,32**

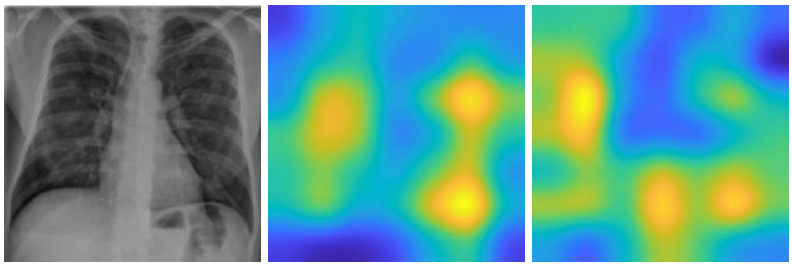

Gth: 3,3; Tahmin: 3,71 **Gth: 2,0; Tahmin: 1,96**

Şekil 5.5. Orta ve en sağdaki sütunlarda verilen Grad-RAM görüntüleri, sırasıyla modelin akciğer tutulum başı ve opasite skor başlığı kullanılarak elde edilmektedir (Öksüz ve diğ., 2021b)

5.3. Görselleştirme

Bu bölümde, hold-out kümesinden seçilen görüntüler için Gradyan Ağırlıklı Regresyon Aktivasyon Haritaları (Grad-RAM) verilmektedir. Ağ çift başlı olduğu için Şekil 5.5'te iki tip Grad-RAM görseli sağlanmıştır. Buna göre Şekil 5.5'in en soldaki sütununda

orijinal görüntüler verilmektedir. Orta sütunda verilen Grad-RAM görüntüleri akciğer tutulumu skor başlığından elde edilirken, en sağ sütunda verilen görüntüler ise opaklık skor başlığından elde edilmektedir. Tahmin edilen skorlar, uzmanlar tarafından atanan gerçek puanlarla (Gth) birlikte Grad-RAM görsellerinin altında altında verilmektedir.

Şekil 5.5'te, her bir tahmin başlığından elde edilen Grad-RAM görüntüleri genellikle akciğerlerin içindeki bölgelere, özellikle opak bölgelere odaklanmaktadır. Bununla birlikte, özellikle opaklık skor başlığından akciğerlerin dışındaki bazı ilgisiz alanlar da sıcak renklerin döndürüldüğü görülmektedir. Modelin bu bölgelere odaklanmasının en olası nedeni yetersiz eğitim örnekleridir.

5.4. Tartışma

Bu çalışmada COVID-19 ciddiyet skorlarını tahmin etmek için oluşturulan modeller arasındaki tek farklılık öznitelik çıkartma omurgasıdır. Herhangi bir görev için üstün performans sağlayan en uygun öznitelik çıkartma omurgasını bulmak son derece önemlidir. Önceden eğitilmiş ağlar tarafından oluşturulan öznitelik haritaları, genel ve karmaşık (özel) bilgilerin birleşiminden oluşmaktadır. Bu bilgiler, ek katmanlar tarafından öğrenilen görevle ilgili özniteliklerle birleştirildiğinde, performans iyileştirilebilmektedir. Bu bağlamda, çalışmada daha iyi bir kombinasyon ShuffleNet temelli model ile elde edilmektedir. Bu model, hold-out kümesi üzerinde daha iyi bir genelleme yeteneği sağlamaktadır. Tablo 5.3'te önerilen yöntem, aynı veri kümesini kullanan referans çalışmaları ile karşılaştırılmaktadır. Cohen vd. (Cohen ve diğ., 2020), ciddiyet skorlarını tahmin etmek için önceden hazır eğitimli DenseNet (Huang ve diğ., 2018) modelinden yararlanmışlardır. Model, nihai bir model oluşturmadan önce farklı veri kaynaklarından toplanan COVID-19 olmayan veri kümeleriyle eğitilmiştir. (Cohen ve diğ., 2020)'de umut verici sonuçlar elde edilmiştir. Amer vd. (Amer ve diğ., 2021) ciddiyet skorlarını tahmin etmek için derin öğrenmeye dayalı bir model önermiştir. (Amer ve diğ., 2021)'te şiddet skoru tahmininden önce, akciğerler bölütlenmektedir. Çalışmada bölütlere ayrılmış akciğerlerden sadece akciğer tutulum skorları tahmin edilmektedir. Tablo 5.3'ten görüldüğü gibi önerilen yöntemle referans çalışmalara göre RMSE, MAE ve R^2 metrikleri anlamında karşılaştırılabilir sonuçlar elde edilmektedir.

Tablo 5.3. Çalışmada elde edilen sonuçların aynı veri kümesi kullanan referans çalışmalar ile karşılaştırılması

Çalışma	Geçerleme yöntemi	Test kümesi	Parametre	RMSE	MAE	R^2
(Cohen ve diğ., 2020)	Hold-out	50-imge	-	1,43/0,92	1,14/0,78	0,60/0,58
(Amer ve diğ., 2021)	Hold-out	50-imge	-	-	-	0,67/-
Önerilen yöntem	Hold-out	50-imge	2,19M	1,73/1,22	1,51/1,06	0,66/0,51

5.5. Değerlendirme

Tez çalışmasının bu bölümünde, COVID-19 pnömonisi şiddetini ifade eden akciğer tutulumu ve opaklık skorlarının tahmini için iki başlı bir ağ yapısı önerilmektedir. Önerilen yöntem toplam 2,19M parametreye sahip olup eldeki problemin çözümüne düşük karmaşıklıkta bir çözüm sunmaktadır. Önerilen model, hastaları daha iyi triyaj yapmanın yanı sıra yoğun bakım ünitesindeki COVID-19 hastalarında hastalık seyrinin izlenmesi için kullanılabilir. Bu çalışmanın sınırlılıklarından biri, modelin henüz kısıtlı sayıda örnekle eğitilmiş olmasıdır. Veri kümesi uzman etiketli verilerle güncellendikçe model ince ayarlı yapılarak performans iyileştirilebilir. Ayrıca, bir bölütleme ağı yönteme entegre edilerek ciddiyet skorlarının tahmininde yalnızca akciğerler kullanılabilir. Böylelikle, performans daha da iyileştirilebilir.

6. MEDİKAL GÖRÜNTÜ BÖLÜTLEME İÇİN ÖZNİTELİK ÇIKARTMA VE SINIFLANDIRMA

Otomatik akciğer bölütleme, akciğer hastalıklarının teşhisinde önemli bir aşamadır. BT veya Akciğer Grafisi (X-ışını) görüntülerinden akciğer bölgelerinin bölütlenmesi, tıp uzmanlarına verecekleri kararlarda rehberlik etmektedir. Tıbbi görüntülerdeki bölütlenmiş akciğerler, çeşitli akciğer hastalıklarıyla ilgili birçok önemli bilgiyi taşımaktadır. Bununla birlikte, bölütlenmiş akciğer bölgelerinin sınırları, kardiyomegali (Becker ve diğ., 1964), amfizem (Thurlbeck ve Müller, 1994), pnömokonyoz (Cullinan ve Reid, 2013) ve pnömotoraks (Baumann ve Noppen, 2004) gibi bazı akciğer hastalıkları hakkında ipuçları da verebilmektedir. Bu nedenle bu gibi Bilgisayar Destekli Tanı (CAD) sistemlerinin geliştirilmesi özellikle uzman sayısının yetersiz olduğu gelişmekte olan ülkeler için büyük önem taşımaktadır. Literatürde X-ışını ve BT görüntüleri kullanılarak akciğer bölgelerini bölütlemek için birçok çalışma yapılmıştır. Yapılan tüm bu çalışmalarda önerilen yöntemleri, el yapımı öznitelikleri kullanan yöntemler ve derin öğrenme temelli yöntemler olmak üzere iki kategoriye ayırmak mümkündür.

(Annangi ve diğ., 2010)'de akciğer sınırlarındaki zıtlık kullanılarak, aktif kontur modelini çalıştırmak için çok ölçekli bir kenar/köşe özelliği noktaları kümesi çıkarılmaktadır. Çalışmada 1130 klinik görüntü kullanılarak %88'lik ortalama Dice skoru elde edilmektedir. (Dai ve diğ., 2015)'da, BT görüntülerinde akciğer bölgelerini bölütlemek için Gauss Karışım Modelleri (GMMs) ile çizge kesme algoritması kullanılmaktadır. Çalışmada ön plan ve arka plan nesneleri GMM'ler kullanılarak modellenmektedir. Her pikselin ön plan veya arka plan nesnesi olma olasılığı *Beklendik Enbüyükleme* (EM) algoritmasından yararlanılarak belirlenmektedir. Daha sonra minimum kesim teorisinden yararlanılarak bölütleme gerçekleştirilmektedir. (Dai ve diğ., 2015)'da %98.74 Dice skoru elde edilmiştir. Manuel öznitelik arama sürecinin benimsendiği (Dai ve diğ., 2015)'de umut verici sonuçlar elde edilmesine rağmen, bu yöntemlerin kullanımı bazı özel koşullarla sınırlı olmaktadır. Bu yöntemlerin performansı genellikle, yöntemlerin genelleme yeteneğini azaltabilecek önceden tanımlanmış parametrelere bağlıdır. Gerçek senaryolarda, akciğer bölgeleri çeşitli hastalıklarla ilgili farklı örüntüler içerebilmektedir. Bu nedenle, akciğerlerin verimli bir şekilde bölütlenebilmesi için hastalıklara özgü örüntüleri öğrenmek son derece önemlidir. Bu gizli örüntüler, derin öğrenmeye dayalı

yöntemlerle etkili bir şekilde öğrenilebilmektedir. Bu nedenle öğrenilen özelliklere dayalı bölütleme, yöntemlerin tıbbi görüntülerde değişen koşullara karşı gürbüzlüğünü artırmaktadır. (Souza ve diğ., 2019)'de, akciğer bölgelerini bölütlemek için iki aşamadan oluşan yama temelli otomatik bir yöntem önerilmiştir. İlk aşamada, yamalar AlexNet (Krizhevsky ve diğ., 2017) modelinden yararlanılarak sınıflandırılmaktadır. İkinci aşamada, ResNet-18 (He ve diğ., 2016) modeli akciğerlerin içindeki eksik alanları yeniden yapılandırmak için kullanılmaktadır. Çalışmada %93.56'luk bir Dice skoru elde edilmektedir. Bir diğer derin öğrenmeye dayalı yöntem (Vidal ve diğ., 2021)'da, COVID-19'lu akciğerlerin bölütlenmesi için önerilmektedir. Bu çalışmada yazarlar daha önce beyin tümörü bölütleme için eğitilmiş U-Net modeli ağırlıklarından yararlanmışlardır. Çalışmada COVID-19 hastalığı nedeniyle enfekte olan akciğerlerin bölütlenmesinde %97.61'lik bir doğruluk oranına ulaşılmaktadır. (Skourt ve diğ., 2018)'de, BT görüntüleri içindeki akciğer bölgelerini bölütlemek için U-Net modelinden yararlanılmaktadır. Çalışmada %95.02'lik Dice skoru elde edilmiştir.

Tez çalışmasının bu bölümünde, X-ışını görüntülerinde akciğerleri etkin bir şekilde bölütleyebilen düşük hesapsal yüke sahip bir yöntem geliştirilmesi amaçlanmıştır. Çalışmanın bu bölümünün temel katkıları aşağıda gibi verilmektedir.

- 7,15M parametreli derin öğrenme temelli bir bölütleme yöntemi önerilmiştir.

- Derin ve daha sığ özniteliklerin kaynaştırılarak öznitelik haritalarının sağlamlaştırılması ve bu sayede bölütleme performansının iyileştirilebilmesi için Bölüm 3'te önerilen topluluk ağı yapısı semantik bölütleme ağının kodlayıcı ağı olarak kullanılmaktadır.

- Literatürde medikal görüntülerin bölütlenmesi için yaygın olarak kullanılan U-Net (Ronneberger ve diğ., 2015) modelinde kod çözme işlemi kod çözücü aşamaları ile orantılı olarak yapılmaktadır. Kod çözücü ağın her aşamasında kodlayıcı ağından gelen semantik haritalar doğrudan beslenmektedir. Bu durum ağın veriyi kodlamadaki aşama sayısına göre model karmaşıklığını arttırmaktadır. Çalışmada topluluk ağını oluşturan her bir alt ağdan gelen semantik haritalar, model karmaşıklığını düşürmek amacıyla noktasal evrişim katmanları ile işlenerek derinlik indirgendikten sonra U-Net (Ronneberger ve diğ., 2015) modelinin aksine performansı eniyileyecek sayıda kod çözme aşamasına beslenmektedir.

- Önerilen mimari, farklı bir medikal bölütleme görevi için de geçerlenerek performansı iyileştirebildiği gösterilmektedir. Böylelikle performansta sağlanan iyileşmenin veri kümesine özel olmadığı ortaya koyulmaktadır.

- Önerilen yöntem, Viral Pnömoni, Tüberküloz ve COVID-19 hastalığı ile ilgili belirtilerin dâhil olduğu akciğer çevritleri ve görece küçük tümörlere ait çevritleri bulma performansını iyileştirmektedir.

Çalışmanın bu bölümü şu şekilde organize edilmektedir. Bölüm 6.1'de önerilen bölütleme çerçevesi tanıtılmaktadır. Bölüm 6.2'de deneysel sonuçlar sunulmaktadır. Bölüm 6.3'te elde edilen deneysel sonuçlar yorumlanmaktadır. Bölüm 6.4, elde edilen sonuçların görsel olarak değerlendirilmesine ayrılmıştır. Son olarak, Bölüm 6.5'te çalışma değerlendirilmektedir.

6.1. Önerilen Yöntem

Önerilen akciğer bölütleme çerçevesi Şekil 6.1'de verilmektedir. Önerilen yöntem, birbirine paralel çalışan üç modeli kullanan bir kodlayıcı ağından ve buna bağlı bir kod çözücü ağından oluşmaktadır. Buna göre, ağ girişine gelen bir X-ışını görüntüsü, uzamsal boyutları azaltmak ve önemli öznitelikleri çıkartmak için ilk olarak kodlayıcı ağı tarafından işlenmektedir. Daha sonra, her bir paralel ağ tarafından üretilen öznitelik haritaları, uzamsal bilgiyi kademeli olarak kurtarmak ve bir ikili akciğer maskesi oluşturmak için bir kod çözücü ağı tarafından işlenmektedir. Önerilen yöntemin ayrıntıları alt bölümlerde verilmektedir.

6.1.1. Kodlayıcı

Öznitelik çıkarma, eldeki herhangi bir görevin performansını iyileştirmek için son derece önemlidir. Uygun bir öznitelik çıkarma omurgasını bulmak ise çoğunlukla deneysel bir süreçtir. Bölüm 3'te önerilen derin öğrenme temelli topluluk modelinin (Ensemble-CVDNet) COVID-19 tespiti için sınıflandırma performansını iyileştirdiği gösterilmiştir. *Ensemble-CVDNet* mimarisinde, farklı derinliklerde ince ayarlı tek modeller, SqueezeNet (Iandola ve diğ., 2016), ShuffleNet (X. Zhang ve diğ., 2017) ve EfficientNet-B0 (M. Tan ve Le, 2020), anlamsal ve kaba özniteliklerin bir birleşimini elde etmek için kaynaştırılmaktadır. Mevcut çalışmada ise daha önce önerilen bu toplu kodlayıcı

mimarisi (Ensemble-CVDNet), akciğer bölgesindeki çeşitli anormallikler ve normalliklerle ilgili örüntüleri öğrenmesi ve etkinliği nedeniyle bazı katmanları kaldırdıktan sonra akciğer bölütleme yapısının kodlayıcı ağı olarak kullanılmaktadır. Çalışmada Ensemble-CVDNet'i oluşturan paralel ağlardan gelen aktivasyon haritalarının birleştirildiği derinlik kaynaştırma katmanından sonraki tüm katmanlar Ensemble-CVDNet'ten kaldırılmaktadır. Paralel ağlardan elde edilen öznitelik haritaları kaynaştırıldıktan sonra 2336 harita elde edilmektedir. Bu durumda kodlayıcının aşağı örnekleme faktörü 32 olduğundan, kodlayıcı çıkışından elde edilen tensör boyutu 7×7×2336 olmaktadır.

6.1.2. Kod Çözücü

Çalışmada kod çözücü ağın tasarımında, daha önce tıbbi görüntülerin bölütlenmesi için geliştirilmiş olan U-Net (Ronneberger ve diğ., 2015) mimarisinden ilham alınmaktadır. Ancak bu mimari çalışmada doğrudan kullanılmamaktadır. U-Net modelinde kodlayıcı kısmının uzamsal çözünürlüğü kademeli olarak azaltılırken, kullanılan çekirdekler kodlamanın her aşamasında kademeli olarak artırılmaktadır. Bu işlem, kod çözme aşamasında ise tersine çevrilmektedir. Öte yandan, önerilen topluluk kodlayıcı modelinde her bir kodlama aşamasında kullanılan çekirdek sayısı birbirinden farklıdır. Bunun yanında toplu kodlayıcı ağında alt örnekleme faktörü 32 olduğundan, kod çözme işlemi beş aşamada gerçekleştirilmektedir. Çalışmada hesapsal yükü düşürebilmek için her bir kod çözme aşamasında Gruplanmış Evrişim ve Noktasal Evrişim işlemlerinden yararlanılmaktadır. Buna göre, her önceki aşamada elde edilen öznitelik haritaları, sırasıyla 3×3 boyutlu çekirdeklerden oluşan Gruplandırılmış Evrişim, 1×1 boyutlu çekirdeklerden oluşan Noktasal Evrişim (Pointwise Convolution), Yığın Normalleştirme (Batch Normalization), ReLU ve 2×2 boyutlu çekirdeklerden oluşan Devrik Evrişim (Transposed Convolution) katmaları tarafından işlenmektedir. Gruplanmış Evrişim katmanlarındaki toplam grup sayısı, önceki aşamadaki derinliğe (veya kanallara) bağlı olarak belirlenmektedir. Diğer bir yandan, kod çözücü ağın ilk dört aşaması için Noktasal Evrişim ve Devrik Evrişim katmanlarında kullanılan çekirdek sayısı sırasıyla 256, 128, 64 ve 32 olarak belirlenmektedir. Ancak son aşamada elde edilen tensörü one-hot kodlanmış forma hazırlamak için 2 çekirdek kullanılmaktadır.

