

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YAPAY ZEKÂ VE AKILLI SİSTEMLER ANABİLİM DALI

EVRIŞİMSEL SİNİR AĞI KULLANILARAK GÖĞÜS
RADYOGRAFİLERİNDE YÜKSEK BAŞARIMLI BÖLÜTLEME YAPILMASI
VE PNÖMONİ TESPİTİNE ETKİSİNİN İNCELENMESİ

YÜKSEK LİSANS

İlhan AYDIN

OCAK-2023
GÜMÜŞHANE



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

YAPAY ZEKÂ VE AKILLI SİSTEMLER ANABİLİM DALI

**EVRIŞİMSEL SİNİR AĞI KULLANILARAK GÖĞÜS
RADYOGRAFİLERİNDE YÜKSEK BAŞARIMLI BÖLÜTLEME YAPILMASI
VE PNÖMONİ TESPİTİNE ETKİSİNİN İNCELENMESİ**

**HIGH PERFORMANCE SEGMENTATION IN CHEST RADIOGRAPHS
USING CONVOLUTIONAL NEURAL NETWORK AND INVESTIGATION OF
ITS EFFECT ON PNEUMONIA DETECTION**

YÜKSEK LİSANS

İlhan AYDIN

**OCAK-2023
GÜMÜŞHANE**



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

YAPAY ZEKÂ VE AKILLI SİSTEMLER ANABİLİM DALI

**EVRIŞİMSEL SİNİR AĞI KULLANILARAK GÖĞÜS
RADYOGRAFİLERİNDE YÜKSEK BAŞARIMLI BÖLÜTLEME YAPILMASI
VE PNÖMONİ TESPİTİNE ETKİSİNİN İNCELENMESİ**

**HIGH PERFORMANCE SEGMENTATION IN CHEST RADIOGRAPHS
USING CONVOLUTIONAL NEURAL NETWORK AND INVESTIGATION OF
ITS EFFECT ON PNEUMONIA DETECTION**

YÜKSEK LİSANS

İlhan AYDIN

Danışman: Dr. Öğr. Üyesi Özkan BİNGÖL

**OCAK-2023
GÜMÜŞHANE**

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Yüksek Lisans Tezi olarak hazırlamış olduğum “**Evrişimsel Sinir Ağı Kullanılarak Göğüs Radyografilerinde Yüksek Başarımli Bölütleme Yapılması Ve Pnömoni Tespitine Etkisinin İncelenmesi**” isimli bu tezimin, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmaları kaynakçada belirttiğimi ve Gümüşhane Üniversitesi'nin lisanslı kullanıcısı olduğu intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü'nün belirlediği kıstaslara uygun olarak raporladığımı taahhüt ederim. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

25/01/2023

.....
İlhan AYDIN

TEŞEKKÜR

Çalışmalarım sırasında bilgi ve tecrübelerinden faydalandığım tez danışmanım Sayın Dr. Öğr. Üyesi Özkan BİNGÖL hocama, çalışmalarımın kod aşamalarında beni yalnız bırakmayan ve desteklerini esirgemeyen Sayın Mehmet Halis KORKMAZ’a, Sayın Dr. Öğr. Üyesi Ramazan Özgür DOĞAN’a , Sayın Süleyman DEMİR ve Sayın Salih TÜRK’e teşekkür ederim. İş arkadaşlarımdan desteklerini esirgemeyen Sayın Murat DEMİRAĞ ve Sayın Mustafa KÜÇÜK’e teşekkür ederim.

Ayrıca tüm bu çalışmalarım sürecinde bana vakit olanağı sağlayan ve desteğini esirgemeyen eşim Aysun AYDIN’a teşekkür ederim.

İlhan AYDIN
GÜMÜŞHANE – 2023

ÖZET

Zatürre diğer adıyla pnömoni bakteriyel veya viral enfeksiyonun neden olduğu yaşamı tehdit eden akciğer hastalığıdır. Bu nedenle, hastalığın erken teşhisi ölüm oranını önemli derecede azaltmaktadır. Göğüs röntgenleri (radyografi) hastalığın teşhisinde büyük öneme sahiptir. Pnömoni teşhisinde sağlık alanındaki çalışmalar dışında, mühendislik alanında da birçok çalışma yapılmakta ve teşhis sürecini hızlandırma konusunda kolaylıklar sağlamaktadır. Bu uygulamalardan biri de derin öğrenme yöntemleri ile hastalığı teşhis etmektir. Çalışmada, Python programlama dilinde Tensorflow Kütüphanesi ve erişime açık veri setlerinden yararlanılmıştır. Veri seti olarak içinde 1-5 yaş arası çocukların göğüs röntgenlerinin bulunduğu Veriseti-1 ve bu veri setinden bir kısım görüntülerin işaretli verilerinin de bulunduğu Veriseti-2 kullanılmıştır. İki aşamalı evrimsel sinir ağı modeli oluşturulmuştur. İlk aşamada, akciğer bölgesi işaretlenmiş Veriseti-2 üzerinde değiştirilmiş U-Net mimarisi kullanılarak bölütlemesi yapılacak Veriseti-1 görüntüleri için model oluşturulmuştur. Ayrıca çalışmanın son kısmında göğüs kafesi bölgesini tespit edebilecek bir yaklaşım önerilmiştir. Oluşturulan model Veriseti-1’de kullanılarak bölütleme yapılmıştır. Bölütleme doğruluğu (accuracy) % 98.98 olarak hesaplanmıştır. Tasarlanan evrimsel sinir ağı modeli Veriseti-2’ye uygulanmış ve pnömoni tespitinde test doğruluk (accuracy) değeri %98.55 olarak elde edilmiştir.

Anahtar Kelimeler: Bölütleme, Derin öğrenme, Evrimsel sinir ağı, Pnömoni, U-Net

SUMMARY

Pneumonia, also known as pneumonia, is a life-threatening lung disease caused by a bacterial or viral infection. Therefore, early diagnosis of the disease significantly reduces the mortality rate. Chest X-rays are of great importance in the diagnosis of the disease. Apart from the studies in the field of health in the diagnosis of pneumonia, many studies are carried out in the field of engineering and provide convenience in accelerating the diagnosis process. One of these applications is to diagnose the disease with Deep Learning methods. Tensorflow Library on Python programming language and open access datasets were used in the study. Dataset-1, which contains chest x-rays of children aged 1-5, and Dataset – 2, which also contains the marked data of some images from this dataset, were used as dataset. A two-stage Convolutional Neural Network model was created. In the first stage, a model was created for dataset-1 images to be segmented using modified U-Net architecture on Dataset – 2 with marked lung region. Segmentation was done by using the created model in Dataset – 1. In addition, an approach that can detect the thorax region is proposed in the last part of study. Segmentation accuracy was calculated as 98.98%. The designed Convolutional Neural Network model was applied to the dataset-2, and the test accuracy in detecting pneumonia was 98.55%.