Her kod çözme aşamasının sonunda (son iki aşama hariç), öznitelik haritalarını önceki katmanlardan gelen daha anlamsal haritalarla birleştirmek için bir derinlik birleştirme katmanı kullanılmaktadır. Bununla birlikte, gelen haritaları doğrudan beslemek yerine (U-Net'in aksine), 1×1 boyutlu çekirdeklerden oluşan Noktasal Evrişim, Toplu Normalleştirme ve ReLU katmanları tarafından işlendikten sonra besleme yaklaşımı benimsenmiştir. Bu işlemin ardındaki ana motivasyon, aynı uzamsal çözünürlüğe sahip haritaların üretildiği toplu kodlayıcı modelinin her bir alt ağından elde edilen toplam harita sayısını (ve dolayısıyla parametre sayısını) azaltmaktır. Gerçekleştirilen işlemler, kod çözme ağının ilk iki aşamasıyla açıklanabilir. Buna göre, topluluk kodlayıcı ağının her bir alt ağı tarafından oluşturulan 14×14 boyutundaki aktivasyon haritaları ilk olarak birleştirilmektedir. Aktivasyon haritaları işlendikten sonra 14×14×256 uzaysal çözünürlükte bir tensör elde edilmektedir. Ardından bu tensör, birinci kod çözme aşamasının sonunda elde edilen tensör ile birleştirilmektedir. Sonuç olarak, 14×14×512 uzaysal çözünürlüklerdeki tensör, ikinci kod çözme aşamasının girdisi olmaktadır. Tensör, ikinci kod çözme aşamasında her biri bir çekirdeğe sahip 512 gruptan oluşan Gruplanmış Evrişim katmanı tarafından işlendikten sonra 128 kanala haritalanmaktadır. Son olarak kodlama katmanlarından gelen 28×28×128 uzamsal çözünürlüklerdeki tensör ile birleştirilerek işlemler devam ettirilmektedir.

6.2. Deneysel Sonuçlar

6.2.1. Veri Kümesi

Çalışmada açık erişimli veri kümeleri olan *V7 Darwin COVID-19-Chest-X-Ray* (veya V7 Darwin) veri kümesi ve *Tuberculosis Chest X-Ray Image* veri kümesi kullanılmaktadır. *V7 Darwin* veri kümesi, her bir imge için bölütleme maskesinin tanımlı olduğu 6500 AP/PA akciğer grafisi içermektedir. Veri kümesindeki görüntülerin uzamsal çözünürlükleri değişebilmektedir. *Tuberculosis Chest X-Ray Image* ve *V7 Darwin* veri kümelerine sırasıyla URL-9 ve URL-10'dan ulaşılabilmektedir.

Veri kümesinde 517 COVID-19 görüntüsü mevcuttur. Çalışmada COVID-19, Normal (veya Sağlıklı) ve Viral Pnömoni sınıflardan sırasıyla 422, 1602 ve 1446 örnek toplanmaktadır. *Tuberculosis Chest X-Ray Image* veri kümesi iki farklı veri setinin

Şekil 6.1. Önerilen akciğer bölütleme ağı: Ensemble-LungMaskNet (Öksüz ve diğ., 2021)

birleşiminden oluşmaktadır: Montgomery County X-Ray (veya Montgomery) ve Shenzhen X-Ray veri kümeleri. Montgomery veri kümesinde normal ve anormal olarak sırasıyla 80 ve 58 görüntü bulunurken, Shenzhen X-Ray veri kümesinde sırasıyla 326 normal ve 336 anormal görüntü bulunmaktadır. Bölütleme maskeleri ise veri kümeleriyle birlikte sağlanmaktadır. Çalışmada bu kaynaklardan 704 görüntü toplanmıştır.

6.2.2. Ön Ayarlar

Önerilen ağ, ADAM optimizer ile 10 epoch için eğitilmektedir. Öğrenme hızı, mini yığın boyutu ve L_2 düzenlileştirme gibi hiperparametreler ise sırasıyla 10^{-3}, 16 ve 5×10^{-3} olarak ayarlanmaktadır. Ağ eğitiminde aşırı uydurmayı önlemek için yatay ve dikey yansıtma ve çevirme, ölçekleme ve döndürme gibi veri çoğaltma teknikleri kullanılarak veriler her bir epoch değerinde çoğaltılmaktadır.

6.2.3. Hata Fonksiyonu

Eşitlik (6.1)'de verilen Dice hata işlevi ağın eğitilmesinde kullanılmaktadır.

$$\ell_{dice} = 1 - \frac{2\sum_{c=1}^{C} w_c \sum_{m=1}^{M} Y_{cm} T_{cm}}{\sum_{c=1}^{C} w_c \sum_{m=1}^{M} Y_{cm}^2 + T_{cm}^2}, \quad w_c = \frac{1}{\left(\sum_{m=1}^{M} T_{cm}\right)^2} \tag{6.1}$$

Eşitlik (6.1)'de, sınıfların sayısı, tahmin edilen herhangi bir sınıfın ağırlık vektörü ve yer doğrusu maskeleri, maske elemanlarının sayısı sırasıyla C, w_c, Y, T ve M olarak belirtilmektedir. Kodlayıcı ağı, akciğer bölgeleriyle zaten eğitilmiş durumda olduğundan kodlayıcı ağının tüm ağırlıkları dondurulmaktadır. Çalışmada yalnızca kod çözücü ağ ağırlıkları güncellenmektedir. Bu durum ağ eğitimini hızlandırmaktadır.

6.2.4. Performans Metrikleri

Performansı değerlendirmek için kullanılan ölçütler, ortalama doğruluk (Mean_Acc), ortalama örtüşme (Mean_IoU), çevrit F_1 puanı (Mean_BF_1), genel doğruluk (Global_Acc) ve Dice benzerlik katsayısıdır (Mean_Dice). Eşitlik (6.2)'de verilen Mean_Acc, duyarlılık anlamında doğruluğu göstermektedir. Eşitlik (6.3)'te verilen Mean_IoU, tahmin edilen maske ile yer doğrusu arasındaki örtüşme doğruluğunu ölçmektedir. Eşitlik (6.4)'te verilen Mean_BF_1 skoru, tahmin edilen çevrit ve gerçek

çevrit arasındaki örtüşmeyi ölçmesi açısından öneme sahiptir. Eşitlik (6.5)'te verilen Global_Acc, genel bölütleme doğruluğunu ölçmektedir. Son olarak, Eşitlik (6.6)'da verilen Mean_Dice, tahmin edilen maske ile karşılık gelen yer doğrusu maskesi arasındaki benzerliği ölçmektedir.

$$Mean_Acc = \frac{1}{C}\sum_{c=1}^{C}\frac{TP}{TP+FN}, \tag{6.2}$$

$$Mean_IoU = \frac{1}{C}\sum_{c=1}^{C}\frac{TP}{TP+FP+FN}, \tag{6.3}$$

$$Mean_BF_1 = \frac{2}{C}\sum_{c=1}^{C}\frac{\mathrm{Pr}ecision \times \mathrm{Re}call}{\mathrm{Pr}ecision + \mathrm{Re}call}, \tag{6.4}$$

$$Global_Acc = \frac{TP+TN}{TP+FN+TN+FP} \tag{6.5}$$

$$Mean_Dice = \frac{1}{C}\sum_{c=1}^{C}\frac{2TP}{2TP+FP+FN}, \tag{6.6}$$

6.2.5. Performans Değerlendirme

Model eğitiminde *V7 Darwin* veri kümesi kullanılmaktadır. Veri kümesinin %70'i eğitim kümesi olarak rastgele seçilmektedir. Geri kalan örnekler ise harici test seti olarak ayrılmaktadır. Çalışmada *Tuberculosis Chest X-Ray Image* (Jaeger et al. 2014; Candemir et al. 2014) veri kümesi ise diğer bir harici test seti olarak tutulmaktadır. Daha sonra, eğitim seti beş kat çapraz doğrulama gerçekleştirmek için örtüşmeyen beş alt gruba bölünmektedir. Aşırı uydurmayı kontrol etmek için ilgili eğitim katlarındaki örneklerin rastgele olarak seçilen %10'luk bölümü geçerleme kümesi olarak ayrılmaktadır. Çapraz geçerlemeden sonra en iyi performans gösteren model belirlenerek ayrılan test kümesi üzerinde değerlendirilmektedir.

6.2.6. Ablasyon Çalışması

Bu bölümde, toplu kodlayıcı mimarisinin akciğer bölütleme görevi üzerindeki etkinliği ortaya koyulmaktadır. Bu amaçla, ilk olarak Şekil 6.1'de verilen önerilen ağ mimarisinde

önceki kodlayıcı katmanlarından gelen anlamsal haritalar göz ardı edilerek beş kod çözme aşamasından oluşan bir kod çözücü ağı oluşturulmaktadır. Tekli kodlayıcı ağların performanslarını görmek için oluşturulan kod çözücü ağ sırasıyla SqueezeNet, ShuffleNet ve EfficientNet-B0 modellerine bağlanarak bölütleme ağları elde edilmektedir. Ardından, oluşturulan kod çözücü yapısı ilk olarak SqueezeNet'in ShuffleNet ile birleştirilmesi ile oluşturulan toplu kodlayıcı yapısına bağlanarak Ensemble-LungMaskNet#1 olarak adlandırılan bölütleme modeli elde edilmektedir. Sonrasında Ensemble-LungMaskNet#1 modelinde kodlayıcı yapısına EfficientNet-B0 modelinin dâhil edilmesiyle Ensemble-LungMaskNet#2 adı verilen diğer bir bölütleme modeli elde edilmektedir. Her bir mimari ile elde edilen bölütleme sonuçları Tablo 6.1'de verilmektedir. Tablo 6.1'den görüldüğü gibi, tekli mimariler kullanılarak oluşturulan bölütleme ağları arasında en iyi sonuçlar ShuffleNet modeli semantik bölütleme ağının kodlayıcı ağı olarak kullanıldığında elde edilmektedir. Buna göre ShuffleNet temelli bölütleme ağı ile Global_Acc, Mean_Acc, Mean_IoU, Mean_Dice ve Mean_BF_1 ölçümleri anlamında sırasıyla verilen %5.08, %6.65, %9.44, %8.23 ve %9.28 oranlar ile daha sığ SqueezeNet temelli bölütleme ağından daha iyi bir performans elde edilmektedir.

Öte yandan, ShuffleNet temelli bölütleme ağı ile Global_Acc, Mean_Acc, Mean_IoU, Mean_Dice ve Mean_BF_1 ölçümleri anlamında sırasıyla %0.65, %1.35, %1.38, %1.42 ve %2.54 ile daha derin EfficientNet-B0 temelli bölütleme ağından daha iyi bir performans elde edilmektedir. Bu durum, ShuffleNet'in eldeki görev için en uygun ağ derinliğini sağladığını göstermektedir. Bununla birlikte, SqueezeNet'in öznitelikleri, yetersiz derinliği nedeniyle piksel sınıflandırması için tatmin edici düzeyde ayırt ediciliğe sahip değildir. Daha derin EfficientNet-B0 temelli bölütleme modeli ile piksel sınıflandırması için daha ayırt edici öznitelikler çıkarılsa dahi, EfficientNet-B0 kodlayıcı yapısının derinliğine bağlı olarak bazı anlamsal bilgiler kaybolabilmektedir. Bu bağlamda, SqueezeNet ve ShuffleNet modellerinin tümleştirilmesi ile oluşturulan Ensemble-LungMaskNet#1 modeli performansı ShuffleNet temelli oluşturulan bölütleme ağı karşısında tüm ölçümlerin ortalaması anlamında %0.26 (Global_Acc: %0.37, Mean_Acc: %-0.03, Mean_IoU: %0.60, Mean_Dice: %0.19, Mean_BF_1: %0.20) artırmaktadır. Ayrıca, EfficientNet-B0 modelinin *Ensemble-LungMaskNet#1* kodlayıcı yapısına dâhil edilerek oluşturulan *Ensemble-LungMaskNet#2*, performansı tüm skorların ortalaması anlamında ShuffleNet temelli bölütleme ağı karşısında %1.77 (Global_Acc: %1.27,

Tablo 6.1. Toplu kodlayıcı mimarisinin bölütleme performansı üzerindeki etkisi. Sonuçlar %95 güven aralığı ile verilmektedir (Öksüz ve diğ., 2021)

Model	Metrik	Fold-1 485 imge	Fold-2 486 imge	Fold-3 486 imge	Fold-4 486 imge	Fold-5 486 imge	*Avg.*
SqueezeNet (1,12M)	*Global_Acc (%)*	88,18 ±2,87	87,29 ±2,96	87,85 ±2,90	88,13 ±2,87	88,13 ±2,87	*87,91* ±1,29
	Mean_Acc (%)	86,81 ±3,01	85,32 ±3,14	86,89 ±3,00	85,34 ±3,14	86,37 ±3,05	*86,14* ±1,37
	Mean_IoU (%)	76,81 ±3,75	75,09 ±3,84	76,39 ±3,77	76,03 ±3,79	76,50 ±3,76	*76,16* ±1,69
	Mean_Dice (%)	81,96 ±3,42	80,10 ±3,55	81,95 ±3,41	80,20 ±3,54	81,21 ±3,47	*81,08* ±1,55
	Mean_BF_1 (%)	66,20 ±4,20	63,93 ±4,27	66,78 ±4,18	63,82 ±4,27	65,62 ±4,22	*65,27* ±1,89
ShuffleNet (1,40M)	*Global_Acc (%)*	92,97 ±2,27	92,88 ±2,28	93,34 ±2,21	93,52 ±2,18	92,25 ±2,37	*92,99* ±1,01
	Mean_Acc (%)	92,74 ±2,30	92,88 ±2,87	93,31 ±2,22	92,96 ±2,27	92,09 ±2,39	*92,79* ±1,02
	Mean_IoU (%)	85,60 ±3,12	85,46 ±3,13	86,32 ±3,05	86,43 ±3,04	84,21 ±3,24	*85,60* ±1,39
	Mean_Dice (%)	89,24 ±2,75	89,40 ±2,73	89,96 ±2,67	89,57 ±2,71	88,39 ±2,84	*89,31* ±1,22
	Mean_BF_1 (%)	74,99 ±3,85	74,32 ±3,88	75,96 ±3,79	74,88 ±3,85	72,61 ±3,96	*74,55* ±1,73
EfficientNet-B0 (4,76M)	*Global_Acc (%)*	92,38 ±2,36	92,31 ±2,37	92,51 ±2,34	92,46 ±2,34	92,08 ±2,40	*92,34* ±1,05
	Mean_Acc (%)	91,67 ±2,45	91,19 ±2,52	91,10 ±2,53	92,24 ±2,37	91,03 ±2,54	*91,44* ±1,11
	Mean_IoU (%)	84,39 ±3,23	84,14 ±3,25	84,42 ±3,22	84,52 ±3,21	83,67 ±3,28	*84,22* ±1,44
	Mean_Dice (%)	88,19 ±2,87	87,75 ±2,91	87,69 ±2,92	88,54 ±2,83	87,29 ±2,96	*87,89* ±1,29
	Mean_BF_1 (%)	72,57 ±3,97	71,95 ±3,99	70,96 ±4,03	73,14 ±3,94	71,47 ±4,01	*72,01* ±1,78
Ensemble-LungMaskNet#1 (2,13M)	*Global_Acc (%)*	93,31 ±2,22	93,23 ±2,23	93,48 ±2,19	93,58 ±2,17	93,21 ±2,23	*93,36* ±0,99
	Mean_Acc (%)	92,57 ±2,33	93,31 ±2,22	92,76 ±2,30	92,77 ±2,30	92,40 ±2,35	*92,76* ±1,03
	Mean_IoU (%)	86,11 ±3,07	86,14 ±3,07	86,43 ±3,04	86,49 ±3,03	85,84 ±3,09	*86,20* ±1,37
	Mean_Dice (%)	89,41 ±2,73	89,92 ±2,67	89,57 ±2,71	89,60 ±2,71	89,03 ±2,77	*89,50* ±1,21
	Mean_BF_1 (%)	74,72 ±3,86	75,24 ±3,84	75,07 ±3,84	74,65 ±3,86	74,07 ±3,89	*74,75* ±1,72
Ensemble-LungMaskNet#2 (6,63M)	*Global_Acc (%)*	94,10 ±2,09	94,55 ±2,02	94,23 ±2,07	93,96 ±2,11	94,48 ±2,03	*94,26* ±0,92
	Mean_Acc (%)	93,51 ±2,19	93,54 ±2,18	93,78 ±2,14	93,64 ±2,16	93,81 ±2,14	*93,65* ±0,96
	Mean_IoU (%)	87,65 ±2,92	88,41 ±2,84	87,92 ±2,89	87,32 ±2,95	88,31 ±2,85	*87,92* ±1,29
	Mean_Dice (%)	90,68 ±2,58	90,70 ±2,58	90,87 ±2,56	90,35 ±2,62	91,08 ±2,53	*90,73* ±1,15
	Mean_BF_1 (%)	77,27 ±3,72	77,15 ±3,73	77,93 ±3,68	77,51 ±3,71	78,01 ±3,68	*77,57* ±1,65

Tablo 6.2. Ensemble-LungMaskNet#2 modelinin kod çözme aşamalarına dâhil edilen kodlayıcı semantik haritalarının bölütleme performansı üzerindeki etkisi. Sonuçlar %95 güven aralığı ile verilmektedir (Öksüz ve diğ., 2021)

Model	Metrik (%)	Fold-1 485 imge	Fold-2 486 imge	Fold-3 486 imge	Fold-4 486 imge	Fold-5 486 imge	*Avg.*
Kod çözme aşama#1 14×14 harita (7,04M)	*Global_Acc*	95,73 ±1,79	96,12 ±1,71	96,11 ±1,72	96,08 ±1,72	96,12 ±1,71	*96,03* ±0,77
	Mean_Acc	95,64 ±1,81	95,72 ±1,80	95,39 ±1,86	95,33 ±1,87	95,50 ±1,84	*95,51* ±0,82
	Mean_IoU	90,95 ±2,55	91,67 ±2,45	91,59 ±2,46	91,46 ±2,48	91,60 ±2,46	*91,45* ±1,11
	Mean_Dice	93,35 ±2,21	93,42 ±2,20	92,98 ±2,27	93,04 ±2,26	93,22 ±2,23	*93,20* ±1,00
	Mean_BF$_1$	85,09 ±3,17	85,04 ±3,17	84,10 ±3,25	84,58 ±3,21	85,14 ±3,16	*84,79* ±1,42
Kod çözme aşama #2 28×28 harita 7,13M	*Global_Acc*	96,45 ±1,64	96,62 ±1,60	96,62 ±1,60	96,58 ±1,61	96,36 ±1,66	*96,52* ±0,72
	Mean_Acc	95,98 ±1,74	95,92 ±1,76	96,49 ±1,63	96,11 ±1,71	95,92 ±1,75	*96,08* ±0,77
	Mean_IoU	92,33 ±2,36	92,65 ±2,32	92,73 ±2,30	92,53 ±2,33	92,12 ±2,39	*92,47* ±1,04
	Mean_Dice	93,72 ±2,15	93,86 ±2,13	94,18 ±2,08	93,89 ±2,12	93,45 ±2,19	*93,82* ±0,95
	Mean_BF$_1$	88,19 ±2,87	87,95 ±2,89	88,79 ±2,80	87,66 ±2,92	88,23 ±2,86	*88,16* ±1,28
Kod çözme aşama #3 56×56 harita (7,15M)	*Global_Acc*	96,35 ±1,66	96,77 ±1,57	96,96 ±1,52	96,62 ±1,60	96,55 ±1,62	*96,65* ±0,71
	Mean_Acc	96,14 ±1,71	96,03 ±1,73	96,37 ±1,66	96,41 ±1,65	96,40 ±1,65	*96,27* ±0,75
	Mean_IoU	92,17 ±2,39	92,95 ±2,27	93,37 ±2,21	92,65 ±2,32	92,55 ±2,33	*92,73* ±1,03
	Mean_Dice	93,95 ±2,12	94,02 ±2,11	94,32 ±2,05	94,12 ±2,09	94,18 ±2,08	*94,11* ±0,93
	Mean_BF$_1$	87,94 ±2,89	88,40 ±2,85	89,16 ±2,76	88,73 ±2,81	88,39 ±2,84	*88,52* ±1,26
Kod çözme aşama #4 112×112 harita (7,16M)	*Global_Acc*	96,31 ±1,67	96,70 ±1,58	96,59 ±1,61	96,26 ±1,68	96,61 ±1,60	*96,49* ±0,73
	Mean_Acc	96,23 ±1,69	95,99 ±1,74	96,31 ±1,67	96,37 ±1,66	96,42 ±1,65	*96,26* ±0,75
	Mean_IoU	92,10 ±2,40	92,81 ±2,29	92,64 ±2,32	91,96 ±2,41	92,67 ±2,31	*92,43* ±1,05
	Mean_Dice	93,92 ±2,12	94,09 ±2,09	94,05 ±2,10	93,76 ±2,15	94,19 ±2,07	*94,00* ±0,94
	Mean_BF$_1$	88,20 ±2,87	88,46 ±2,84	87,84 ±2,90	87,43 ±2,94	88,95 ±2,78	*88,17* ±1,28

Mean_Acc: %0.86, Mean_IoU: %2.32, Mean_Dice: 1.42, Ortalama_BF_1: %3.02) artırmaktadır. Sonuçlar, farklı derinliklere sahip tekli ağların öznitelik haritalarının kaynaştırılmasının, ince taneli ve kaba taneli öznitelikleri dâhil ederek bölütleme performansını artırdığını göstermektedir. Elde edilen *Ensemble-LungMaskNet#2* modelinin toplam parametre yükü ise 6.63M'dir. Kodlayıcı ağının önceki katmanlarından kod çözücü ağına semantik haritaların beslenmesinin bölümleme performansını iyileştirebileceği iyi bilinmektedir. Bu nedenle, *Ensemble-LungMaskNet#2*'nin bölütleme performansını iyileştirebilmek için kodlayıcı bölümündeki anlamsal haritalar kod çözme bölümüne aktarılmaktadır. Bununla birlikte, anlamsal haritaların doğrudan kodlayıcı ağının aynı uzamsal çözünürlükte haritalarının elde edildiği bir kod çözme aşamasına beslendiği U-Net ve SegNet mimarilerinden farklı olarak, sırasıyla her bir kod çözme aşamasına anlamsal haritaların beslenmesi ile en iyi performansın elde edildiği ağ mimarisi belirlenmektedir. Tablo 6.2'de her bir mimari ile elde edilen sonuçlar sunulmaktadır. Tablo 6.2'den görüldüğü gibi, anlamsal haritalar ilk kod çözme aşamasına dâhil edildiğinde (Kod çözme aşama#1), Global_Acc, Mean_Acc, Mean_IoU, Mean_Dice ve ortalama BF_1 puanları sırasıyla %1.77, %1.86, %3.53, %2.47 ve %7.22 oranında iyileşmektedir. Ayrıca, anlamsal haritaların ilk ve ikinci kod çözme aşamalarına dâhil edilmesi Global_Acc, Mean_Acc, Mean_IoU, Mean_Dice ve Mean_BF_1 metrikleri anlamında performansta %0.49, %0.57, %1.02, %0.62 ve %3.37 iyileşme elde edilmektedir. Bununla birlikte, Tablo 6.2'den görülebileceği gibi, anlamsal haritalar üçüncü kod çözme aşamasına dâhil edildiğinde, Global_Acc, Mean_Acc, Mean_IoU, Mean_Dice ve Mean_BF_1 metrikleri anlamında performans yalnızca %0.13, %0.19, %0.26, %0.29 ve %0.36 iyileşmektedir. Anlamsal haritaların bir sonraki kod çözme aşamasına (Kod çözme aşama#4) aktarılması ise bölütleme performansını düşürmektedir. Bu nedenle mimari, anlamsal haritaları dördüncü ve beşinci kod çözme aşamalarına beslemeksizin sonlandırılmaktadır. Elde edilen nihai model Ensemble-LungMaskNet (önerilen yöntem) olarak adlandırılmıştır. Anlamsal haritaların ardışık üç kod çözme aşamasında (Kod çözme aşama#1, kod çözme aşama#2, kod çözme aşama#3) Ensemble-LungMaskNet#2 modeline beslenmesi yalnızca 0.52M parametre yükü getirmektedir. Bununla birlikte, toplu kodlayıcı mimarisi ve anlamsal haritaların ilgili kod çözme aşamalarına beslenmesi ile toplam performans Global_Acc, Mean_Acc, Mean_IoU, Mean_Dice ve Mean_BF_1 metrikleri anlamında sırasıyla %3.66, %3.48, %7.13, %4.80

ve %13.97 oranları ile önemli ölçüde iyileştirilmektedir. Böylelikle, önerilen yöntemin toplam parametre yükü 7,15M olmaktadır. Deneylerde, önerilen bölütleme ağında noktasal evrişimli birimlerin kullanılmamasının etkisi de ayrıca değerlendirilmiştir. Bu amaçla, noktasal evrişimli birimler, her biri 3×3 boyutlu çekirdeğe sahip klasik evrişim birimleri ile değiştirilmektedir. Sonuç olarak, bu düzenleme ağın toplam parametre yükünü 16.41M'ye getirmektedir. Bu durumda elde edilen performans ise Global_Acc, Mean_Acc, Mean_IoU, Mean_Dice ve Mean_BF1 anlamında sırasıyla %0.03, %0.24, %0.09, %1.86 ve %0.09 oranlarında düşmektedir. Şekil 6.2'de ise önerilen yöntemin performans değerlendirme süreci özetlenmektedir. Şekil 6.2'te her bir test katında elde edilen normalize edilmiş karışıklık matrislerinin yanı sıra, harici test kümeleri üzerinde (yani *V7 Darwin* ve *Tuberculosis Chest X-Ray*) elde edilen karışıklık matrisleri de verilmektedir. Buna göre, yöntemin *V7 Darwin* veri kümesinde çapraz gerçeleme ve hold-out geçerlemesi ile benzer yanlış negatif oranlarının (sırasıyla %5 ve %6) elde edildiği görülmektedir. Öte yandan, *Tuberculosis Chest X-Ray Image* test kümesi üzerinde önerilen yöntemin yanlış negatif oranı %8 olarak elde edilmektedir. Yanlış negatif oranı, V7 Darwin veri kümesinden ayrılan test kümesi üzerinde elde edilen orandan daha yüksek olmasına rağmen, bu veri kümesinden hiçbir örneğin model eğitimi aşamasında kullanılmadığına dikkat edilmelidir. Bu durum, önerilen modelin *Tuberculosis Chest X-Ray Image* veri kümesi için akciğer bölgesi piksellerinin %92 duyarlılıkla sınıflandırdığı anlamına gelmektedir. Şekil 6.3'te, çalışmada elde edilen sonuçları özetleyen bir çubuk grafiği verilmektedir.

6.3. Tartışma

Bu çalışmada, önerilen model geniş bir veri kümesinden rastgele seçilen sağlıklı durumların yanı sıra viral pnömoni, COVID-19 pnömonisi gibi hastalıklara ait örüntüleri de içeren *V7 Darwin* veri kümesinden ayrılan bir eğitim kümesi üzerinde eğitilmektedir. Daha sonra önerilen model, bu veri kümesinden ayrılan nispeten büyük bir harici test kümesinde (1041 görüntü) geçerlenmektedir. Dünya genelinde farklı makinelerden elde edilen görüntüler toplanarak oluşturulan veri kümeleri önemli farklılıklar içerebilmektedir.

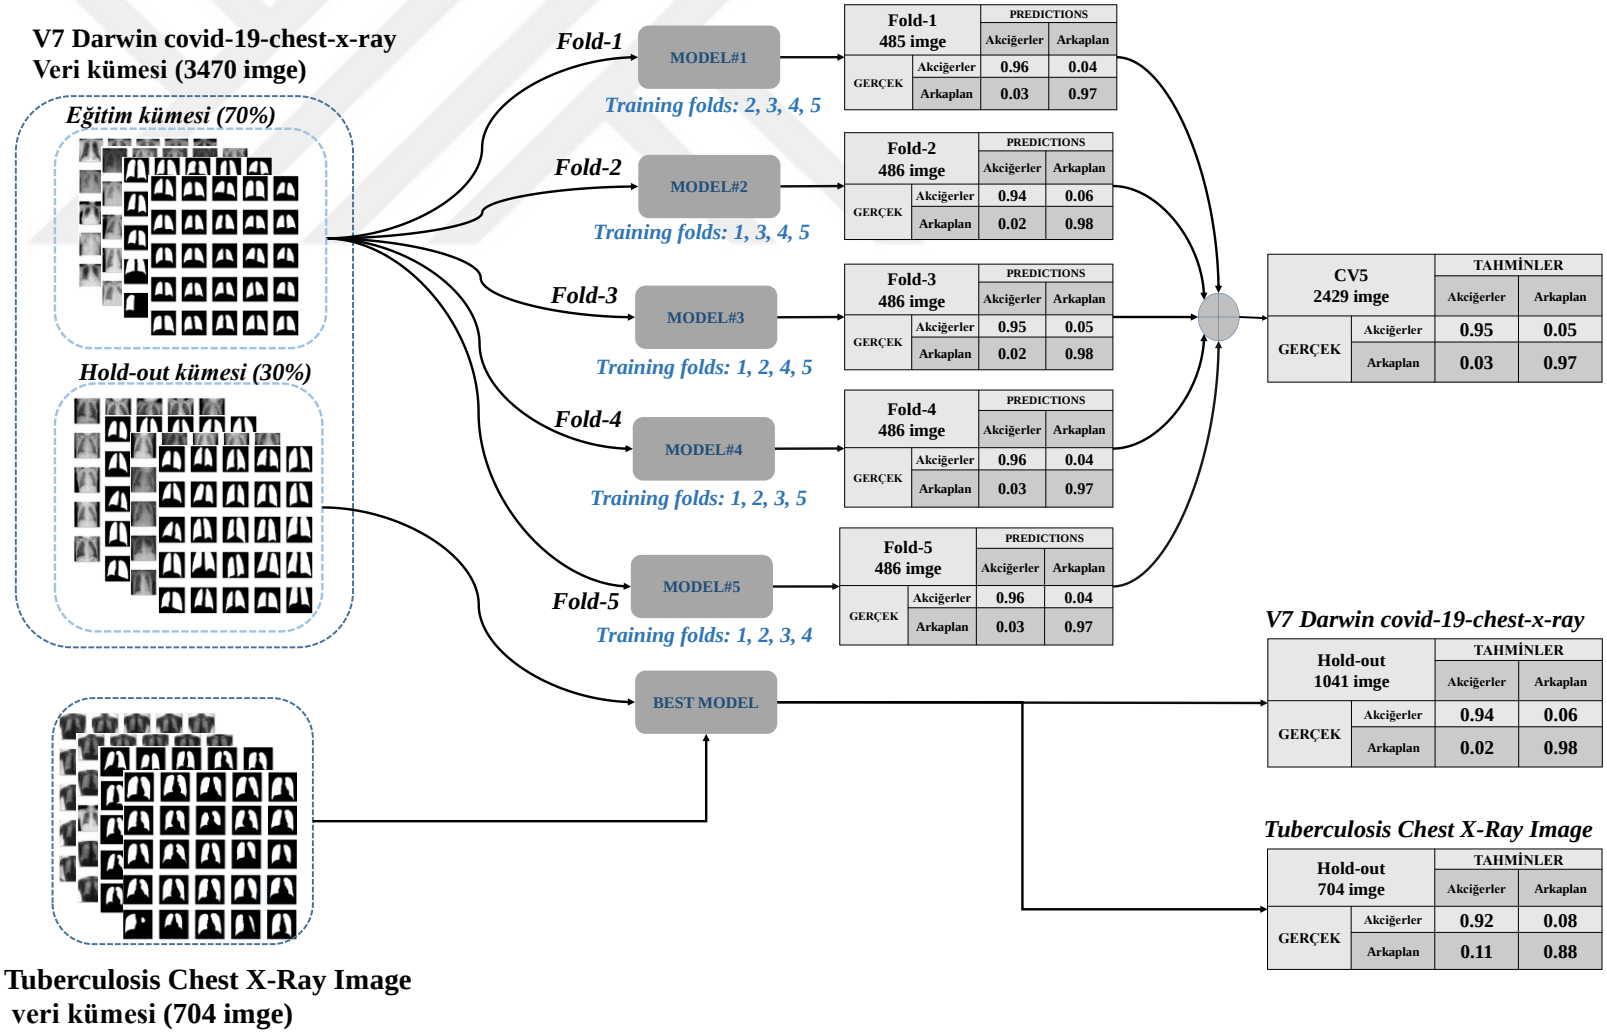

Şekil 6.2. Önerilen bölütleme ağının açık erişimli veri setleri üzerinde geçerleme süreci (Oksuz ve diğ., 2021)