Keywords: Segmentation, Deep learning, Convolutional neural network, Pneumonia, U-Net

İÇİNDEKİLER

KABUL VE ONAY	HATA! YER İŞARETİ TANIMLANMAMIŞ.
BİLİMSEL ETİĞE UYGUNLUK BEYANI.....	III
TEŞEKKÜR.....	V
ÖZET.....	VI
SUMMARY	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ	X
ŞEKİLLER DİZİNİ.....	XI
SİMGELER VE KISALTMALAR DİZİNİ	XIII
1. GİRİŞ	1
2. TEZ KONUSU VE KAPSAMI	3
3. MATERYAL VE YÖNTEM	7
3.1. Bölütleme	7
3.2. Derin öğrenme.....	9
3.2.1. Yapay Sinir Ağları	9
3.2.2. Derin Ağ Mimarisi	11
3.2.3. Evrişimsel Sinir Ağı.....	12
3.2.4. Evrişim Katmanı	13
3.2.5. Havuzlama Katmanı.....	14
3.2.6. ReLU Fonksiyonu	14
3.2.7. Sigmoid Fonksiyonu	15
3.2.8. Tanh Fonksiyonu.....	16
3.2.9. Softmax	16
3.2.10. Düzleştirme Katmanı	17
3.2.11. Tam Bağlı Katman	17
3.2.12. Kaydırma Adımı.....	18
3.2.13. Dolgu İşlemi.....	18
3.3. U-Net Mimarisi	19
3.4. Kullanılan Veri Setleri	20
3.4.1. Veriseti-1.....	20
3.4.2. Veriseti-2.....	21
3.5. Değerlendirme Metotları.....	22

3.5.1. Karışıklık Matrisi	22
3.5.2. K Katlamalı Çarpaz Doğrulama	23
4. YAPILAN ÇALIŞMALAR	25
4.1. U-Net Tabanlı Bölütleme Ağ Mimarisi	26
4.2. Sınıflandırma Ağ Yapısı	29
4.3. Göğüs Bölgesinin (Thorax) Tespit Edilmesi	31
5. BULGULAR VE TARTIŞMA	37
5.1. U-Net Mimarisi İle Bölütleme	37
5.2. Veriseti-1 Orijinal Görüntüler İçin Sınıflandırma İşlemi.....	38
5.3. Veriseti-1 Bölütlenmiş Görüntüler İçin Sınıflandırma	40
5.4. Veriseti-2 Orijinal Görüntüler İçin Sınıflandırma İşlemi.....	42
5.5. Veriseti-2 Bölütleme Görüntüleri İçin Sınıflandırma İşlemi	44
5.6. Göğüs Bölgesi Bölütleme ve Sınıflandırma.....	46
6. SONUÇLAR VE ÖNERİLER	50
KAYNAKÇA	53
ÖZGEÇMİŞ	60

TABLÖLAR DİZİNİ

Tablo 1. Eğitim başarı değerleri.....	4
Tablo 2. Literatürde veriseti-1'e ait orijinal görüntüler için test doğruluk değerleri	4
Tablo 3. Bölütlemeye dayalı bazı çalışmalar	5
Tablo 4. Bölütleme değerleri (Zhao vd., 2019).....	5
Tablo 5. Veriseti-1'e ait bazı bilgiler	21
Tablo 6. Veriseti-2'deki görüntülerin sayısı ve özellikleri	22
Tablo 7. U-Net mimarisi parametreleri.....	26
Tablo 8. Bölütleme başarımlar değerleri.....	28
Tablo 9. ESA sınıflandırma ağ yapısı	30
Tablo 10. Bölütlemeye eğitim ve doğrulama verilerine ait başarı değerleri.....	38
Tablo 11. K katlamalı çapraz doğrulama ve diğer parametrik değerler.....	39
Tablo 12. Veriseti-1 orijinal görüntüler için sınıflandırma başarımlar sonuçları.....	40
Tablo 13. Veriseti-1 bölütlenmiş görüntüler için sınıflandırma başarımlar sonuçları	42
Tablo 14. K katlamalı çapraz doğrulama ve diğer parametrik değerler.....	42
Tablo 15. Orijinal görüntüler için sınıflandırma başarımlar sonuçları.....	44
Tablo 16. Siyah arka plan başarımlar sonuçları	45
Tablo 17. Beyaz arka plan başarımlar sonuçları	45
Tablo 18. Ortalama arka plan başarımlar sonuçları	45
Tablo 19. Morfolojik işlemler sonucunda üretilen maskelere dayalı sınıflandırma sonuçları	47
Tablo 20. Göğüs bölgesine dayalı bölütlenmiş görüntülerden elde edilen sınıflandırma değerleri.....	48
Tablo 21. Göğüs bölgesi bölütlemesine dayalı sınıflandırmaya ait çapraz doğrulama değerleri.....	49

ŞEKİLLER DİZİNİ

Şekil 1. Pnömoni	1
Şekil 2. Akciğer sınırları ve maskeler	5
Şekil 3. Doğal sinir hücresi (Gershenson, 2003).....	10
Şekil 4. Yapay sinir ağının yapısı	11
Şekil 5. Örnek bir ESA yapısı	13
Şekil 6. Evrişim işlemi	13
Şekil 7. Havuzlama katmanı	14
Şekil 8. Relu fonksiyonu	15
Şekil 9. Sigmoid fonksiyonu	15
Şekil 10. Tanh fonksiyonu	16
Şekil 11. Softmax fonksiyonu	16
Şekil 12. Düzleştirme katmanı örneği.....	17
Şekil 13. Tam bağlı katman	17
Şekil 14. Adım kaydırma	18
Şekil 15. Dolgu işlemi.....	18
Şekil 16. Örnek bir U-Net Mimarisi (Ronneberger vd., 2015).....	20
Şekil 17. Veriseti-1'e ait normal ve pnömoni görüntü örnekleri	21
Şekil 18. Veriseti-2'ye ait örnek görüntüler.....	22
Şekil 19. Karışıklık matrisi	22
Şekil 20. Çapraz doğrulama	24
Şekil 21. U-Net ve sınıflandırma blok diyagramı	25
Şekil 22. Önerilen değiştirilmiş U-Net modeli	27
Şekil 23. Bölütlemeye ait eğitim başarı grafikleri	28
Şekil 24. U-Net ile bölütlenmiş örnek görüntüler.....	29
Şekil 25. Yayma işlemi uygulanan maskelenmiş görüntüler	31
Şekil 26. Yayma işlemi uygulanan maske görüntüleri.....	31
Şekil 27. Loblara ait uç noktaların tespiti ve birleştirilmesi	32
Şekil 28. Lobların uç noktalarına göre üretilen göğüs bölgesi maske görüntüleri.....	33
Şekil 29. X ve Y değerlerinin görsel olarak gösterimi.....	33
Şekil 30. Uzun ve kısa kenar.....	34
Şekil 31. Görüntü bölgeleri-1.....	34
Şekil 32. Orijinal görüntü – Yeni görüntü	35