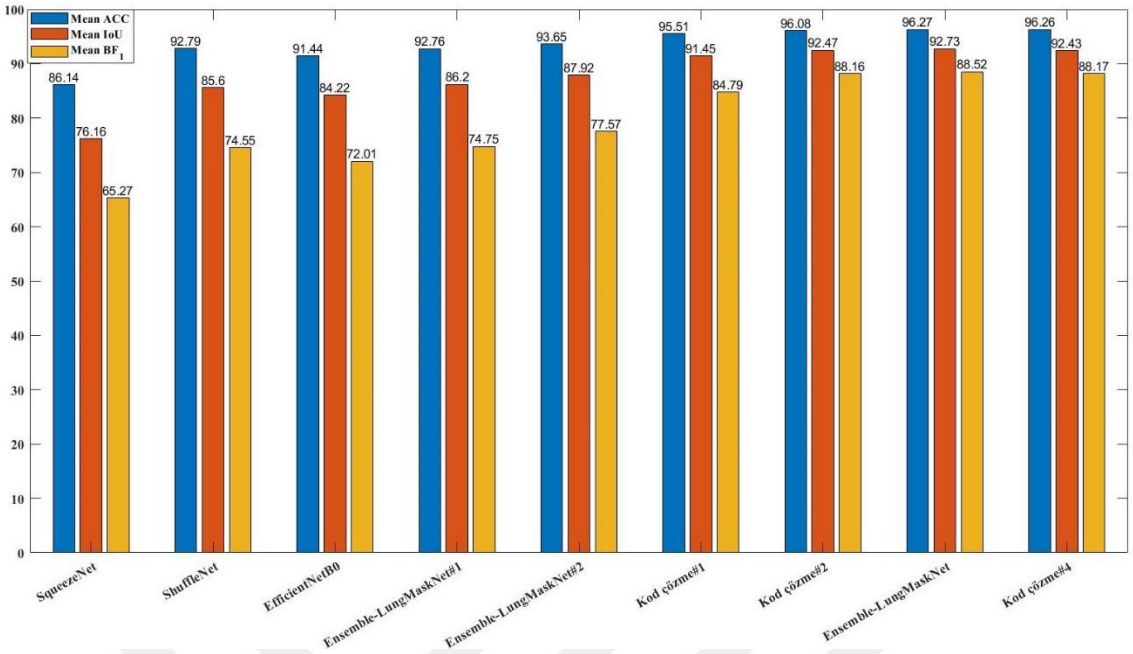

Şekil 6.3. Çalışma kapsamında kullanılan yöntemlerin karşılaştırılması

Bu nedenle eğitilen modelin, farklı bir dağılımdan gelen veri kümeleri üzerindeki genelleme yeteneğini görmek amacıyla model eğitiminde kullanılmayan Tuberculosis Chest X-Ray Image Data set veri kümesi üzerinde de test edilmiştir. Tablo 6.3 ve Tablo 6.4'te, yöntem aynı veri kümelerini kullanan referans çalışmaları ile karşılaştırılmaktadır. Yöntem Tablo 6.3'te ilk olarak V7 Darwin veri setinin kullanıldığı referans çalışmaları ile karşılaştırılmıştır

Tablo 6.3. Bölütleme performansının *V7 Darwin* veri kümesini kullanan referans çalışmaları ile karşılaştırılması (Öksuz ve diğ., 2021)

Çalışmalar	Geçerleme Yöntemi	Test Kümesi Boyutu	Global_Acc	Mean_Acc	Mean_IoU	Mean_Dice	Mean_BF_1
(A. Zhang, 2020)	Hold-out	132 imge	-	-	86,66	92,73	-
(Abdulah ve diğ., 2021)	Hold-out	204 imge	-	96,00	-	96,00	-
Önerilen yöntem	Hold-out	1041 imge	96,70 ±1,08	96,01 ±1,18	92,79 ±1,57	93,86 ±1,45	88,70 ±1,92
	CV-5	2429 imge	96,65 ±0,71	96,27 ±0,75	92,73 ±1,03	94,11 ±0,93	88,52 ±1,26

. (A. Zhang, 2020)'te, dört aşamadan oluşan U-Net modeli (yani 16 kat aşağı örnekleme) akciğer bölgelerini bölütlemek için herhangi bir modifikasyon yapılmadan kullanılmıştır. Açıklanan mimariye göre, modelin toplam parametreleri yaklaşık 31M'dir. (Abdulah ve diğ., 2021)'te birbirini izleyen iki birimden oluşan bir çerçeve tasarlanmıştır. İlk birim akciğerlerin bölütlenmesinden sorumluyken, diğer birim COVID-19 hastalığının

saptanmasından sorumludur. İki birimin performansı (Abdulah ve diğ., 2021)'deki çalışmada ayrı olarak değerlendirilmektedir. Geliştirilen ağ parametrelerinin toplam sayısı ise 59.16k olarak açıklanmaktadır (Abdulah ve diğ., 2021).Tablo 6.4'te önerilen yöntem (A. Singh ve diğ., 2021)'te verilen referans çalışma ile karşılaştırılmıştır. (A. Singh ve diğ., 2021)'te MobileNetv2 ve ResNet-18 modellerinin iskelet model olarak kullanıldığı iki farklı Deeplabv3+ temelli bölütleme ağı önerilmektedir. (A. Singh ve diğ., 2021)'te önerilen her bir bölütleme ağının kodlayıcısı, giriş görüntülerinin 16 kat alt örneklemesini gerçekleştirecek şekilde ayarlanmıştır. Ağların toplam parametreleri (A. Singh ve diğ., 2021)'te verilmemiş olsa da, açıklanan mimarilere bağlı olarak, MobileNetv2 tabanlı model için toplam parametre yaklaşık 6.8M'dir ve ResNet-18 temelli model için yaklaşık 20.6M olduğu söylenebilir. Çalışmada, Montgomery veri kümesi, Shenzhen veri kümesi, JSRT veri kümesi (Shiraishi ve diğ., 2000) ve açık erişimli olmayan (in-house) bir veri kümesi kullanılmıştır (A. Singh ve diğ., 2021). Toplanan örneklerin %30'u test kümesi olarak ayrılmıştır. Çalışmada her bir veri kümesi için performans ölçümleri sağlanmaktadır. *Tuberculosis Chest X-Ray Image* veri kümesi, *Montgomery* ve *Shenzhen* veri kümelerinden oluştuğu için, Tablo 6.4'te Montgomery ve Shenzhen veri kümeleri üzerinde elde edilen sonuçların ortalaması verilmektedir.

Tablo 6.4. Bölütleme performansının *Tuberculosis Chest X-Ray Image* veri kümesini kullanan referans çalışmalarla karşılaştırılması (Öksüz ve diğ., 2021)

Çalışma	Geçerleme Yöntemi	Test Kümesi Boyutu	ACC_{global}	ACC_{mean}	IoU	Dice	BF_1
(A. Singh ve diğ., 2021)	Hold-out	≈240 imge	98,70	97,58	96,73	92,37	-
Önerilen yöntem	Hold-out	704 imge	89,25 ±2,28	90,21 ±2,19	77,15 ±3,10	80,63 ±2,91	73,87 ±3,24

(A. Zhang, 2020), (Abdulah, 2021) ve (A. Singh ve diğ., 2021)'te önerilen yöntemlerin temel sınırlaması, nispeten küçük test kümelerinde geçerlenmiş olmalarıdır. Test kümesi boyutu arttıkça performansın düşebileceği bilinmektedir. Tablo 6.3'te verilen sonuçlara göre, önerilen yöntemin nispeten büyük bir test kümesi üzerindeki (1041 görüntü) performansı, elde edilen beş kat çapraz doğrulama performansı ile tutarlıdır. *Tuberculosis Chest X-Ray Image* veri kümesinden eğitimde yer alan görseller olmasa da önerilen model referans çalışmayla uyumlu sonuçlar vermektedir. Bu durum, önerilen yöntemin farklı

dağılımlardan gelen akciğerleri de bölütlere ayırabildiğini göstermektedir. Tüm bunlar, önerilen yöntemin genelleme yeteneğini göstermektedir.

Söz edilmesi gereken bir diğer önemli faktör de model karmaşıklıklarıdır. (A. Zhang, 2020)'te neden dört aşamadan oluşan bir U-Net modelinin benimsendiği açık değildir. U-Net modelinde kodlayıcı/kod çözücü aşamalarının sayısının azaltılması ve artırılması, model karmaşıklığını büyük ölçüde etkileyecektir. Diğer bir ifadeyle, 3 aşamalı bir U-Net modeli için 7M parametreli ve 5 aşamalı bir U-Net modeli için 124M parametreli bir model elde edilebilir. (Abdulah ve diğ., 2021)'te, düşük hesaplama yüküne sahip bir ağ önerilmiştir, ancak bölütleme görevlerinde yaygın olarak kullanılan Global_Acc, BF_1, IoU için elde edilen skorlar sağlanmamıştır. Benzer şekilde (A. Singh ve diğ., 2021)'te DeepLabv3+ temelli ağların neden 8 kat veya 32 kat aşağı örnekleme yerine 16 kat aşağı örnekleme yapacak şekilde oluşturulduğu açık değildir. Bu çalışmalar karşısında, tez çalışmasının bu bölümünde ise akciğer bölütleme görevinin performansını optimize etmek için CV-5 performansında düşüşe neden olan ve parametre yükünü artırabilecek gereksiz kısımlar kaldırılarak en uygun ağ yapısı belirlenmiştir.

6.3.1. Önerilen yapının farklı bir medikal bölütleme görevinde geçerlenmesi

Bu bölümde, akciğer bölütleme performansını optimize etmek için önerilen ağ yapısının farklı bir medikal bölütleme problemi üzerindeki performansı değerlendirilmektedir. Tez çalışması kapsamında beyin tümörleri de konu alındığından önerilen mimari, Bölüm 2.1.1'de tanıtılan *Brain tumor* (Cheng, 2017) veri kümesi üzerinde çapraz geçerlenmektedir. Bu amaçla, *Brain tumor* (Cheng, 2017) veri kümesinde bulunan 233 hastanın tamamı kullanılmıştır. Verilen hasta seviyesinde çapraz geçerleme indislerinden yararlanılarak veri örtüşmeyen beş ayrı eğitim ve test kümelerine ayrılmaktadır. Karşılaştırmayı sadeleştirebilmek adına yalnızca *Mean ACC*, *Mean IoU* ve *Mean* BF_1 metrikleri için elde edilen beş kat çapraz gerçeleme skorları Şekil 6.4'teki çubuk grafiğinde verilmektedir.

Şekil 6.4'ten görüldüğü gibi tekli mimarilerden derin model EfficientNet-B0'a kıyasla sığ model ShuffleNet ile daha iyi bir performans elde edilmektedir. Bu durum, ağ derinliğine bağlı olarak bölütleme için bir takım anlamsal özniteliklerin derin ağda sönümlendiğini göstermektedir. Derin ağda sönümlenen bilgilerin telafi edilmesi için bir

sığ ve bir derin ağın tümleştirilmesi ile oluşturulan *Ensemble-LungMaskNet#1* modeli, tek kodlayıcılı bölütleme ağlarından daha iyi bir performans vermektedir. Buna göre, *Ensemble-LungMaskNet#1* ile performans tüm metriklerin ortalaması anlamında ShuffleNet'e göre %0.70, EfficientNet-B0'a göre ise %2.83 iyileşmektedir. Bölütleme ağının topluluk kodlayıcı yapısına daha sığ model SqueezeNet'in tümleştirilmesi ile oluşturulan *Ensemble-LungMaskNet#2* ağı, performansı *Ensemble-LungMaskNet#1*'e kıyasla tüm metriklerin ortalaması anlamında %1.16 iyileştirmektedir.

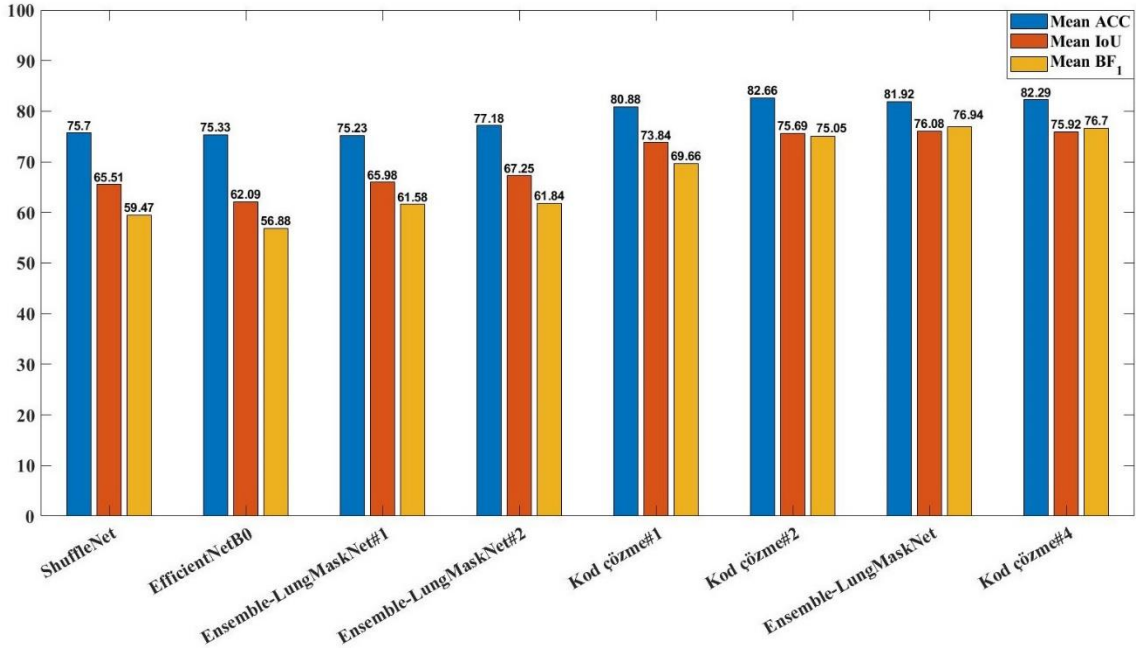

Şekil 6.4. Çalışma kapsamında geliştirilen bölütleme modellerinin *Brain tumor* (Cheng, 2017) veri kümesi üzerindeki performanslarının karşılaştırması

Ardından *Ensemble-LungMaskNet#2* ağının topluluk kodlayıcısını oluşturan paralel ağların her birinden elde edilen semantik haritalar, kod çözme aşamalarına sırasıyla beslenmektedir. Buna göre, anlamsal haritaların Şekil 6.1'de verilen *kod çözme aşama#1*'e beslenmesi performansı %6.03 iyileştirirken, ilk iki aşama (*kod çözme aşama#1 ve kod çözme aşama#2*) ve ilk üç aşamaya beslenmesi ise performansı sırasıyla %9.04 ve %9.55 iyileştirmektedir. Diğer bir yandan, anlamsal haritalar ilk dört aşamaya beslendiğinde performansta elde edilen iyileşme (%9.54) önceki aşamaya göre daha fazla bir iyileşme sağlamamaktadır. Böylelikle, beyin tümörlerinin bölütlenmesi görevinde de en iyi performans, akciğer bölütleme görevinde olduğu gibi *Ensemble-LungMaskNet* yapısı kullanıldığında elde edilmektedir. Elde edilen sonuçlar, önerilen mimarinin

yalnızca akciğerlerin bölütlenmesinde değil aynı zamanda farklı bir medikal bölütleme görevinde de performansı iyileştirebildiğini ortaya koymaktadır.

6.4. Görselleştirme

Bu bölümde önerilen yöntemin akciğerler ve beyin tümörlerini bölütlenmesine ilişkin içerdiği örnek çıktılar, oluşturulan ShuffleNet temelli bölütleme ağının çıktıları ile karşılaştırmalı olarak sırasıyla Şekil 6.5 ve Şekil 6.6'da verilmektedir. Şekil 6.5 ve Şekil 6.6'nın (b) sütununda verilen yer doğruları, (a) sütunundaki X-ışını görüntülerine karşılık gelmektedir. Tahmin edilen bölütleme maskeleri, ShuffleNet temelli model için (c) sütununda ve önerilen model için (d) sütununda verilmektedir. Şekil 6.5 ve Şekil 6.6'nın (d) sütunlarında, gerçek çevrit kırmızı ile gösterilirken, tahmin edilen çevrit ShuffleNet temelli model için yeşil, önerilen yöntem için ise mavi olarak verilmektedir. Şekil 6.5'in (a) sütunundaki ilk üç görüntünün COVID-19 vakaları, sonraki iki görüntünün ise Viral Pnömoni vakaları ve sonuncusunun sağlıklı bir vaka olduğunu belirtmekte fayda bulunmaktadır. Şekil 6.5'te önerilen yöntemin akciğer sınırlarının belirgin olmaması, kablo gibi bir tıbbi donanımın akciğer grafisinde görünürlüğü (üçüncü görüntü) ve görüntü içerisinde bulunan diğer istenmeyen nesneler (ikinci görüntüdeki oklar gibi) gibi bölütleme görevini zorlaştıran durumları başarılı bir şekilde ele alabildiği görülmektedir. Diğer bir yandan, yöntemin beyin tümörlerinin bölütlenmesine ilişkin döndürdüğü Şekil 6.6'da verilen örnek bölütleme çıktıları incelendiğinde, tek kodlayıcılı modele kıyasla orijinal tümör çevritine daha yakın çevritlerin elde edildiği görülmektedir. Tek kodlayıcılı bölütleme modeli ile daha kaba sınırlar elde edilirken, kodlayıcı yapısı topluluk modeli olan ağ (önerilen yöntem) ile yanlış pozitifler azaltılarak görece küçük tümörler (birinci ve beşinci satırlar) dahi yakalanabilmektedir.

6.5. Değerlendirme

Akciğerlerin bölütlenmesi için tasarlanmış ve görüntü başına birçok yanlış pozitif üreten herhangi bir uzman sistem, uzman müdahalesi gerektireceğinden tam otomatik bir sistem olmaktan uzak olacaktır. Bu nedenle uzmanların günlük rutinlerini devralacak tam otomatik bir uzman sistem tasarlamak, yüksek performansın elde edilebilmesine bağlıdır. Tasarlanan herhangi bir sistemin hesaplama yükü ise gerçek senaryolarda uygulanabilirliğinin bir başka faktörüdür.

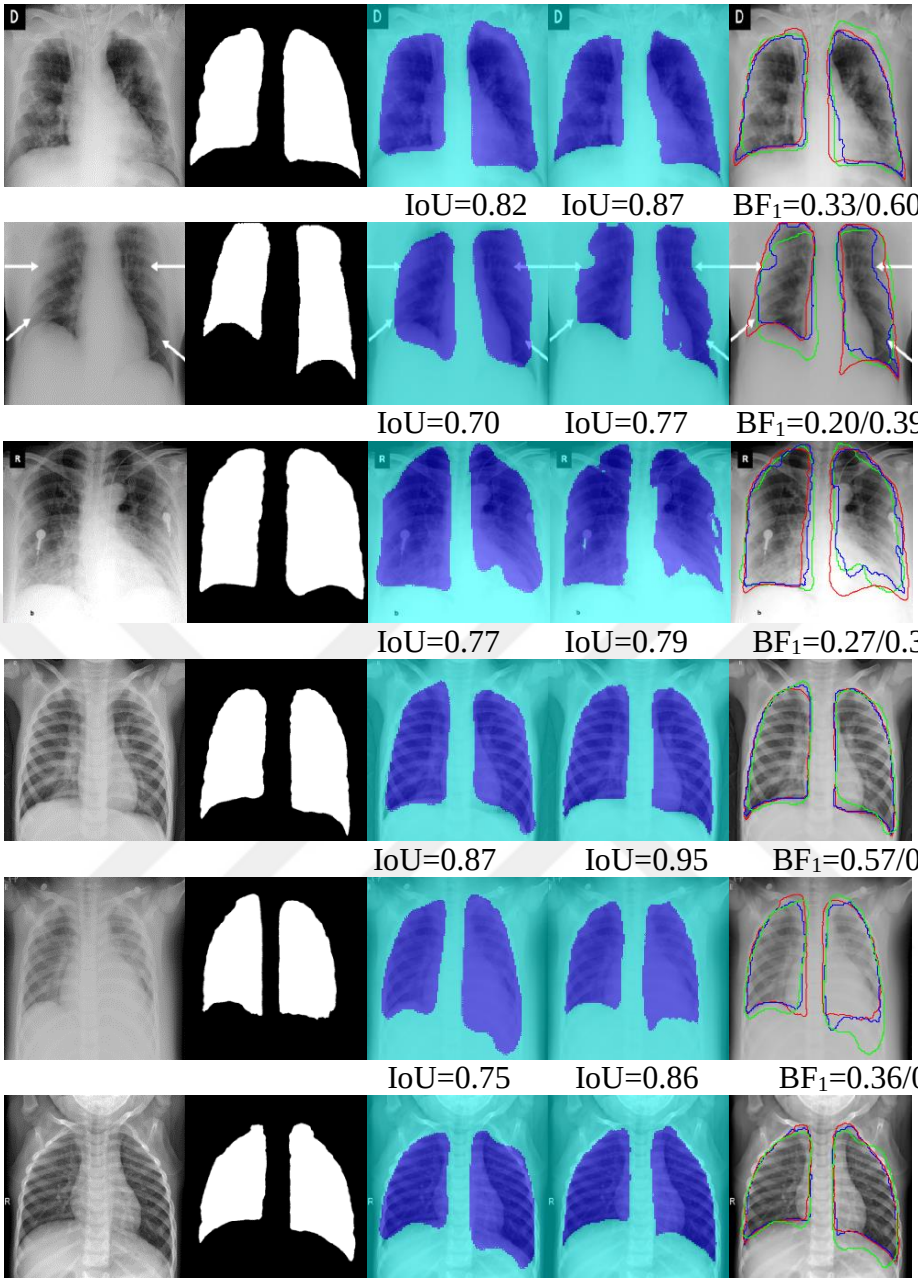

Şekil 6.5. Akciğerlerin bölütlenmesine ait yöntem çıktıları. Orijinal görüntüler (a) sütununda, karşılık gelen temel gerçekler ise (b) sütununda verilmiştir. Bölütleme çıktıları ShuffleNet temelli bölütleme ağı için (c) sütununda, önerilen yöntem için ise (d) sütununda için verilmiştir. Her yöntem tarafından tahmin edilen sınırlar karşılaştırmalı olarak sütun (e)'de verilmiştir. (e)'deki kırmızı ile verilen sınırlar gerçek çevriti göstermektedir. (e)'deki yeşil olarak verilen sınırlar ShuffleNet temelli mimariye aitken mavi ile verilen sınırlar ise önerilen yönteme aittir. Tahmin edilen skorlar da görsellerin altında verilmiştir. Eğik çizgiden sonra verilen çevrit eşleştirme puanları (veya BF_1) önerilen yönteme aittir (Öksüz ve diğ., 2021)

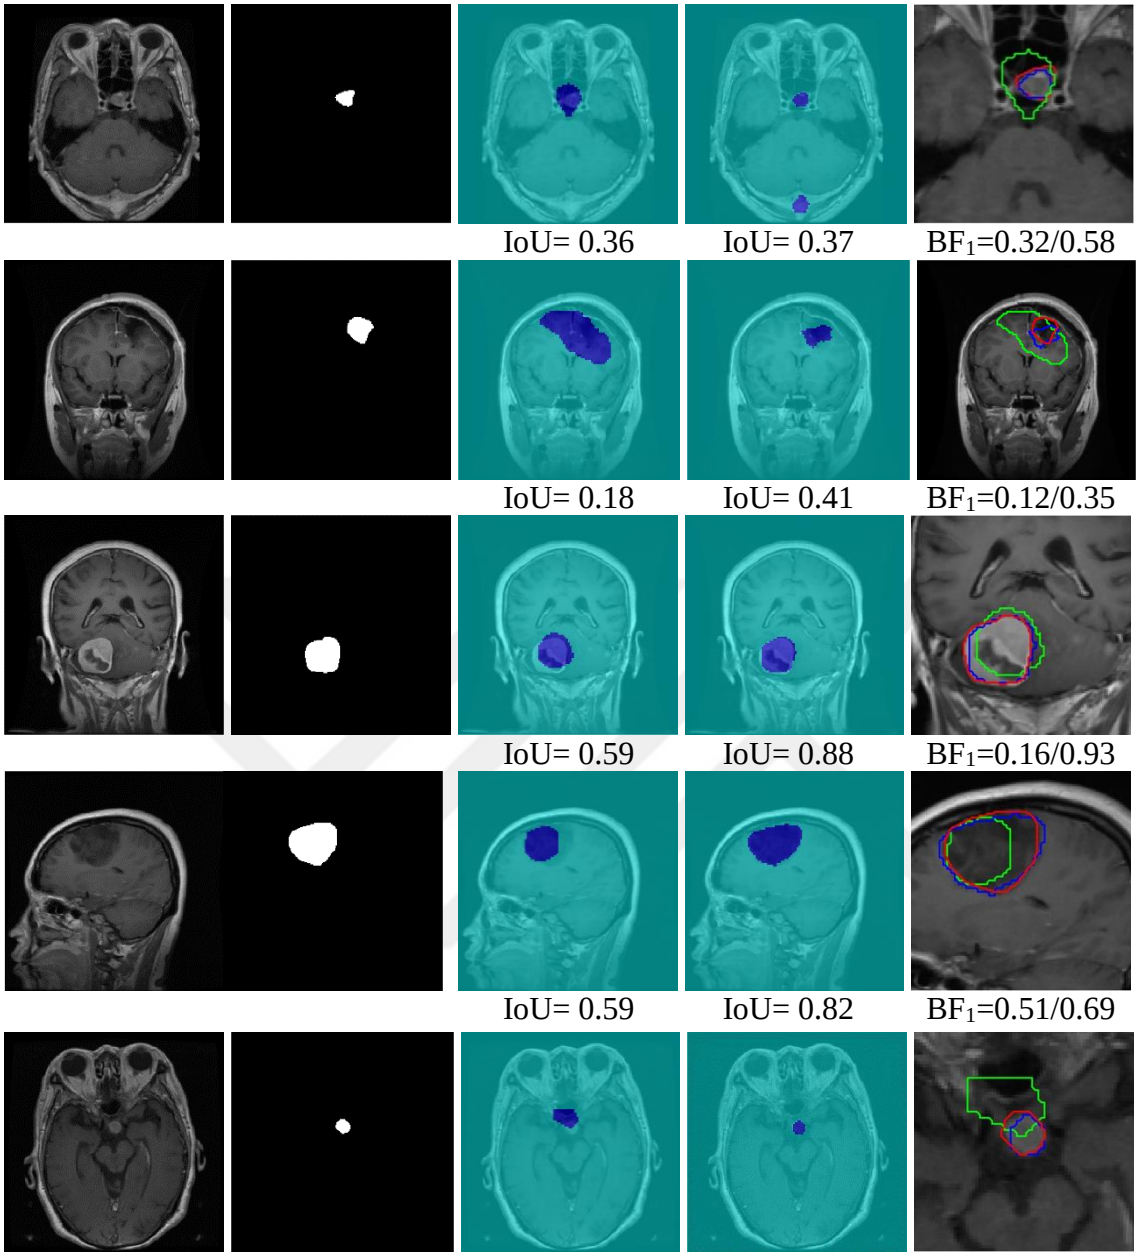

Şekil 6.6. Beyin tümörlerinin bölütlenmesine ilişkin yöntem örnek çıktıları. Orijinal görüntüler (a) sütununda, karşılık gelen yer doğruları ise (b) sütununda verilmektedir. Bölütleme çıktıları ShuffleNet temelli bölütleme ağı için (c) sütununda, önerilen yöntem için ise (d) sütununda için verilmektedir. Her bir yöntem tarafından tahmin edilen sınırlar karşılaştırmalı olarak sütun (e)'de verilmektedir. (e)'deki kırmızı ile verilen sınırlar gerçek çevriti, yeşil olarak verilen sınırlar ShuffleNet temelli mimariye aitken mavi ile verilen sınırlar ise önerilen yönteme aittir. Tahmin edilen skorlar da görsellerin altında verilmiştir. Eğik çizgiden sonra verilen çevrit eşleştirme puanları (veya BF_1) önerilen yönteme aittir

Bu bağlamda, bu çalışmada 7,15M parametreli derin öğrenme temelli bir akciğer bölütleme çerçevesi önerilmektedir. Deneysel sonuçlar, topluluk ağları ile oluşturulan kodlayıcı ağın anlamsal bölütleme performansında önemli bir iyileşme sağladığını göstermektedir. Deneysel sonuçlarda gösterildiği gibi X-ışını görüntüsünde akciğerlerin sınırları COVID-19 ve Viral Pnömoni gibi hastalıklar nedeniyle ortadan kalkmış olsa da önerilen yöntemin akciğerleri yine de başarılı bir şekilde bölütleyebildiği görülmektedir. Dahası, önerilen mimarinin farklı bir medikal bölütleme görevi üzerinde geçerlenmesi ile elde edilen sonuçlar iyileşen performansın veri kümesine özel olmadığını ortaya koymaktadır. Önerilen yöntem, ilgilenilen bölge (ROI) temelli sınıflandırmayı benimseyen yöntemlere ROI sağlamak için kullanılabilir. Ayrıca kalp, damar bölütleme gibi diğer medikal bölütleme görevlerine de uyarlanabilir.

7. SONUÇLAR VE ÖNERİLER

Radyomik veri, uzmanlar tarafından verilecek kararlara ikinci bir görüş sağlayabilmek adına son yıllarda tıbbın birçok alanında yaygın olarak kullanılmaktadır. Çeşitli hastalıklara ait örüntüler içeren tıbbi görüntülerden çıkartılan radyomikler, hastalıkların belirlenmesinde, hastalıkların altında yatan nedenlerin daha iyi anlaşılmasında, hastalık seyrinin izlenmesinde ve doğru tedavi planlamasının yapılmasında ayırt edici bir bilgi ortaya koymaktadır. Bu açıdan son yıllarda ortaya çıkan kişiselleştirilmiş tıp için de radyomikler paha biçilemez bir niteliğe sahiptir. Üstelik tıbbi görüntülerden çıkartılan radyomikler ile geliştirilen yarı otomatik ve tam otomatik modeller, hastalıkların teşhisinde invasif olmayan yöntemler sunarak risk, maliyet gibi etkenleri düşürmekte ve zamandan tasarruf sağlamaktadır. Bu tez çalışması kapsamında tıbbi görüntülerden derin öğrenme temelli radyomiklerin çıkartıldığı özgün yöntemler önerilmiştir. Tez çalışmasının ikinci ve beşinci bölümleri arasındaki sunulan yöntemlerde, temelde derin ve sığ öznitelikleri kaynaştırmak üzere geliştirilmiş olan gözetimli öğrenme yapıları tanıtılmaktadır. Çalışmanın ikinci bölümünde derin öğrenilen öznitelikler temelli klasik makine öğrenimi sınıflandırması gerçekleştirilmiştir. Beyin tümörlerinin konu alındığı ikinci bölümdeki çalışmada, tümör çevre dokuları ROI'ye dâhil edilerek derin ve sığ ESA yapılarından çıkartılan radyomikler kaynaştırıldığında performansta dikkate değer bir artışın sağlandığı ortaya koyulmuştur. COVID-19 hastalığının X-Işını görüntülerinden tespitinin konu alındığı üçüncü bölümdeki çalışmada derin öğrenme temelli sınıflandırma gerçekleştirilmektedir. Bu bağlamda ince taneli, kaba taneli ve daha kaba taneli soyut öznitelik haritalarının kaynaştırılmasını sağlayacak hafif derin bir topluluk modeli önerilmiştir. Önerilen topluluk modeli ile COVID-19 vakalarının tespitinin yanı sıra hastalığın hafif ve ağır formlarının belirlenmesinde literatürdeki mevcut yöntemlerden daha üstün bir performans elde edilmiştir. Dahası, önerilen topluluk yapısı tez çalışmasının beşinci bölümünde akciğerleri otomatik olarak bölütleyecek bir yapıya dönüştürülmüştür. Kodlayıcı bölümü bir topluluk ağı olan modelin literatürdeki mevcut diğer yöntemlerden ve tekli ağ yapılarından daha iyi bir performans sağladığı gösterilmiştir. COVID-19 hastalığına ait şiddet skorlarının tahmininin hedeflendiği dördüncü bölümdeki çalışmada performansı optimize edecek derin öğrenme radyomiklerinin elde edildiği ağ yapısı belirlenmiştir. Böylelikle elde edilen hafif ağırlıklı model ile literatürdeki mevcut yöntemler karşısında üstün sonuçlar elde edilmiştir.

Tez çalışmasının beşinci bölümünde önerilen bölütleyici model ince ayar stratejisi ile beyin tümörlerinin bölütlemesi görevine uyarlanabilir. Böylelikle elde edilen yapı ikinci bölümde beyin tümörlerinin sınıflandırılması için önerilen çatıya ROI sağlayarak tam otomatik bir sistem elde edilebilir. Benzer şekilde, Bölüm 5'te akciğerlerin bölütlenmesi için önerilen ağ yapısı, Bölüm 2'de önerilen topluluk ağ yapısına ve Bölüm 3'te önerilen COVID-19 hastalığı şiddet skoru tahmin ağına ROI sağlayarak modellerin yalnızca ilgilenilen bölgelere odaklanması sağlanabilir. Böylelikle, hastalıklara ilişkin önemli imzalar yakalanabilecektir. Bununla birlikte, tek bir hata işlevi üzerinden eğitilebilen çok görevli bir ağ yapısı oluşturularak ROI çıkartma, şiddet skoru tahmini ve sınflandırma gibi görevler tümleştirilebilir. Tez çalışması kapsamında yalnızca gözetimli öğrenmenin benimsendiği yöntemler önerilmiştir. Medikal alanda sınırlı sayıda etiketli örneğin olması, son zamanlardaki eğilim olan yarı gözetimli öğrenme yaklaşımlarını son derece ilgi çekici hale getirmektedir. Gelecek çalışmalarda bu konular üzerinde durulması hedeflenmektedir.

KAYNAKLAR

Abbas, A., Abdelsamea, M. M., & Gaber, M. M. (2021). Classification of COVID-19 In Chest X-Ray Images Using Detrac Deep Convolutional Neural Network. *Applied Intelligence, 51*(2), 854-864.

Abdulah, H., Huber, B., Lal, S., Abdallah, H., Palese, L. L., Soltanian-Zadeh, H., & Gatti, D. L. (2021). CXR-Net: An Artificial Intelligence Pipeline for Quick Covid-19 Screening of Chest X-Rays. *arXiv preprint arXiv:2103.00087*.

Abiwinanda, N., Hanif, M., Hesaputra, S. T., Handayani, A., & Mengko, T. R. (2018). Brain Tumor Classification Using Convolutional Neural Network. *World Congress On Medical Physics and Biomedical Engineering 2018*, Prague, Czech Republic, 3-8 Haziran 2018.

Afshar, P., Mohammadi, A., & Plataniotis, K. N. (2018). Brain Tumor Type Classification Via Capsule Networks. *25th IEEE International Conference on Image Processing (ICIP)*, Athens, Greece, 7-10 Ekim 2018.

Afshar, P., Plataniotis, K. N., & Mohammadi, A. (2019). Capsule Networks for Brain Tumor Classification Based on MRI Images and Coarse Tumor Boundaries. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Brighton, UK, 12-17 Mayıs 2019.

Akkus, Z., Ali, I., Sedlář, J., Agrawal, J. P., Parney, I. F., Giannini, C., & Erickson, B. J. (2017). Predicting Deletion of Chromosomal Arms 1p/19q in Low-Grade Gliomas from MR Images Using Machine Intelligence. *Journal of Digital Imaging, 30*(4), 469-476.

Alcantarilla, P. F., Bartoli, A., & Davison, A. J. (2012). KAZE Features. *European Conference on Computer Vision*. Florence, Italy, 7-13 Ekim 2012.