Şekil 33. Bölütlemeye eğitim ve doğrulama verilerine ait başarı grafikleri	37
Şekil 34. Veriseti-1 orijinal görüntüleri için eğitim başarı grafikleri.....	39
Şekil 35. Veriseti-1 orijinal görüntüleri için test başarı grafikleri	39
Şekil 36. Normal(N) ve bölütlenmiş-maskelenmiş(M) görüntüler	40
Şekil 37. Veriseti-1 bölütlenmiş görüntüler için eğitim başarı grafikleri	41
Şekil 38. Bölütlenmiş görüntüler için test başarı grafikleri	41
Şekil 39. Veriseti-2 orijinal görüntüler için eğitim başarı grafikleri.....	43
Şekil 40. Veriseti-2 orijinal görüntüler için test başarı grafikleri	43
Şekil 41. Siyah (S), Beyaz (B), Ortalama arka plan (O)	44
Şekil 42. Ortalama arka plan eğitim başarı grafikleri	46
Şekil 43. Morfolojik işlemler sonucunda elde edilen bölütlenmiş görüntüler	47
Şekil 44. Göğüs bölgesine dayalı bölütlenmiş görüntüler	48
Şekil 45. Sınıflandırmaya ait eğitim başarı grafikleri	49

SİMGELER VE KISALTMALAR DİZİNİ

P	: Girdi Sayısı
w	: Parametre Girdi Ağırlığı
x	: Girdi
b	: Yanlılık (bias)
f	: Aktivasyon Fonksiyonunu
OKD	: Ortalama Kenar Değeri
n_p	: Dizideki Toplam Pnömoni Görüntü Sayısı
n_n	: Dizideki Toplam Normal Görüntü Sayısı
Kk	: Kısa Kenar
Uk	: Uzun Kenar
i, n	: Tam Sayı, Toplam
AF	: Akciğer Filmi
AİK	: Alıcı İşletim Karakteristiği
BDT	: Bilgisayar Destekli
DL	: Derin Öğrenme
DÖ	: Derin Öğrenme
DSÖ	: Dünya Sağlık Örgütü
ESA	: Evrişimsel Sinir Ağı
ReLU	: Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
SGD	: Stokastik Gradyan İniş
TESA	: Tam Evrişimli Sinir Ağı
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ

1. GİRİŞ

Pnömoni (ya da bilinen adıyla zatürre), kısaca akciğerlere yerleşen bir enfeksiyon olarak tanımlanabilir. Bu hastalıkta akciğerdeki hava kesecikleri sıvıyla dolar ve bu da kişinin nefes almasını zorlaştırır. Bakteriyel her türlü organizma vb. pnömoninin önde gelen nedenidir (McLuckie vd., 2009). Bakterilerle beraber virüs veya mantar gibi otuzdan fazla bulaşıcı veya rahatsız edici mikrobun Şekil 1’de gösterildiği gibi gaz değişiminin gerçekleştiği alana nüfuz etmesiyle rahatsızlık başlar. Pnömoni hastalığında en sık görülen belirtiler; kaşıntılı öksürük, yüksek ateş, titreme ve nefes alma sırasında havasızlık veya göğüs ağrısıdır (Tursyngaliyeva, 2019).



Şekil 1. Pnömoni

Pnömoni, iskemik kalp hastalığı, inme ve kronik obstrüktif akciğer hastalığından sonra dünya çapında dördüncü en yaygın ölüm nedenidir ve yaşam kaybının ikinci en yaygın nedenidir (Ferkol ve Schraufnagel, 2014). Dünya Sağlık Örgütü (DSÖ)'ne göre, pnömoni her yıl 5 yaşın altındaki yaklaşık 2 milyon çocuğu öldürüyor ve sürekli olarak çocukluk ölümlerinin önde gelen tek nedeni olarak tahmin ediliyor (Rudan vd., 2008).

Bir solunum yolu enfeksiyonu olarak pnömoni, nispeten yüksek ölüm oranı, güçlü yayılımı ve yaygınlığı nedeniyle dünyanın her yerindeki ülkelerden büyük ilgi görmüştür. Zatürre (pnömoni) için erken teşhis ve tedavi, ölüm oranını önemli ölçüde azaltabilmektedir. Göğüs röntgeni, gelişmekte olan ülkelerde tercih edilen tanı aracı olmaya devam etmektedir ve tedaviyi yapan hekimler, pnömoniye teşhis ve tedavi etmek için sıklıkla DSÖ tavsiyelerini kullanır (DSÖ, 2013). Günümüzde de x-ışını teşhisi nispeten etkili bir yöntem olarak kabul edilmektedir.

Deneyimli bir doktorun röntgen akciğer grafisi üzerindeki görsel analizi yaklaşık 5 ile 15 dakika arasında sürmektedir. Vakalar yoğunlaştığında bu durum hiç şüphesiz doktorun klinik teşhisi üzerinde muazzam bir baskı oluşturmaktadır. Bu da görüntüleme doktorunun çıplak gözüne güvenmenin verimini düşürmektedir. Bu nedenle, pnömoninin klinik görüntü teşhisi için yapay zekâ kullanımı son yıllarda yaygınlaşmaktadır. Ayrıca yapay zekâ tanı koymada çok hızlı çalışmaktadır ve bir çok çalışma bu sistemlerin insanlardan daha iyi performans elde edebildiğini göstermiştir (Yue vd., 2020).

Yapay zeka tabanlı teşhis sistemlerinin başarısı iyi bir eğitim sürecine ve oluşturulan sınıflandırıcıların ayırtediciliğine bağlıdır. Bu da geliştirilen sistemlerde özellik çıkarımı aşamasının önemini artırmaktadır. Dolayısıyla özellik çıkarımında etkili sonuçlar verdiği için Evrişimsel Sinir Ağları (ESA) literatürdeki son çalışmalarda tercih nedeni olmuştur.

2. TEZ KONUSU VE KAPSAMI

Tıbbi hizmetler alanında insan potansiyelini aşan muazzam veri kümeleriyle başa çıkabilme yeteneği nedeniyle yapay zekâ yöntemlerinin kullanımı artmaktadır (Liang ve Zheng, 2020). Göğüs radyografisi de bu veri türlerinden biridir ve dünya çapında pnömoni tanısında kullanılan en önemli yöntemlerdendir (Jaiswal vd., 2019).