Fridadar, M., Amer, R., Gozes, O., Nassar, J., & Greenspan, H. (2021). COVID-19 in CXR: From Detection and Severity Scoring to Patient Disease Monitoring. *IEEE Journal of Biomedical and Health Informatics*, *25*(6), 1892 - 1903.

Andén, J., & Mallat, S. (2014). Deep Scattering Spectrum. *IEEE Transactions on Signal Processing, 62*(16), 4114-4128.

Annangi, P., Thiruvenkadam, S., Raja, A., Xu, H., Sun, X., & Mao, L. (2010). A Region Based Active Contour Method for X-Ray Lung Segmentation Using Prior Shape And Low Level Features. *IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, Rotterdam, Netherlands, 14-17 Nisan 2010.

Arezzo, F., Loizzi, V., La Forgia, D., Moschetta, M., Tagliafico, A. S., Cataldo, V., ... & Cormio, G. (2021). Radiomics Analysis in Ovarian Cancer: A Narrative Review. *Applied Sciences, 11*(17), 7833.

Arimura, H. (2017). *Image-Based Computer-Assisted Radiation Therapy* (1st ed.). Singapore: Springer Singapore.

Bauer, S., Wiest, R., Nolte, L. P., & Reyes, M. (2013). A Survey of MRI-Based Medical Image Analysis for Brain Tumor Studies. *Physics in Medicine & Biology*, *58*(13), R97.

Baumann, M. H., & Noppen, M. (2004). Pneumothorax. *Respirology*, *9*(2), 157-164.

Bay, H., Ess, A., Tuytelaars, T., & Van Gool, L. (2008). Speeded-up Robust Features (SURF). *Computer Vision and Image Understanding*, *110*(3), 346-359.

Becker, H. C., Nettleton, W. J., Meyers, P. H., Sweeney, J. W., & Nice, C. M. (1964). Digital Computer Determination of a Medical Diagnostic Index Directly from Chest X-Ray Images. *IEEE Transactions on Biomedical Engineering*, *BME-11* (3), 67-72.

Bengio, Y., Delalleau, O., & Le Roux, N. (2006). The Curse of Highly Variable Functions for Local Kernel Machines. *Advances in neural information processing systems*, *18*, 107.

Brock, A., De, S., Smith, S. L., & Simonyan, K. (2021). High-Performance Large-Scale Image Recognition Without Normalization. *arXiv preprint arXiv:2102.06171*.

Brunese, L., Mercaldo, F., Reginelli, A., & Santone, A. (2020). Explainable Deep Learning for Pulmonary Disease And Coronavirus COVID-19 Detection from X-rays. *Computer Methods and Programs in Biomedicine*, *196*, 105608.

Cancer Genome Atlas Research Network. (2015). Comprehensive, Integrative Genomic Analysis of Diffuse Lower-Grade Gliomas. *New England Journal of Medicine*, *372*(26), 2481-2498.

Candemir, S., Jaeger, S., Palaniappan, K., Musco, J. P., Singh, R. K., Xue, Z., ... & McDonald, C. J. (2013). Lung Segmentation In Chest Radiographs Using Anatomical Atlases With Nonrigid Registration. *IEEE Transactions on Medical Imaging*, *33*(2), 577-590.

Cha, S. (2006). Update on Brain Tumor Imaging: From Anatomy to Physiology. *American Journal of Neuroradiology*, *27*(3), 475–87.

Cheng, J. (2017). *Brain Tumor Dataset*. Figshare, https://doi.org/10.6084/m9.figshare.1512427.v5, (Ziyaret Tarihi: 1 Ekim 2019).

Cheng, J., Wei, H., Shuangliang, C., Ru, Y., Wei, Y., Zhaoqiang, Y., Zhijian, W., Qianjin, F. (2015). Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition. Edited by Daoqiang Zhang. *PLOS ONE*, *10*(10), e0140381. https://doi.org/10.1371/journal.pone.0140381.

Chowdhury, M. E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., ... & Islam, M. T. (2020). Can AI help in Screening Viral and COVID-19 Pneumonia?. *IEEE Access*, *8*, 132665-132676.

Chung, C., Metser, U., & Ménard, C. (2015). Advances in Magnetic Resonance Imaging and Positron Emission Tomography Imaging for Grading and Molecular Characterization of Glioma. *Seminars in Radiation Oncology*, *25*(3), 164-171.

Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., ... & Prior, F. (2013). The Cancer Imaging Archive (TCIA): Maintaining and Operating A Public Information Repository. *Journal of Digital Imaging*, *26*(6), 1045-1057.

Clarke, R., Ressom, H. W., Wang, A., Xuan, J., Liu, M. C., Gehan, E. A., & Wang, Y. (2008). The Properties of High-Dimensional Data Spaces: Implications For Exploring Gene And Protein Expression Data. *Nature Reviews Cancer*, *8*(1), 37-49.

Cohen, J. P., Dao, L., Roth, K., Morrison, P., Bengio, Y., Abbasi, A. F., ... & Duong, T. (2020). Predicting COVID-19 Pneumonia Severity on Chest X-Ray with Deep Learning. *Cureus*, *12*(7).

Cohen, J. P., Morrison, P., Dao, L., Roth, K., Duong, T. Q., & Ghassemi, M. (2020). COVID-19 Image Data Collection: Prospective Predictions Are the Future. *arXiv preprint arXiv:2006.11988*.

Cortes, C., Vladimir, V. (1995). Support-Vector Networks. *Machine Learning*, *20*(3), 273–97. https://doi.org/10.1007/BF00994018.

National Research Council. (2011). *Toward precision medicine: building a knowledge network for biomedical research and a new taxonomy of disease* (1st ed.), Washington (DC): National Academies Press (US).

Cozzi, D., Albanesi, M., Cavigli, E., Moroni, C., Bindi, A., Luvarà, S., ... & Miele, V. (2020). Chest X-ray in New Coronavirus Disease 2019 (COVID-19) Infection: Findings and Correlation with Clinical Outcome. *La radiologia medica*, *125*, 730-737.

Csurka, G., Dance, C., Fan, L., Willamowski, J., Bray, C. (2004). Visual Categorization with Bags of Keypoints. *Workshop on Statistical Learning in Computer Vision (ECCV)*, Prague, Czech, Mayıs 15, 2004.

Cullinan, P., Peter, R. (2013). Pneumoconiosis. *Primary Care Respiratory Journal*, *22*(2), 249–52. https://doi.org/10.4104/pcrj.2013.00055.

Dai, S., Lu, K., Dong, J., Zhang, Y., & Chen, Y. (2015). A Novel Approach of Lung Segmentation On Chest CT Images Using Graph Cuts. *Neurocomputing*, *168*, 799-807.

Dalal, N., & Triggs, B. (2005). Histograms of Oriented Gradients for Human Detection. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, San Diego, CA, USA, 20-25 Haziran 2005.

Decuyper, M., Bonte, S., Deblaere, K., & Van Holen, R. (2020). Automated MRI Based Pipeline for Glioma Segmentation and Prediction of Grade, IDH Mutation and 1p19q Co-Deletion. *arXiv preprint arXiv:2005.11965*.

Deepak, S., & Ameer, P. M. (2019). Brain Tumor Classification Using Deep CNN Features Via Transfer Learning. *Computers in biology and medicine*, *111*, 103345.

Desai, S., Baghal, A., Wongsurawat, T., Jenjaroenpun, P., Powell, T., Al-Shukri, S., ... & Prior, F. (2020). Chest Imaging Representing a COVID-19 Positive Rural US Population. *Scientific Data*, *7*(1), 1-6.

Doi, K. (2005). Current Status and Future Potential of Computer-Aided Diagnosis in Medical Imaging. *The British Journal of Radiology*, *78*(suppl_1), s3-s19.

Doi, K. (2007). Computer-Aided Diagnosis in Medical Imaging: Historical Review, Current Status and Future Potential. *Computerized medical imaging and graphics*, *31*(4-5), 198-211.

El Abbadi, N. K., & Kadhim, N. E. (2017). Brain Cancer Classification Based on Features and Artificial Neural Network. *Brain*, *6*(1), 123-134.

El Naqa, I., Grigsby, P. W., Apte, A., Kidd, E., Donnelly, E., Khullar, D., ... & Deasy, J. O. (2009). Exploring Feature-Based Approaches in PET Images for Predicting Cancer Treatment Outcomes. *Pattern recognition*, *42*(6), 1162-1171.

El-Dahshan, E. S. A., Hosny, T., & Salem, A. B. M. (2010). Hybrid Intelligent Techniques for MRI Brain Images Classification. *Digital signal processing*, *20*(2), 433-441.

Engle Jr, R. L. (1992). Attempts to Use Computers as Diagnostic Aids in Medical Decision Making: A Thirty-Year Experience. *Perspectives in biology and medicine*, *35*(2), 207-219.

Erickson, B., Akkus, Z., Sedlar, J., Korfiatis, P. (2017). *Data from LGG-1p19qDeletion*. TCIA, https://doi.org/10.7937/K9/TCIA.2017.DWEHTZ9V, (Ziyaret Tarihi: 1 Ekim 2020).

Erickson, B. J., Korfiatis, P., Akkus, Z., Kline, T., & Philbrick, K. (2017). Toolkits and Libraries for Deep Learning. *Journal of digital imaging*, *30*(4), 400-405.

Farooq, M., & Hafeez, A. (2020). Covid-resnet: A Deep Learning Framework for Screening of Covid19 from Radiographs. *arXiv preprint arXiv:2003.14395*.

Fellah, S., Caudal, D., De Paula, A. M., Dory-Lautrec, P., Figarella-Branger, D., Chinot, O., ... & Girard, N. (2013). Multimodal MR Imaging (Diffusion, Perfusion, And Spectroscopy): Is It Possible to Distinguish Oligodendroglial Tumor Grade and 1p/19q Codeletion in the Pretherapeutic Diagnosis?. *American Journal of Neuroradiology*, *34*(7), 1326-1333.

Freund, Y., & Schapire, R. E. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of computer and system sciences*, *55*(1), 119-139.

Galloway, M. M. (1975). Texture Analysis Using Gray Level Run Lengths. *Computer graphics and image processing*, *4*(2), 172-179.

Gao, J., Jiang, Q., Zhou, B., & Chen, D. (2019). Convolutional Neural Networks for Computer-Aided Detection or Diagnosis in Medical Image Analysis: An Overview. *Mathematical Biosciences and Engineering*, *16*(6), 6536-6561.

Gao, Y., Cai, G. Y., Fang, W., Li, H. Y., Wang, S. Y., Chen, L., ... & Gao, Q. L. (2020). Machine Learning Based Early Warning System Enables Accurate Mortality Risk Prediction for COVID-19. *Nature communications*, *11*(1), 1-10.

Ge, C., Gu, I. Y. H., Jakola, A. S., & Yang, J. (2018). Deep Learning and Multi-Sensor Fusion for Glioma Classification Using Multistream 2D Convolutional Networks. *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Honolulu, HI, USA, 18-21 Temmuz 2018.

Ghassemi, N., Shoeibi, A., & Rouhani, M. (2020). Deep Neural Network with Generative Adversarial Networks Pre-Training for Brain Tumor Classification Based On MR Images. *Biomedical Signal Processing and Control*, *57*, 101678.

Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep Learning* (1st ed.). Cambridge, Massachusetts: The MIT Press.

Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). Textural Features for Image Classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.

Hastie, T., Tibshirani, R., Friedman, J. H. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). New York, NY: Springer.

Hawkins, S., Wang, H., Liu, Y., Garcia, A., Stringfield, O., Krewer, H., ... & Gillies, R. J. (2016). Predicting Malignant Nodules from Screening CT Scans. *Journal of Thoracic Oncology*, *11*(12), 2120-2128.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference On Computer Vision and Pattern Recognition*. Las Vegas, NV, USA, 27-30 Haziran 2016.

Heaton, J. (2016). An Empirical Analysis of Feature Engineering for Predictive Modeling. *SoutheastCon 2016*, Norfolk, VA, USA, 30 Mart-3 Nisan 2016.

Hodson, R. (2016). Precision Medicine. *Nature*, *537*(7619), S49-S49.

Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *IEEE Conference On Computer Vision and Pattern Recognition*. Honolulu, HI, USA, 21-26 Temmuz 2017.

Huang, J. (2020). *RMSProp*. Cornell University, https://optimization.cbe.cornell.edu/index.php?title=RMSProp, (Ziyaret Tarihi: 1 Aralık 2021)

Huber, P. J. (1964). Robust Estimation of a Location Parameter. *The Annals of Mathematical Statistics, 35*(1), 73–101. https://doi.org/10.1214/aoms/1177703732.

Hui, T. C., Khoo, H. W., Young, B. E., Mohideen, S. M. H., Lee, Y. S., Lim, C. J., ... & Tan, C. H. (2020). Clinical Utility of Chest Radiography for Severe COVID-19. *Quantitative imaging in medicine and surgery*, *10*(7), 1540.

Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016). SqueezeNet: Alexnet-Level Accuracy with 50x Fewer Parameters and< 0.5 MB Model Size. *arXiv preprint arXiv:1602.07360*.

Hochreiter, S., Bengio, Y., Frasconi, P., & Schmidhuber, J. (2001). Gradient Flow in Recurrent Nets: The Difficulty of Learning Long-Term Dependencies. Kremer, S., Kolen, J. F. (eds), *A Field Guide to Dynamical Recurrent Networks* (1st ed.) (237-243). Wiley-IEEE Press.

Ioffe, S., Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *International Conference on Machine Learning*, Lille, France, 7-9 Temmuz 2015.

Iqbal, S., Khan, M. U. G., Saba, T., & Rehman, A. (2018). Computer-Assisted Brain Tumor Type Discrimination Using Magnetic Resonance Imaging Features. *Biomedical Engineering Letters*, *8*(1), 5-28.

Ismael, A. M., & Şengür, A. (2021). Deep Learning Approaches for COVID-19 Detection Based on Chest X-Ray Images. *Expert Systems with Applications*, *164*, 114054.

Ismael, M. R., Abdel-Qader, I. (2018). Brain Tumor Classification Via Statistical Features and Back-Propagation Neural Network. *IEEE International Conference On Electro/Information Technology*, Rochester, MI, USA, 3-5 Mayıs 2018.

Iwadate, Y., Shinozaki, N., Matsutani, T., Uchino, Y., & Saeki, N. (2016). Molecular Imaging of 1p/19q Deletion in Oligodendroglial Tumours with 11C-Methionine Positron Emission Tomography. *Journal of Neurology, Neurosurgery & Psychiatry*, *87*(9), 1016-1021.

Iyer, V. R., Sanghvi, D. A., Shenoy, A., & Goel, A. (2009). Three Distinct Co-Existent Primary Brain Tumors in A Patient. *Journal of cancer research and therapeutics*, *5*(4), 293.

Jaeger, S., Candemir, S., Antani, S., Wáng, Y. X. J., Lu, P. X., & Thoma, G. (2014). Two Public Chest X-Ray Datasets for Computer-Aided Screening of Pulmonary Diseases. *Quantitative Imaging in Medicine and Surgery*, *4*(6), 475.

Jain, A. K., & Farrokhnia, F. (1991). Unsupervised Texture Segmentation Using Gabor Filters. *Pattern recognition*, *24*(12), 1167-1186.

James, G., Witten, D., Hastie, T., Tibshirani, R. (2013). *An Introduction to Statistical Learning: With Applications in R* (1st ed.). New York: Springer.

Jenjaroenpun, P., Wanchai, V., Ono-Moore, K. D., Laudadio, J., James, L. P., Adams, S. H., ... & Wongsurawat, T. (2020). Two SARS-Cov-2 Genome Sequences of Isolates from Rural US Patients Harboring the D614G Mutation, Obtained Using Nanopore Sequencing. *Microbiology Resource Announcements*, *10*(1), e01109-20.

Ji, T., Liu, Z., Wang, G., Guo, X., Lai, C., Chen, H., ... & Zhou, Q. (2020). Detection of COVID-19: A Review of the Current Literature and Future Perspectives. *Biosensors and Bioelectronics*, *166*, 112455.

Jiang, J., Wu, Y., Huang, M., Yang, W., Chen, W., & Feng, Q. (2013). 3D Brain Tumor Segmentation in Multimodal MR Images Based on Learning Population-And Patient-Specific Feature Sets. *Computerized Medical Imaging and Graphics*, *37*(7-8), 512-521.

John, P. (2012). Brain Tumor Classification Using Wavelet and Texture Based Neural Network. *International Journal of Scientific & Engineering Research*, *3*(10), 1-7.

Jolliffe, I. T. (2002). *Principal Component Analysis* (2nd ed.). New York: Springer-Verlag.

Kanas, V. G., Zacharaki, E. I., Thomas, G. A., Zinn, P. O., Megalooikonomou, V., & Colen, R. R. (2017). Learning MRI-Based Classification Models for MGMT Methylation Status Prediction in Glioblastoma. *Computer methods and programs in biomedicine*, *140*, 249-257.

Karthik, R., Menaka, R., & Hariharan, M. (2021). Learning Distinctive Filters for COVID-19 Detection from Chest X-Ray Using Shuffled Residual CNN. *Applied Soft Computing*, *99*, 106744.

Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., ... & Zhang, K. (2018). Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*, *172*(5), 1122-1131.

Kharat, K. D., Kulkarni, P. P., & Nagori, M. B. (2012). Brain Tumor Classification Using Neural Network Based Methods. *International Journal of Computer Science and Informatics, 1*(4), 2231-5292.

Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. *arXiv preprint arXiv:1412.6980*.

Kissler, S. M., Tedijanto, C., Goldstein, E., Grad, Y. H., & Lipsitch, M. (2020). Projecting The Transmission Dynamics of SARS-Cov-2 Through The Postpandemic Period. *Science*, *368*(6493), 860-868.

Kleihues, P., Burger, P. C., & Scheithauer, B. W. (1993). The New WHO Classification of Brain Tumours. *Brain pathology*, *3*(3), 255-268.

Kobayashi, K., Miyake, M., Takahashi, M., & Hamamoto, R. (2021). Observing Deep Radiomics for The Classification of Glioma Grades. *Scientific Reports*, *11*(1), 1-13.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet Classification with Deep Convolutional Neural Networks. *Advances in neural information processing systems*, *25*, 1097-1105.

Kruger, R. P., Thompson, W. B., & Turner, A. F. (1974). Computer Diagnosis of Pneumoconiosis. *IEEE Transactions on Systems, Man, and Cybernetics*, (1), 40-49.

Kruger, R. P., Townes, J. R., Hall, D. L., Dwyer, S. J., & Lodwick, G. S. (1972). Automated Radiographic Diagnosis Via Feature Extraction and Classification of Cardiac Size and Shape Descriptors. *IEEE Transactions on Biomedical Engineering*, (3), 174-186.

Kundu, S., Elhalawani, H., Gichoya, J. W., & Kahn Jr, C. E. (2020). How Might AI And Chest Imaging Help Unravel COVID-19's Mysteries?. *Radiology: Artificial Intelligence*, *2*(3), e200053.

Lambin, P., Rios-Velazquez, E., Leijenaar, R., Carvalho, S., Van Stiphout, R. G., Granton, P., ... & Aerts, H. J. (2012). Radiomics: Extracting More Information from Medical Images Using Advanced Feature Analysis. *European journal of cancer*, *48*(4), 441-446.

LeCun, Y. (1985). Une Procedure D'apprentissage Ponr Reseau a Seuil Asymetrique. *Proceedings of Cognitiva 85*, 599-604.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *nature*, *521*(7553), 436-444.

Obermeyer, C. S., Nagy, P. G., Weaver, S. J., & Newman-Toker, D. E. (2013). Cognitive and System Factors Contributing To Diagnostic Errors In Radiology. *American Journal of Roentgenology*, *201*(3), 611-617.

Lee, E. J., Chang, C. H., Wang, L. C., Hung, Y. C., & Chen, H. H. (2002). Two Primary Brain Tumors, Meningioma and Glioblastoma Multiforme, In Opposite Hemispheres of the Same Patient. *Journal of clinical neuroscience*, *9*(5), 589-591.

Leutenegger, S., Chli, M., & Siegwart, R. Y. (2011, November). BRISK: Binary Robust Invariant Scalable Keypoints. *International Conference on Computer Vision*, Barcelona, Spain, 6-13 Kasım 2011.

Li, C., Zhao, C., Bao, J., Tang, B., Wang, Y., & Gu, B. (2020). Laboratory Diagnosis of Coronavirus Disease-2019 (COVID-19). *Clinica Chimica Acta; International Journal of Clinical Chemistry*, *510*, 35.

Li, F., Sone, S., Abe, H., MacMahon, H., Armato, S. G., & Doi, K. (2002). Lung Cancers Missed at Low-Dose Helical CT Screening in A General Population: Comparison of Clinical, Histopathologic, and Imaging Findings. *Radiology*, *225*(3), 673-683.

Li, Q., Li, F., Suzuki, K., Shiraishi, J., Abe, H., Engelmann, R., ... & Doi, K. (2005). Computer-Aided Diagnosis in Thoracic CT. *Seminars in Ultrasound, CT and MRI*, *26*(5), 357-363.

Li, Y., Yao, L., Li, J., Chen, L., Song, Y., Cai, Z., & Yang, C. (2020). Stability Issues of RT-PCR Testing of SARS-Cov-2 For Hospitalized Patients Clinically Diagnosed with COVID-19. *Journal of medical virology*, *92*(7), 903-908.

Limkin, E. J., Sun, R., Dercle, L., Zacharaki, E. I., Robert, C., Reuzé, S., ... & Ferté, C. (2017). Promises and Challenges for The Implementation of Computational Medical Imaging (Radiomics) In Oncology. *Annals of Oncology*, *28*(6), 1191-1206.

Lodwick, G. S., Haun, C. L., Smith, W. E., Keller, R. F., & Robertson, E. D. (1963). Computer Diagnosis of Primary Bone Tumors: A Preliminary Report. *Radiology*, *80*(2), 273-275.

Long, C., Xu, H., Shen, Q., Zhang, X., Fan, B., Wang, C., ... & Li, H. (2020). Diagnosis of the Coronavirus Disease (COVID-19): rRT-PCR or CT?. *European journal of radiology*, *126*, 108961.

Louis, D. N., Ohgaki, H., Wiestler, O. D., Cavenee, W. K., Burger, P. C., Jouvet, A., ... & Kleihues, P. (2007). The 2007 WHO Classification of Tumours of the Central Nervous System. *Acta neuropathologica*, *114*(2), 97-109.

Lowe, D. G. (2004). Distinctive Image Features from Scale-Invariant Keypoints. *International journal of computer vision*, *60*(2), 91-110.

Macdonald, D. R., Gaspar, L. E., & Cairncross, J. G. (1990). Successful Chemotherapy for Newly Diagnosed Aggressive Oligodendroglioma. *Annals of Neurology: Official Journal of the American Neurological Association and the Child Neurology Society*, *27*(5), 573-574.

Maguolo, G., & Nanni, L. (2021). A Critic Evaluation of Methods for Covid-19 Automatic Detection from X-Ray Images. *Information Fusion*, *76*, 1-7.

Mangal, A., Kalia, S., Rajgopal, H., Rangarajan, K., Namboodiri, V., Banerjee, S., & Arora, C. (2020). CovidAID: COVID-19 Detection Using Chest X-Ray. *arXiv preprint arXiv:2004.09803*.

Matas, J., Chum, O., Urban, M., & Pajdla, T. (2004). Robust Wide-Baseline Stereo from Maximally Stable Extremal Regions. *Image and vision computing*, *22*(10), 761-767.

Mettler Jr, F. A., Huda, W., Yoshizumi, T. T., & Mahesh, M. (2008). Effective Doses in Radiology and Diagnostic Nuclear Medicine: A Catalog. *Radiology*, *248*(1), 254-263.

Meyers, P. H., Charles, M. N., Hal, C. B., Wilson, J. N., James, W. S., George, R. M. (1964). Automated Computer Analysis of Radiographic Images. *Radiology, 83*(6), 1029–34. https://doi.org/10.1148/83.6.1029.

Minaee, S., Kafieh, R., Sonka, M., Yazdani, S., & Soufi, G. J. (2020). Deep-covid: Predicting COVID-19 From Chest X-Ray Images Using Deep Transfer Learning. *Medical image analysis*, *65*, 101794.

Mitchell, T. (1997). *Machine Learning* (1st ed.). McGraw-Hill Series in Computer Science. New York: McGraw-Hill.

Narang, S., Lehrer, M., Yang, D., Lee, J., & Rao, A. (2016). Radiomics in Glioblastoma: Current Status, Challenges and Potential Opportunities. *Translational Cancer Research*, *5*(4), 383-397.

Ning, W., Lei, S., Yang, J., Cao, Y., Jiang, P., Yang, Q., ... & Wang, Z. (2020). Open resource of clinical data from patients with pneumonia for the prediction of COVID-19 outcomes via deep learning. *Nature biomedical engineering*, *4*(12), 1197-1207.

Nishio, M., Chihiro, N. (2017). Computer-Aided Diagnosis for Lung Cancer: Usefulness of Nodule Heterogeneity. *Academic Radiology*, *24*(3), 328–36. https://doi.org/10.1016/j.acra.2016.11.007.

Nour, M., Cömert, Z., & Polat, K. (2020). A Novel Medical Diagnosis Model for COVID-19 Infection Detection Based On Deep Features and Bayesian Optimization. *Applied Soft Computing*, *97*, 106580.

Nutt, C. L., Mani, D. R., Betensky, R. A., Tamayo, P., Cairncross, J. G., Ladd, C., ... & Louis, D. N. (2003). Gene Expression-Based Classification of Malignant Gliomas Correlates Better with Survival Than Histological Classification. *Cancer research*, *63*(7), 1602-1607.

Obermeyer, Z., Ezekiel, J. E. (2016). Predicting the Future — Big Data, Machine Learning, and Clinical Medicine. *The New England Journal of Medicine, 375*(13), 1216–19. https://doi.org/10.1056/NEJMp1606181.

Ojala, T., Pietikainen, M., Maenpaa, T. (2002). Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence, 24*(7), 971–87. https://doi.org/10.1109/TPAMI.2002.1017623.

Ostrom, Q. T., Patil, N., Cioffi, G., Waite, K., Kruchko, C., & Barnholtz-Sloan, J. S. (2020). CBTRUS Statistical Report: Primary Brain and Other Central Nervous System Tumors Diagnosed in The United States in 2013–2017. *Neuro-oncology*, *22*(Supplement_1), iv1-iv96.

Ouchicha, C., Ammor, O., & Meknassi, M. (2020). CVDNet: A Novel Deep Learning Architecture for Detection of Coronavirus (Covid-19) From Chest X-Ray Images. *Chaos, Solitons & Fractals*, *140*, 110245.

Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., & Acharya, U. R. (2020). Automated Detection of COVID-19 Cases Using Deep Neural Networks with X-Ray Images. *Computers in biology and medicine*, *121*, 103792.

Öksüz, C., Güllü, M. K. (2020). Deep Feature Extraction Based Fine-Tuning. *28th Signal Processing and Communications Applications Conference (SIU)*, Gaziantep, Turkey, 5-7 Ekim 2020.

Öksüz, C., Urhan, O., & Güllü, M. K. (2020). Ensemble-CVDNet: A Deep Learning based End-to-End Classification Framework for COVID-19 Detection using Ensembles of Networks. *arXiv preprint arXiv:2012.09132*.

Öksüz, C., Urhan, O., & Güllü, M. K. (2021). Efficientnet-B0 Based Single Stage and Multi-Scale Object Detection Model for Localization of Low Grade Gliomas and Detection of 1p/19q Codeletion Status. *Artificial Intelligence Theory and Applications, 1*(2), 191–201.

Öksüz, C., Urhan, O., Güllü, M. K. (2021). Ensemble-LungMaskNet: Automated Lung Segmentation using Ensembled Deep Encoders. In *2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, Kocaeli, Turkey, 25-27 Aug. 2021.

Öksüz, C., Urhan, O., Güllü, M. K. (2021). A Two-Headed Deep Learning Framework for Predicting Severity of COVID-19 Disease. *Artificial Intelligence Theory and Applications, 1*(3), 19–28.

Öksüz, C., Urhan, O., & Güllü, M. K. (2022). Brain Tumor Classification Using the Fused Features Extracted from Expanded Tumor Region. *Biomedical Signal Processing and Control*, *72*, 103356.

Parmar, C., Grossmann, P., Bussink, J., Lambin, P., & Aerts, H. J. (2015). Machine Learning Methods for Quantitative Radiomic Biomarkers. *Scientific reports*, *5*(1), 1-11.

Pashaei, A., Sajedi, H., & Jazayeri, N. (2018, October). Brain Tumor Classification Via Convolutional Neural Network and Extreme Learning Machines. *8th International Conference On Computer and Knowledge Engineering (ICCKE)*, Mashhad, Iran, 25-26 Ekim 2018.

Paul, R., Kariev, S., Cherezov, D., Schabath, M. B., Gillies, R. J., Hall, L. O., & Goldgof, D. B. (2021). Deep Radiomics: Deep Learning on Radiomics Texture Images. *Medical Imaging 2021: Computer-Aided Diagnosis*, San Diego, United States, Feb 14-18, 2021.

Petrovska, B., Atanasova-Pacemska, T., & Stojanovic, I. (2018). Classification of Small Sets of Images with Pre-trained Neural Networks. *International Journal of Engineering and Manufacturing*, *8*(4), 40-55.

Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. *arXiv preprint arXiv:1511.06434*.

Raina, R., Battle, A., Lee, H., Packer, B., Ng, A. Y. (2007). Self-Taught Learning: Transfer Learning from Unlabeled Data. *Proceedings of the 24th international conference on Machine learning*, New York, NY, United States, Haziran 20-24, 2007.

Ramachandran, P., Zoph, B., & Le, Q. V. (2017). Searching for Activation Functions. *arXiv preprint arXiv:1710.05941*.

Ribeiro, M. T., Singh, S., Guestrin, C. (2016). " Why Should I Trust You?" Explaining The Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco California, USA, Ağustos 13-17, 2016.

Roberts, M., Driggs, D., Thorpe, M., Gilbey, J., Yeung, M., Ursprung, S., ... & Schönlieb, C. B. (2021). Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans. *Nature Machine Intelligence*, *3*(3), 199-217.

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Munich, Germany, Ekim 5-9, 2015.

Rosenblatt, F. (1957). The Perceptron, A Perceiving and Recognizing Automaton Project Para, *Cornell Aeronautical Laboratory*, 85-460-1, 85-460.

Roth, V. (2004). The Generalized LASSO. *IEEE Transactions on Neural Networks*, *15*(1), 16–28. https://doi.org/10.1109/TNN.2003.809398.

Rublee, E., Rabaud, V., Konolige, K., Bradski, G. (2011). ORB: An Efficient Alternative to SIFT or SURF. *2011 International Conference on Computer Vision*, Barcelona, Spain, 6-13 Kasım 2011.

Rumelhart, D. E., Geoffrey, E. H., Ronald, J. W. (1986). Learning Representations by Back-Propagating Errors. *Nature*, *323*(6088), 533–36. https://doi.org/10.1038/323533a0.

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L. (2015). Imagenet Large Scale Visual Recognition Challenge. *International journal of computer vision*, *115*(3), 211-252.

Sachdeva, J., Vinod, K., Indra, G., Niranjan, K., Chirag, K. A. (2013). Segmentation, Feature Extraction, and Multiclass Brain Tumor Classification. *Journal of Digital Imaging*, *26*(6), 1141–50.

Saenz del Burgo, L., Hernández, R. M., Orive, G., Pedraz, J. L. (2014). Nanotherapeutic Approaches for Brain Cancer Management. *Nanomedicine: Nanotechnology, Biology and Medicine*, *10*(5), 905–919. https://doi.org/10.1016/j.nano.2013.10.001.

Sajjad, M., Salman, K., Khan, M., Wanqing, W., Amin, U., Sung, W. B. (2019). Multi-Grade Brain Tumor Classification Using Deep CNN with Extensive Data Augmentation. *Journal of Computational Science*, *30*(2019), 174–82. https://doi.org/10.1016/j.jocs.2018.12.003.

Salmon, E., Ir, C. B., & Hustinx, R. (2015). Pitfalls and Limitations of PET/CT in Brain Imaging. *Seminars in nuclear medicine*, *45*(6), 541-551.

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L. C. (2018). Mobilenetv2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, 18-23 Haziran 2018.

Santa Cruz, B. G., Bossa, M. N., Soelter, J., & Husch, A. D. (2021). Public Covid-19 X-Ray Datasets and Their Impact On Model Bias-A Systematic Review of a Significant Problem. *medRxiv*.

Santurkar, S., Tsipras, D., Ilyas, A., & Mądry, A. (2018). How Does Batch Normalization Help Optimization?. *Proceedings of the 32nd International Conference On Neural Information Processing Systems*, Montréal, Canada, Aralık 3 - 8, 2018.

Schölkopf, B., Smola, A. J., Bach, F. (2002). *Learning with Kernels: Support Vector Machines, Regularization, Optimization, And Beyond* (1st ed.). Cambridge, Massachusetts: MIT press.

Schroeder, A., Heller, D. A., Winslow, M. M., Dahlman, J. E., Pratt, G. W., Langer, R., ... & Anderson, D. G. (2012). Treating Metastatic Cancer with Nanotechnology. *Nature Reviews Cancer*, *12*(1), 39-50.

Selfridge, O. G. (1958). Pandemonium: A Paradigm for Learning. *Proceedings of a Symposium Held at the National Physical Laboratory*, London, UK, 24-27 Nov. 1958.

Selvaraj, H., Selvi, S. T., Selvathi, D., Gewali, L. (2007). Brain MRI Slices Classification Using Least Squares Support Vector Machine. *International Journal of Intelligent Computing in Medical Sciences & Image Processing*, *1*(1), 21–33. https://doi.org/10.1080/1931308X.2007.10644134.

Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-Cam: Visual Explanations from Deep Networks Via Gradient-Based Localization. *Proceedings of the IEEE International Conference On Computer Vision*, Venice, Italy, 22-29 Ekim 2017.

Sethy, P. K., Behera, S. K. (2021). A Data Constrained Approach For Brain Tumour Detection Using Fused Deep Features and SVM. *Multimedia Tools and Applications*, *80*(19), 28745 – 28760.

Shen, W., Zhou, M., Yang, F., Yang, C., Tian, J. (2015). Multi-Scale Convolutional Neural Networks for Lung Nodule Classification. *International Conference on Information Processing in Medical Imaging*, Isle of Skye, UK, Haziran 28-Temmuz 3 2015.

Shiraishi, J., Katsuragawa, S., Ikezoe, J., Matsumoto, T., Kobayashi, T., Komatsu, K., Matsui, M., Fujita, H., Kodera, Y., Doi, K. (2000). Development of a Digital Image Database for Chest Radiographs with and Without a Lung Nodule. *American Journal of Roentgenology*, *174*(1), 71–74. https://doi.org/10.2214/ajr.174.1.1740071.