Bu tez çalışmasında akciğer x-ray görüntülerinden otomatik olarak pnömoni ve normal sınıflandırması yapabilecek derin öğrenme tabanlı bir sistem geliştirilmesi amaçlanmıştır. Böylece doktorların tanı ve teşhis koymasında yardımcı olabilecek bir aracın geliştirilmesi hedeflenmiştir. Benzeri amaçla literatürde yapılan birçok çalışma bulunmaktadır. Bu çalışmalarda yetişkinlere ait röntgen görüntülerinde yüksek başarımlara ulaşılmasına rağmen, çocuklara ait görüntülerde başarımlar nispeten düşük kalmıştır. Tez kapsamında çocuk röntgen görüntülerine odaklanılmış olup, başarımları artıracak stratejiler geliştirilmeye çalışılmıştır.

Tez kapsamında genel erişime açık pediatrik akciğer grafileri içeren iki veri seti kullanılmıştır. Bu verisetlerinden ilki (Veriset-1) 1-5 yaş arası çocuklara ait 5856 adet normal ve pnömonili akciğer görüntüsünden oluşmaktadır (Kermany vd., 2018). İkinci veri seti (Veriseti-2) ise ilk veri setinden alınan 1341 normal görüntü, 1345 pnömoni görüntü ve bunlara ait aynı sayılardaki maske görüntülerini içermektedir (Pham, 2021). Bu verisetleri ile ilgili detaylı bilgiler 3. bölümde verilmiştir.

Çalışma sonucunda kullanılan veri setleri arasında Veriseti-1 görüntülerinde normal görüntüler için geliştirilen ağ modelinde %97.18'lik doğrulama oranına, bölütleme için geliştirilen ağ modelinde %95.25'lik doğrulama oranına, Veriseti-2 için normal görüntülerde geliştirilen ağ modeliyle %98.33'lük doğrulama oranına, bölütleme için geliştirilen ağ modelinde %97.14'lük doğrulama oranına, geliştirilen yöntem ve ağ modelinde %98.55'lik doğrulama oranına ulaşılmıştır.

Çalışmada kullanılan Veriseti-1 üzerinde bölütleme olmaksızın normal görüntüler üzerinde (Kermany vd., 2018) yapmış oldukları çalışmada normal ile pnömoni olarak görülen göğüs röntgenlerinin karşılaştırılmasında %92.8 hassasiyet, %93.2 duyarlılık ve %90.1 özgüllük ile %92.8 doğruluk elde edildiği belirtilmiştir. Normal görüntüden pnömoninin saptanması için Alıcı İşletim Karakteristiği eğrisi altında kalan alan %96.8'dir. Bakteriyel ve viral pnömoninin ikili karşılaştırması, %88.6 duyarlılık ve %90.9 özgüllük ile %90.7'lik bir test doğruluğuna ve Alıcı İşletim Karakteristiği eğrisinin altındaki alan %94.0 olarak elde edildiği ifade etmişlerdir (Kermany vd., 2018).

Tablo 1’de Veriseti-1 ile (Yue vd., 2020) beş adet ESA modelinin (MobileNet, ResNet-18, ResNet-50, VGG19, ESA) eğitim seti doğruluğu ortalaması, eğitim seti kaybı, doğrulama seti doğruluğu, doğrulama seti kaybı ve test doğruluğu için beyan edilen değerler verilmiştir.

Tablo 1. Eğitim başarı değerleri

Yöntem	Doğruluk (Accuracy)	Kayıp (Loss)	Doğrulama Doğruluğu (Val_Accuracy)	Doğrulama Kaybı (Val_Loss)	Test Doğruluğu (Accuracy)
MobileNet	0.94454	0.15300	0.87119	0.25509	0.92986
ResNet-18	0.98795	0.03783	0.85388	0.28453	0.85515
ResNet-50	0.94342	0.13564	0.82982	0.37387	0.87486
VGG19	0.94318	0.18500	0.86044	0.50610	0.90529
ESA	0.93980	0.15152	0.72090	0.51290	0.91446

Benzeri şekilde Veriseti-1 için yapılan literatürdeki bazı çalışmalara ait pnömoni sınıflandırma çalışmalarının başarı oranları Tablo 2’te gösterilmiştir.

Tablo 2. Literatürde veriseti-1’e ait orijinal görüntüler için test doğruluk değerleri

Çalışma	Başarı (accuracy)
(Rajaraman vd., 2018).	96.2
(Ayan ve Ünver, 2019).	84.5
(Hashmi vd., 2020).	98.26
(Hashmi vd., 2021).	98.3


Tablo 1. ve Tablo 2. deki değerlere bakıldığında bu Veriseti-1 için bir miktar daha iyileştirme yapılabileceği anlaşılmaktadır. Tezde ele alınan bölütleme ön işleminin sınıflandırma başarısını artıracak fikrine yoğunlaşmış olup, literatürde akciğer bölütlemesi ile ilgili çalışmalar irdelenmiştir. Tablo 3’te bazı çalışmalara ait bölütleme doğruluk değerleri verilmiştir. Bu çalışmalarda güncel bölütleme yaklaşımları tercih edilmesine rağmen tez kapsamında ele alınan verisetleri kullanılmamış olup, her bir çalışmada tercih edilen verisetleri de tabloda ayrıca verilmiştir.

Tüm bu çalışmalar çocuk göğüs görüntüleri üzerinde de bölütlemeye dayalı bir çalışmaya ihtiyaç duyulduğunu göstermektedir. Ayrıca çocuk görüntülerinde özellikle duruş bozukluklarından kaynaklı sınıflandırma ve bölütlemelerde başarısız sonuçlar alınması beklenmektedir. Bununla ilgili bölütmenin başarısını artırmak için (Zhao vd., 2019), Veriseti-1 üzerinde yaptıkları akciğer bölütlemesi ve göğüs kafesi bölütlemelerini karşılaştırmıştır.