Skourt, B. A., El Hassani, A., & Majda, A. (2018). Lung CT Image Segmentation Using Deep Neural Networks. *Procedia Computer Science*, *127*, 109-113.

Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

Singh, A., Lall, B., Panigrahi, B. K., Agrawal, A., Agrawal, A., Thangakunam, B., Christopher, D. J. (2021). Deep LF-Net: Semantic Lung Segmentation from Indian Chest Radiographs Including Severely Unhealthy Images. *Biomedical Signal Processing and Control*, *68*, 102666. https://doi.org/10.1016/j.bspc.2021.102666.

Singh, D., Febbo, P. G., Ross, K., Jackson, D. G., Manola, J., Ladd, C., Tamayo, P., (2002). Gene Expression Correlates of Clinical Prostate Cancer Behavior. *Cancer Cell*, *1*(2), 203–9. https://doi.org/10.1016/S1535-6108(02)00030-2.

Souza, J. C., Diniz, J. O. B., Ferreira, J. L., da Silva, G. L. F., Silva, A. C., & de Paiva, A. C. (2019). An Automatic Method for Lung Segmentation and Reconstruction in Chest X-Ray Using Deep Neural Networks. *Computer methods and programs in biomedicine*, *177*, 285-296.

Sridhar, D., Krishna, I. M. (2013). Brain Tumor Classification Using Discrete Cosine Transform and Probabilistic Neural Network. *International Conference on Signal Processing, Image Processing & Pattern Recognition*, Coimbatore, India, 7-8 Feb. 2013.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *The journal of machine learning research*, *15*(1), 1929-1958.

Sultan, H. H., Salem, N. M., & Al-Atabany, W. (2019). Multi-Classification of Brain Tumor Images Using Deep Neural Network. *IEEE Access*, *7*, 69215-69225.

Sun, C., Wee, W. G. (1983). Neighboring gray level dependence matrix for texture classification. *Computer Vision, Graphics, and Image Processing*, *23*(3), 341-352.

Suzuki, K., Sheu, I., Epstein, M., Kohlbrenner, R., Lostumbo, A., Rockey, D. C., & Dachman, A. H. (2008). An MTANN CAD for detection of polyps in false-negative CT colonography cases in a large multicenter clinical trial: Preliminary results. *Medical Imaging 2008: Computer-Aided Diagnosis*, San Diego, California, United States, 27 Mart 2008.

Swati, Z. N. K., Zhao, Q., Kabir, M., Ali, F., Ali, Z., Ahmed, S., Lu, J. (2019). Brain tumor classification for MR images using transfer learning and fine-tuning. *Computerized Medical Imaging and Graphics*, *75*, 34-46.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston, MA, 7-12 June 2015.

Tabik, S., Gómez-Ríos, A., Martín-Rodríguez, J. L., Sevillano-García, I., Rey-Area, M., Charte, D., ... & Herrera, F. (2020). COVIDGR Dataset and COVID-Sdnet Methodology for Predicting COVID-19 Based On Chest X-Ray Images. *IEEE Journal of Biomedical and Health Informatics*, *24*(12), 3595-3605.

Takahashi, R., & Kajikawa, Y. (2017). Computer-Aided Diagnosis: A Survey with Bibliometric Analysis. *International journal of medical informatics*, *101*, 58-67.

Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., Liu, C. (2018). A Survey On Deep Transfer Learning. *International Conference on Artificial Neural Networks*, Rhodes, Greece, Oct 4-7 2018.

Tan, M., Le, Q. (2019). Efficientnet: Rethinking Model Scaling for Convolutional Neural Networks. *International Conference on Machine Learning*, California, USA, 9-15 June 2019.

Tang, Z., Zhao, W., Xie, X., Zhong, Z., Shi, F., Ma, T., ... & Shen, D. (2021). Severity Assessment of COVID-19 Using CT Image Features and Laboratory Indices. *Physics in Medicine & Biology*, *66*(3), 035015.

Thibault, G., Angulo, J., & Meyer, F. (2013). Advanced Statistical Matrices for Texture Characterization: Application to Cell Classification. *IEEE Transactions on Biomedical Engineering*, *61*(3), 630-637.

Thurlbeck, W. M., & Müller, N. L. (1994). Emphysema: Definition, Imaging, and Quantification. *AJR. American journal of roentgenology*, *163*(5), 1017-1025.

Toriwaki, J. I., Suenaga, Y., Negoro, T., & Fukumura, T. (1973). Pattern Recognition of Chest X-Ray Images. *Computer Graphics and Image Processing*, *2*(3-4), 252-271.

Tunthanathip, T., Kanjanapradit, K., Ratanalert, S., Phuenpathom, N., Oearsakul, T., & Kaewborisutsakul, A. (2018). Multiple, Primary Brain Tumors with Diverse Origins and Different Localizations: Case Series and Review of the Literature. *Journal of Neurosciences in Rural Practice*, *9*(04), 593-607.

URL- 1: https://gco.iarc.fr/tomorrow/en/dataviz/isotype, (Ziyaret Tarihi: 1 Aralık 2021).

URL-2: https://covid19.who.int, (Ziyaret Tarihi: 12 Ocak 2022).

URL-3: http://scott.fortmann-roe.com/docs/BiasVariance.html, (Ziyaret Tarihi: 2 Aralık 2021).

URL-4: https://nimhans.ac.in, (Ziyaret Tarihi: 12 Ocak 2022).

URL-5: http://www.med.harvard.edu/AANLIB/home.html, (Ziyaret Tarihi: 12 Ocak 2022)

URL-6: https://www.cancer.gov/about-nci/organization/ccg/research/structural-genomics/tcga, (Ziyaret Tarihi: 12.01.2022).

URL-7: https://github.com/ml-workgroup/covid-19-image-repository, (Ziyaret Tarihi: 1 Aralık 2021)

URL-8: https://github.com/ari-dasci/OD-covidgr, (Ziyaret Tarihi: 19 Aralık 2021).

URL-9: https://lhncbc.nlm.nih.gov/LHC-publications/pubs/TuberculosisChestXrayImageDataSets.html, (Ziyaret Tarihi: 25 Nisan 2021).

URL-10: https://github.com/v7labs/covid-19-xray-dataset, (Ziyaret Tarihi: 25 Nisan 2021).

Vidal, P. L., de Moura, J., Novo, J., & Ortega, M. (2021). Multi-Stage Transfer Learning for Lung Segmentation Using Portable X-Ray Devices for Patients with COVID-19. *Expert Systems with Applications*, *173*, 114677.

Van der Maaten, L., & Hinton, G. (2008). Visualizing Data Using T-SNE. *Journal of Machine Learning Research*, *9*(11).

Van der Voort, S. R., Incekara, F., Wijnenga, M. M., Kapas, G., Gardeniers, M., Schouten, J. W., ... & Smits, M. (2019). Predicting The 1p/19q Codeletion Status of Presumed Low-Grade Glioma with an Externally Validated Machine Learning Algorithm. *Clinical Cancer Research*, *25*(24), 7455-7462.

Van den Bent, M. J., Brandes, A. A., Taphoorn, M. J., Kros, J. M., Kouwenhoven, M. C., Delattre, J. Y., ... & Hoang-Xuan, K. (2013). Adjuvant Procarbazine, Lomustine, And Vincristine Chemotherapy in Newly Diagnosed Anaplastic Oligodendroglioma: Long-Term Follow-Up of EORTC Brain Tumor Group Study 26951. *Journal of Clinical Oncology*, *31*(3), 344-350.

Wang, L., Lin, Z. Q., & Wong, A. (2020). Covid-net: A Tailored Deep Convolutional Neural Network Design for Detection of Covid-19 Cases from Chest X-Ray Images. *Scientific Reports*, *10*(1), 1-12.

Warren, M. A., Zhao, Z., Koyama, T., Bastarache, J. A., Shaver, C. M., Semler, M. W., ... & Ware, L. B. (2018). Severity Scoring of Lung Oedema on the Chest Radiograph is Associated with Clinical Outcomes in ARDS. *Thorax*, *73*(9), 840-846.

Weinstock, M. B., Echenique, A. N. A., Russell, J. W., Leib, A. R. I., Miller, J., Cohen, D., ... & Illuzzi, F. (2020). Chest X-Ray Findings in 636 Ambulatory Patients with COVID-19 Presenting to an Urgent Care Center: A Normal Chest X-Ray Is No Guarantee. *J Urgent Care Med*, *14*(7), 13-18.

Werbos, P. (1974). Beyond Regression. Ph. D. Dissertation, Harvard University, Cambridge Massachusetts, US. https://ci.nii.ac.jp/naid/10004070196/.

Williams, T. C., Wastnedge, E., McAllister, G., Bhatia, R., Cuschieri, K., Kefala, K., ... & Templeton, K. E. (2020). Sensitivity of RT-PCR Testing of Upper Respiratory Tract Samples for SARS-Cov-2 In Hospitalised Patients: A Retrospective Cohort Study. *Wellcome Open Research*, *5*(254), 254.

Winsberg, F., Elkin, M., Macy Jr, J., Bordaz, V., & Weymouth, W. (1967). Detection of Radiographic Abnormalities in Mammograms by Means of Optical Scanning and Computer Analysis. *Radiology*, *89*(2), 211-215.

Wise, J. (2021). Covid-19: The E484K mutation and the risks it poses.

Wolberg, G. (1992). *Digital Image Warping* (1st ed.). Los Alamitos, Calif: IEEE Computer Society Press.

Wong, H. Y. F., Lam, H. Y. S., Fong, A. H. T., Leung, S. T., Chin, T. W. Y., Lo, C. S. Y., ... & Ng, M. Y. (2020). Frequency and Distribution of Chest Radiographic Findings in Patients Positive for COVID-19. *Radiology*, *296*(2), E72-E78.

Xu, Y., Jia, Z., Ai, Y., Zhang, F., Lai, M., Eric, I., & Chang, C. (2015). Deep Convolutional Activation Features for Large Scale Brain Tumor Histopathology Image Classification and Segmentation. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, South Brisbane, QLD, Australia, 19-24 Nisan 2015.

Xue, H., & Jin, Z. (2020). The Appropriate Position of Radiology in COVID-19 Diagnosis and Treatment—Current Status and Opinion from China. *Chinese journal of Academic Radiology*, *3*(1), 1-3.

Yang, W., Sirajuddin, A., Zhang, X., Liu, G., Teng, Z., Zhao, S., & Lu, M. (2020). The Role of Imaging in 2019 Novel Coronavirus Pneumonia (COVID-19). *European Radiology*, 1-9.

Zeiler, M. D., Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. *European Conference on Computer Vision*, Zurich, Switzerland, Eylül 6-12, 2014.

Zhang, A. (2020). COVID-19 Chest X-Ray Images: Lung Segmentation and Diagnosis Using Neural Networks. *International Journal on Computational Science & Applications (IJCSA)*, *10*(5), https://doi.org/10.5121/ijcsa.2020.10501.

Zhang, C., Qin, L., Li, K., Wang, Q., Zhao, Y., Xu, B., ... & Zhang, Y. (2020). A Novel Scoring System for Prediction of Disease Severity in COVID-19. *Frontiers in cellular and infection microbiology*, *10*, 318.

Zhang, G., Ma, Z. M., Tong, Q., He, Y., Zhao, T. (2008). Shape Feature Extraction Using Fourier Descriptors with Brightness in Content-Based Medical Image Retrieval. In *2008 International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, Harbin, China, 15-17 Ağustos 2008.

Zhang, K., Liu, X., Shen, J., Li, Z., Sang, Y., Wu, X., ... & Wang, G. (2020). Clinically Applicable AI System for Accurate Diagnosis, Quantitative Measurements, And Prognosis of COVID-19 Pneumonia Using Computed Tomography. *Cell*, *181*(6), 1423-1433.

Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). Shufflenet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *Proceedings of the IEEE Conference On Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, 18-23 June 2018.

Zhang, Z., Yang, Y., Zhang, K., Zhuang, J., Shao, F., Liu, H., ... & Xu, S. (2018). Collision Tumor of Glioblastoma and Meningioma: Case Report and Literature Review. *World Neurosurgery*, *117*, 137-141.

Zheng, A., Casari, A. (2018). *Feature Engineering for Machine Learning: Principles and Techniques for Data Scientists* (1st edition). Beijing, Boston: O'Reilly.

Zheng, Y., Englander, S., Baloch, S., Zacharaki, E. I., Fan, Y., Schnall, M. D., & Shen, D. (2009). STEP: Spatiotemporal Enhancement Pattern for MR-Based Breast Tumor Diagnosis. *Medical physics*, *36*(7), 3192-3204.

Zoph, B., Cubuk, E. D., Ghiasi, G., Lin, T. Y., Shlens, J., & Le, Q. V. (2020). Learning Data Augmentation Strategies for Object Detection. *European Conference on Computer Vision*, Glasgow, United Kingdom, 23-28 Ağustos 2020.

Zou, H., Hastie, T. (2005). Regularization and Variable Selection via the Elastic Net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, *67*(2), 301–20. https://doi.org/10.1111/j.1467-9868.2005.00503.x.

KİŞİSEL YAYIN VE ESERLER

Öksüz, C., Gullu, M. K., (2015). Adaptive local thresholding based number plate detection. *23nd IEEE Signal Processing and Communications Applications Conference (SIU)*, Malatya, Turkey, 16-19 Mayıs 2015.

Öksüz, C., Gullu, M. K., (2020). Deep Feature Extraction Based Fine-Tuning, *2020 28th IEEE Signal Processing and Communications Applications Conference (SIU)*, Gaziantep, Turkey, 5-7 Ekim 2020.

Öksüz, C., Gullu, M. K., (2020). Brain Tumor Localization Using Yolo v2, *2020 28th IEEE Signal Processing and Communications Applications Conference (SIU)*, Gaziantep, Turkey, 5-7 Ekim 2020.

Öksüz, C., Urhan, O., Gullu, M. K, (2021). A Lightweight Deep Model for Brain Tumor Segmentation, *2021 29th IEEE Signal Processing and Communications Applications Conference (SIU)*, Istanbul, Turkey, 9-11 Haziran 2021.

Öksüz, C., Urhan, O., Gullu, M. K, (2021). Ensemble-LungMaskNet: Automated Lung Segmentation using Ensembled Deep Encoders, *IEEE International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, Kocaeli, Turkey, *25-27 Ağustos 2021*.

Öksüz, C., Urhan, O., Gullu, M. K, (2021). Covid-19 Related Pneumonia Severity Score Estimation Using Pre-Trained Deep Convolutional Neural Networks, *II. International Artificial Intelligence in Health Congress*, Izmir, Turkey, *16-18 Nisan 2021*.

Öksüz, C., Urhan, O., Gullu, M. K, (2021). Efficientnet-B0 Based Single Stage and Multi-Scale Object Detection Model for Localization of Low-Grade Gliomas and Detection of 1p/19q Codeletion Status. *Artificial Intelligence Theory and Applications*, *1*(2), 191-201.

Öksüz, C., Urhan, O., Gullu, M. K, (2021). A Two-Headed Deep Learning Framework for Predicting Severity of COVID-19 Disease. *Artificial Intelligence Theory and Applications*, *1*(3), 19-28.

Öksüz, C., Urhan, O., Gullu, M. K, (2020). *Ensemble-CVDNet: A Deep Learning based End-to-End Classification Framework for COVID-19 Detection using Ensembles of Networks*. arXiv preprint arXiv:2012.09132, https://arxiv.org/abs/2012.09132v2, (Ziyaret tarihi: 17 Kasım 2021). (*under review*)

Öksüz, C., Urhan, O., & Güllü, M. K. (2022). Brain tumor classification using the fused features extracted from expanded tumor region. *Biomedical Signal Processing and Control*, *72*, 103356.

Öksüz, C., Urhan, O., Gullu, M. K, (2022). COVID-19 Detection with Severity Level Analysis using the Deep Features, and Wrapper-based Selection of Ranked Features. *Concurrency and Computation: Practice and Experience*, e6802.

ÖZGEÇMİŞ

Coşku ÖKSÜZ, ilk, orta ve lise öğrenimini Aydın'ın Kuşadası ilçesinde tamamladı. İlk lisans derecesini 2009 yılında Kocaeli Üniversitesi Elektronik ve Bilgisayar Eğitimi bölümünden aldı. Samsun Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'ndeki eğitimini 2016 yılında tamamlayarak Elektrik-Elektronik Mühendisi olarak mezun oldu. Kocaeli Üniversitesi'nin Elektronik ve Haberleşme Mühendisliği Bölümü'ndeki yüksek lisans eğitimini 2015 yılında tamamladı. 2016 yılından bu yana Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümü'ndeki doktora eğitimine devam etmektedir. Doktora eğitimi süresince Elsevier ve IEEE gibi kuruluşlar tarafından yayınlanan SCI kapsamlı dergilerde 20'den fazla hakemlik yapmıştır. 2014 Şubat ayından itibaren Kastamonu Üniversitesi Bozkurt Meslek Yüksekokulu Elektronik ve Otomasyon Bölümü'nde Öğretim Görevlisi olarak çalışmaktadır. Kastamonu Üniversitesi Mühendislik Fakültesi'nin Elektrik-Elektronik Mühendisliği ve Biyomedikal Mühendisliği bölümlerinde Tıbbi İşaret İşleme, Tıbbi Görüntü İşleme, Devre Teorisi-I ve Devre Teorisi-II dersleri vermektedir.