Tablo 3. Bölütlemeye dayalı bazı çalışmalar

Yazar	Veri Seti	Yöntem	Doğruluk (%)
(Cao ve Zhao, 2021)	NIH ve JRST	Değiştirilmiş U-Net	0.9701, 0.9334
(Diniz vd., 2021).	İlgili veri setleri	Değiştirilmiş U-Net	77.1 (Dice) 99.76 Ortalama
(Rahman vd., 2020)	X-ray Görüntüleri	U-Net	92.82
(Pang vd., 2019)	ILD	Çeşitli Kombinasyonlar ile Otomatik Bölütleme Modeli	89.42 (Dice)
(Monshi vd., 2021)	İlgili veri setleri	Optimize edilmiş U-Net	0.976 ve 0.973

Göğüs kafesi bölütleme yaklaşımının klasik akciğer bölütlemesinden farkı Şekil 2’de gösterilmiştir. Şekilden de anlaşılacağı üzere grafi üzerinden eksik veya hatalı seçimler yapılmış olsa bile göğüs kafesi daha geniş bir alanı kaplayacağından seçilmemiş bölgeleri dahil etme ihtimali yüksektir. Bu da sınıflandırmanın başarısına olumlu katkı sağlayacağı düşüncesini doğurmaktadır. Buradaki kritik nokta, akciğer seçimi sırasında pnömoni için bilgi içerebilecek akciğer bölgelerinin (özellikle buzlanmadan kaynaklı kontrast değişikliğinden dolayı) bölütme alanının dışında kalmasının önüne geçmektedir. Böylece sınıflandırma başarısının artırılabilceği düşünülmüştür.



Şekil 2. Akciğer sınırları ve maskeler

Zhao vd., (2019) yaptıkları çalışmada Tablo 4’te verilen akciğer bölütlemesi ile göğüs kafesi bölütleme değerlerine ulaşmışlardır. Bu tabloda göğüs kafesi bölütlemesinin daha başarılı olduğu ulaşılan değerlerle gösterilmiştir.

Tablo 4. Bölütleme değerleri (Zhao vd., 2019)

Metrik	Akciğer Bölütleme	Göğüs Kafesi Bölütleme
Jaccard benzerlik katsayısı	0.910	0.950
Dice katsayısı	0.948	0.974

Tüm bu durumlar dikkate alındığında, çocuk göğüs grafilerinden pnömoni sınıflandırmasının başarısını artırmak için öncelikle bir bölütleme sürecinin

gerçekleştirilmesi ve bölütleme sonucunda elde edilen maskelenmiş görüntüler üzerinden sınıflandırmanın yapılması bu tezin çalışma konusunu oluşturmaktadır. Dolayısıyla tez çalışması iki aşamalı olarak kurgulanmıştır:

İlk aşamada akciğer röntgen görüntülerinden sadece akciğer bölgelerinin seçilebileceği bir bölütleme işlemi gerçekleştirilmiştir. Bu aşamada yüksek doğruluklu bölütleme elde edebilmek için detayları 4. bölümde anlatılan özgün bir U-Net mimarisi tasarlanmıştır. İkinci aşamada ise bölütleme sonucunda elde edilen maskelenmiş akciğer görüntüleri üzerinden sınıflandırma yapan ve detayları 5. bölümde anlatılan özgün bir derin ağ mimarisi geliştirilmiştir.



3. MATERYAL VE YÖNTEM

3.1. Bölütleme

Görüntü bölütleme, görüntüdeki bileşenleri önceden tanımlanmış ölçütlere göre anlamlı parçalara ayırarak görüntüyü daha anlaşılır yapan ve analiz için kolay hale getiren önemli bir görüntü işleme yöntemidir. Bölütleme sonuçları nesne sınıflandırma, özellik çıkarımı ve görüntü yorumlama gibi görüntü analiz süreçlerini etkilemektedir (Öztürk ve Öztürk, 2021).

Gite vd., 2022 bölütlemenin avantajlarını aşağıdaki 3 başlık altında toplamışlardır:

1. Görüntünün bölütlenmesi önemli bir tıbbi görüntüleme sürecidir. Otomatik bir süreçle ilgi bölgesi (ROI)'ni çıkarır. Bölütleme, görüntüde vücut organlarını/dokularını birbirinden ayırmak gibi belirli bir ilgiye dayalı olarak bir alana böler.
2. Sınıflandırma sinir ağı algoritmalarının bölümlere ayrılmış radyolojik görüntüler üzerinde uygulanması, bölütleme doğruluğunu önemli ölçüde iyileştirebilir.
3. Bölütleme, hesaplama maliyetini artırabilir; ancak hastalık teşhisinin toplam maliyetini önemli ölçüde azaltabilir.

Literatürdeki çalışmalar göz önünde bulundurulduğunda en iyi denilebilecek bir görüntü segmentasyon modeli bulunmadığını söylenebilir. Her segmentasyon modelinin başarısı, yapılan çalışmanın ve kullanılan görüntünün türüne göre değişkenlik gösterebilmektedir (Kaya ve Önal, 2021).

Sağlık alanında görüntü işleme teknikleri yardımıyla bölütleme yapılabilmektedir. Örneğin, beyin MR görüntülerinin otomatik olarak bölütlenmesi (Patil vd., 2015) ve akciğer tümörlerinin (Wu vd., 2019) tespiti için fuzzy c-means algoritmasının kullanıldığı çalışmalar mevcuttur. Başka çalışmada ise meme tümörlerinin ultrason görüntülerinin bölütlenmesi için watershed algoritması ve aktif kontur modeli kullanılmıştır (Ma vd., 2015).

Görüntü bölütleme sürecinde, geleneksel görüntü işleme ve derin öğrenme yöntemleri karşılaştırıldığında, genel olarak derin öğrenme yöntemlerinin daha iyi sonuçlar elde ettiği rapor edilmektedir. Derin öğrenmenin görüntü sınıflandırma ve algılamadaki başarısı, temel olarak, yüksek seviye özellikleri ve ayırt edici temsilleri doğrudan verilerden öğrenme yeteneğinden kaynaklanmaktadır (Litjens vd., 2017). Derin öğrenme, üst düzey özellikleri öğrenme ve karmaşık kalıpları işleme yeteneği nedeniyle

tıbbi görüntü segmentasyonunda dikkate değer bir performans göstermiştir (Hesamian vd., 2019).

Sonuç olarak, sağlık alanındaki bölütleme çalışmalarında derin öğrenme yöntemleri klasik görüntü işleme yöntemlerine göre birçok avantaja sahiptir. Bu avantajlar arasında yüksek performans, özelleştirilebilirlik ve çok amaçlılık yer almaktadır. Bu özellikler, derin öğrenmeyi segmentasyon gibi tıbbi görüntü analizi görevleri için çekici bir teknik haline getirmektedir. Son yıllarda da yapılan çalışmalara bakıldığında bölütlemeye dayalı çalışmalarda derin öğrenme tabanlı yaklaşımların tercih edildiği dikkat çekmektedir. Evrişimsel Sinir Ağları ve birçok kodlayıcı-kod çözücü tabanlı birçok bölütleme yöntemi mevcuttur (Schmidt vd., 2018).

Derin öğrenme akciğer bölütlemesinde de sıklıkla kullanılmaya başlanmıştır. Örneğin, Dong vd., (2017) bir çift kodlayıcı-dekodlayıcı derin öğrenme ağı kullanarak akciğer bölütlemesi yapmak için bir yöntem önerdiler. Bu yöntem, çapraz katmanlı bağlantılar ve salınımlı bir bileşen kullanarak akciğerlerin doğru bir şekilde bölütlenmesini sağlamıştır. Deneyler, önerilen yöntemin, birkaç farklı veri setinde başarılı bir şekilde uygulanabileceğini göstermiştir. Zhang vd., (2019) ise akciğer bölütlemesi yaparken, akciğer loblarını da ayrıntılı bir şekilde bölütlemek için bir derin öğrenme tabanlı yöntem önerdiler. Bu yöntem; bir evrişimli sinir ağı ve bir regresyon bileşeni kullanarak, akciğer loblarının bölütlenmesi için birkaç farklı veri setinde test edilmiştir. Sonuçlar, önerilen yöntemin geleneksel yöntemlere göre daha yüksek bir doğruluk oranı sağladığını göstermiştir. Yine bir başka çalışmada Wand vd., (2020) akciğer bölütlemesi yapmak için iki adımlı bir evrişimli sinir ağı kullanarak bir yöntem önerdiler. Bu yöntem, akciğerlerin sınırlarını önce tahmin etmek için bir evrişimli sinir ağı kullanır ve ardından akciğerleri tam olarak bölütlemek için ikinci bir evrişimli sinir ağı kullanmaktadır.

Bu çalışmalar, derin öğrenme tekniklerinin akciğer bölütlemesi yapmak için etkili bir araç olduğunu göstermektedir. Akciğer bölütlemesi için derin öğrenme teknikleri şu şekilde gruplandırılabilir:

- **Evrişimli sinir ağları (Convolutional Neural Networks):** Akciğer görüntüleri, konvolüsyonel katmanlar, örneklemeyi azaltan katmanlar, yoğun katmanlar ve çıkış katmanları içeren bir ESA kullanılarak bölümlenir (Golan vd., 2018; Zhang vd., 2018; Li vd., 2019; Cui vd., 2020).
- **Katmanlı Önceden Öğrenme (Layer-wise Pretraining):** Veri kümesi yeterince büyük olmadığında, tabakalı çıkarma kullanarak önceden eğitilmiş bir

ağa dayalı özellik çıkarma yapmak mümkündür (Chen vd., 2019; Akcay vd., 2021; Huang vd., 2020; Setio vd., 2017).

- **Çoklu Mod Özellik Çıkarma (Multimodal Feature Extraction):** Akciğer görüntülerinin yanı sıra, derin öğrenme teknikleri, örneğin radyografik özellikler ve klinik veriler gibi diğer veri türlerinden de özellikler çıkarmak için kullanılabilir (Çiçek vd., 2019; Wang vd., 2019; Kim vd., 2019; Luo vd., 2020).
- **Kodlayıcı-dekodlayıcı Ağlar (Encoder-decoder Networks):** Derin öğrenme yöntemlerindeki bu tür ağlar, bir görüntüyü bir dizi işlemden geçirerek kodlar ve ardından bu kodlamayı kullanarak görüntüyü yeniden oluşturarak bölütlemeyi gerçekleştirir (Karami vd., 2020; Zhang ve Zhang, 2020; Wang vd., 2019; Dai ve Cao, 2020).

3.2. Derin Öğrenme


Derin öğrenme (DÖ), beynin yapısından esinlenerek geliştirilen bir makine öğrenimi alt dalıdır (Narin vd., 2021). Bir başka tanımlamayla derin öğrenme; karmaşık yapılardan veya doğrusal olmayan dönüşümlerden oluşan birden çok nöron katmanını kullanarak, üst düzey veri soyutlamalarını modellemeye çalışan Yapay Sinir Ağları'nın geliştirilmiş bir türüdür (Hao vd., 2016). Derin öğrenme ağlarının, Yapay Sinir Ağlarından en önemli farkı çoklu katman yapısına sahip olmasıdır. Ayrıca klasik makine öğrenimlerinden farklı olarak öznitelik çıkarımı sürecini kendi bünyesinde barındırır. Güçlü öznitelik çıkarımı ve başarılı sınıflandırma özelliklerinden dolayı derin öğrenme, tıbbi görüntüleme de hastalık tespit etmek amacıyla sıklıkla tercih edilmektedir (Puttagunta ve Ravi, 2021).

3.2.1. Yapay Sinir Ağları


Genel anlamda Yapay Sinir Ağları (YSA); insan beyninin biyolojik sinir yapısını taklit ederek, sinirsel algılayıcılar yardımı ile önceden öğrenilmiş ya da sınıflandırılmış bilgileri kullanarak yeni bilgiler oluşturabilen, aynı zamanda karar verebilen bilgisayar programlarıdır (Efe vd., 1999). Bir sinir hücresi, vücudumuzdaki sinir sistemi tarafından yapılan elektro-kimyasal iletişimin temel birimidir. Sinir hücreleri, dış dünyadaki uyaranları algılar ve bu uyaranları elektriksel sinyaller şeklinde beyne iletir. Sinir hücresi, Şekil 3.'te gösterildiği gibi hücrenin uçlarındaki dendritler ve asıl hücre boyunca uzanan bir axon tarafından oluşur. Dendritler, dış dünyadaki uyaranları algılamak için tasarlanmıştır ve axon ise bu uyaranları beyne taşıma görevini üstlenir. Bir hücre aktive olduğunda, dendritlerdeki uyaranların birikmesi sonucu axondaki elektriksel potansiyel

değişir. Eğer uyarılar yeterince yoğun veya güçlü ise, elektriksel potansiyel sinir hücresinin depolarizasyonu sonucu bir sınır değerine (eşik değer) ulaşır. Bu, sinir hücresinin beyine gönderdiği elektriksel sinyal olarak ifade edilir (Gershenson, 2003). Bu sinyal, axon ucunda bulunan terminal bölgeler aracılığıyla sinir hücresi ile diğer sinir hücreleri arasında kimyasal maddeler olarak adlandırılan neurotransmitterler tarafından taşınır. Neurotransmitterler, sinaptik boşluk adı verilen bir boşlukta bulunan sinir hücresinin terminal bölgesinden bir diğer sinir hücresinin dendritlerine geçerek sinir hücreleri arasında iletişimi sağlar.

Bir yapay sinir hücresi de gerçek bir sinir hücresinin çalışma mantığını simüle eder. Birden çok yapay sinir hücresini bir araya getirilerek oluşturulan yapıya Yapay Sinir Ağı denmektedir. Teknik olarak Yapay Sinir Ağı'nın görevi, bir girdi kümesi olarak kendisine verilen bilgilere yanıt olarak Şekil 4'te verildiği gibi bir çıktı üretmektir. Bunu yapmak için ağ, belirli örneklerle eğitilir. Ağ, daha sonra genelleme ve karar verme seviyesine ulaşır. Daha sonra elde edilen bu yetenekle çıktıları belirler (Keskenler ve Keskenler, 2017).



Şekil 3. Doğal sinir hücresi (Gershenson, 2003).



Şekil 4. Yapay sinir ağının yapısı

Her nöronun farklı ağırlıktaki girişleri ve bir çıkışı vardır. Bu amaçla toplam girdilerin farklı ağırlıkları Eşitlik 1 ve Eşitlik 2’deki gibi tanımlanır.

$$n = \sum_{i=1}^P W_i X_i + b \quad (\text{Eşitlik 1})$$

$$f(n) = f\left(\sum_{i=1}^P w_i x_i + b\right) \quad (\text{Eşitlik 2})$$

Burada; P girdi sayısıdır, w girdi ağırlığıdır, x girdidir, b (bias) yanlılık veya denge değeridir. Ağırlıklı girdiler ve önyargı ile birlikte her nöronun toplamı iletilir. Aktivasyon fonksiyonu ve sonuç olarak çıktı buna bağlıdır nöron elde edilir. Aktivasyon fonksiyonunu f ile belirtilmiştir (Haykin, 1994).

Yapay sinir ağlarının temel özelliği, eğitim veri setinin üstünde çalışarak ağırlıkları belirlemesidir. Her bir gözlemle ağırlıklar değişerek zamanla daha güçlü ve sapması azalan bir yapıya dönüşecektir. Böylece çıktı olarak verdiği tahminde ya da yapıda genelleştirme yeteneği daha güçlü olacaktır. Ağın ürettiği sonuçlar ise; ağa girilen bilgilerin kendi ağırlıkları (W) ile çarpımlarının toplanması sonucu elde edilen net girdinin, bir transfer fonksiyonu ile işlenmesi ile çıktı katmanından alınmaktadır (Öztemel, 2003).

3.2.2. Derin Ağ Mimarisi

Derin Öğrenme, beyin yapısı ve işlevinden ilham alan ve makine öğrenmesi alt dalı olan, büyük miktarda veriden öğrenme yoluyla karmaşık sorunları modelleme ve çözme

amaçlayan bir tekniktir. Bu, derin öğrenme algoritmalarının görüntü sınıflandırması, konuşma tanıma ve doğal dil işleme gibi görevleri olağanüstü bir doğrulukla yerine getirmesini mümkün kılar (LeCun vd., 2015).

Derin öğrenme makine öğreniminin bir parçasıdır ve öznetelikleri ham girdi verilerinden otomatik olarak çıkarabilir (Liu vd., 2017). Derin öğrenme, birden çok soyutlama düzeyiyle farklı özellikleri öğrenmek için birden çok gizli katman (derin ağlar) içermektedir. Böylece, daha düşük seviyeli özellikler olarak tanımlanan, daha yüksek seviyeli öğrenilmiş özelliklerle, birden fazla seviyede iyi temsilleri keşfetmek için girdi dağılımındaki bilinmeyen yapıdan yararlanmaya çalışır (Wani vd., 2020).


Derin öğrenme, biyomedikal alanında bölütleme amaçlı kullanım için de etkilidir. Örneğin, CT ve MRI görüntülerindeki patolojik bulguları doğru bir şekilde tanımlamak için derin öğrenme algoritmaları kullanılmıştır (Girshick vd., 2014; Lakhani vd., 2017). Aynı şekilde derin öğrenme algoritmaları, hasta sonuçlarını ve tedavi cevabını tahmin etmek için de kullanılmıştır; örneğin, kalp hastalığı riskini tahmin etmek (Huang vd., 2018) veya ilaç etkinliğini tahmin etmek (Ma vd., 2019). Derin öğrenme algoritmaları, mammografi görüntülerinin kanser tespitinde de kullanılmıştır. Bir çalışmada derin öğrenme yöntemleri kullanılarak mammografi görüntülerindeki kanser tümörlerinin doğru bir şekilde tespit edilmesi sağlanmıştır (Wang vd., 2016). Başka bir çalışmada ise derin öğrenme yöntemleri kullanılarak deri hastalıklarının tanımlanmasında yüksek doğruluk oranları elde edilmiştir (Esteva vd., 2017). Ultrason görüntülerinin bebeğin gelişimi hakkında bilgi vermek için yine derin öğrenme yöntemlerinden yararlanılmıştır (Kermany vd., 2018).

3.2.3. Evrişimsel Sinir Ağı

Tıbbi görüntüleri analiz etmek için kullanılan çeşitli yöntemler arasında, Evrişimsel Sinir Ağları (ESA) aracılığıyla görüntü bölümlendirme, en popüler yaklaşımlardan birisi olmuştur (Tursyngaliyeva, 2019). ESA, ilk olarak LeCun vd., (1998) tarafından önerilmiştir. Bu çalışmada ESA'ların el yazısı tanıma gibi görsel işleme görevleri için başarılı bir şekilde kullanılabileceğini gösterilmiştir. Ayrıca bu çalışma, ESA'ların yapısını ve uygulanabileceği görsel işleme görevlerini ortaya koyarak, makine öğrenimi ve yapay zeka araştırmalarının önemli bir dönüm noktası olarak kabul edilir.

Çok katmanlı algılayıcı şeklinde oluşturulan ESA, günümüzde nesne tanıma ve sınıflandırma alanında başarılı sonuçlar üretmektedir. Derin evrişimsel sinir ağlarına dayalı geliştirilen modeller, birçok avantaja sahiptir. Bu avantajlardan biri de bölütleme ve nesneyi arka plandan ayırma gibi ön işlem aşaması uygulanmaksızın ileri düzey


görevler gerçekleştirilebilmektedir (Türkoğlu vd., 2021). Evrişim işlemi, başlangıçta rastgele değerlere sahip görüntü filtresinin giriş görüntüsü ile konvolüsyon işlemine tabi tutulmasıdır. Şekil 5'te bir ESA mimarisi verilmiştir. Bir ESA; evrişim, havuzlama gibi alt katmanları içerebilir.



Şekil 5. Örnek bir ESA yapısı

3.2.4. Evrişim Katmanı

Evrişim katmanı konvolüsyon (convolution), aktivasyon fonksiyonu (relu) ve havuzlama (pooling) evrelerini barındırmakta ve yüksek boyutlu veriden düşük boyutlu özniteliklerin çıkarılmasını sağlamaktadır. Probleme özgü olarak evrişim katmanının ardışık bağlanma derinliği değişmektedir. Sınıflandırma katmanı ise düşük boyutlu öz nitelikler ile kategorilerin eşleşmesini sağlar ve genellikle tam bağlı bir yapay sinir ağı mimarisine sahiptir (Fırıldak ve Talu 2019). Derin sinir ağlarının temeli, evrişim katmanından oluşmaktadır. Bu katmanda, 2×2 , 3×3 ve 5×5 gibi boyutlu filtrelerin tüm görüntü üzerinde dolaştırılmasına dayanmaktadır. Böylece görüntüdeki daha belirgin öznitelikler çıkartılarak yeni bir görüntü elde edilir (Kızrak ve Bolat 2018). Şekil 6'da örnek bir evrişim işlemi gösterilmektedir.




Şekil 6. Evrişim işlemi

Şekil 6’da tek kanallı 6×6 boyutundaki görüntü matrisi üzerinde 3×3 boyutundaki evrişim filtresi ile görüntü değerleri çarpılarak hesaplama işlemi gösterilmiştir. Örneğin $(9 \times 1 + 5 \times 1 + 1 \times 0 + 3 \times 1 + 1 \times 0 + 4 \times 1 + 6 \times 0 + 8 \times 0 + 9 \times 1 = 30)$ şeklinde hesaplanır. Bu işlem 3×3 filtresinin giriş görüntüsü üzerinde sağa-sola ve aşağı-yukarı adım değeri üç (3) ile kaydırılmasıyla işlemler gerçekleştirilir. Bu kaydırma işlemi, tüm görüntü üzerinde uygulanır ve ideal seviyede öz niteliklere dayalı yeni bir görüntü elde edilir.

3.2.5. Havuzlama Katmanı


Evrişimli sinir ağının havuzlama katmanında kullanılan filtreler, ortalama değer veya maksimum değer hesaplama ilkesine göre çalışır. Havuzlama işlemi ekseri 2×2, 3×3,..., n×n boyutunda filtreler uygulanarak yapılır. Ortalama havuzlama, filtre boyutunun alanına giren piksel değerlerin toplamının filtre pencere boyutuna bölünmesi prensibiyle çalışır. Maksimum havuzlama, filtre boyutunun alanına giren piksel değerlerinden büyük olan değer belirlenmesi işlemidir (Ali ve Hanbay, 2018). Şekil 7’de örnek bir maksimum havuzlama süreci gösterilmiştir. Minimum havuzlama ise filtre boyutunun alanına giren piksel değerlerinden en küçük değerin belirlenmesi işlemidir.



Şekil 7. Havuzlama katmanı

3.2.6. ReLU Fonksiyonu

Relu fonksiyonu güçlü matematiksel temellere sahip olan Hahnloser vd., (2000) tarafından tanıtilen bir fonksiyondur. Evrişimsel sinir ağları için aktivasyon fonksiyonları önemli bir etkidir. Relu, derin sinir ağlara dayalı geliştirilen modellerde en yaygın kullanılan aktivasyon fonksiyonudur (Türkoğlu vd., 2021).



Şekil 8. Relu fonksiyonu

$$f(x) = \{ 0 \text{ eğer } x < 0 \}$$

(Eşitlik 3)


$$f(x) = \{ x \text{ eğer } x \geq 0 \}$$

(Eşitlik 4)

Fonksiyon (3) x 'in 0'dan küçük değerleri için 0 (sıfır), fonksiyon (4) x 'in 0'dan büyük ve eşit değerleri için x değerini üretir. Aktivasyon fonksiyonları içinde Relü fonksiyonundan hariç Sigmoid, Tanh ve Softmax aktivasyon fonksiyonları sıklıkla kullanılmaktadır.

3.2.7. Sigmoid Fonksiyonu

Fonksiyon giriş değerinin 0 ile 1 arasında değer aralığında kalmasını sağlayan, doğrusal olmayan sürekli bir fonksiyondur. Şeki 9'da grafiğin sağ ve solundaki uç değerlerde türevin 0'a yaklaştığı görülmektedir.




Şekil 9. Sigmoid fonksiyonu

Eşitlik 5'te sigmoid aktivasyon fonksiyonu gösterilmektedir.

$$S(x) = \frac{1}{1+e^{-x}} \quad (\text{Eşitlik 5})$$

3.2.8. Tanh Fonksiyonu

Tanh fonksiyonu şekil 10’da görüldüğü üzere -1 ile 1 aralığında değerler alan, giriş değeri ne kadar büyükse, çıkış değeri 1’e o kadar yakın; aksi durumda giriş değeri ne kadar küçükse, çıkış değeri -1’e o kadar yakın olur.




Şekil 10. Tanh fonksiyonu

Eşitlik 6’da Tanh aktivasyon fonksiyonu gösterilmektedir.

$$T(x) = \frac{e^{2x}-1}{e^{2x}+1} \quad (\text{Eşitlik 6})$$

3.2.9. Softmax

Genellikle multi-Sigmoid olarak da bilinen bu softmax fonksiyonu, çok sınıflı bir hedef değişkeni (çok sınıflı sınıflandırma) içeren sınıflandırma problemleri için uygun bir aktivasyon fonksiyonudur. Softmax, çıktı olarak her sınıf için bir olasılık sonucu verir.




Şekil 11. Softmax fonksiyonu

Eşitlik 7’de Softmax aktivasyon fonksiyonu gösterilmektedir.

$$Softmax(z_i) = \frac{\exp(z_i)}{\sum_j \exp(z_j)} \quad (\text{Eşitlik 7})$$

3.2.10. Düzleştirme Katmanı


ESA temelinde geliştirilen katmanlardan elde edilen verileri düzenli hale getirmek için düzleştirme katmanı kullanılır. Bu işlem, giriş verilerinin belirli bir aralıkta olmasını sağlar ve ağı performansı olumlu yönde etkiler (Doğan ve Türkoğlu, 2018).



Şekil 12. Düzleştirme katmanı örneği

3.2.11. Tam Bağlı Katman


Tam bağlı katman, kısaca ileri sinir ağlarını beslemektir. Tam bağlı katmanlar, ağdaki son birkaç katmanı oluşturur. Tam bağlı katmana giriş, düzleştirilen ve daha sonra tam bağlı katmanla beslenen son havuz veya evrişimli katmandan gelen çıktıdır.



Şekil 13. Tam bağlı katman

3.2.12. Kaydırma Adımı


Kaydırma adımı (Stride), evrişim işlemi için ağırlık matrisi olan filtrenin görüntü üzerinde tek piksellik adımlarla veya birden daha büyük adımlarla kayacağını bildirir. Bu işlem, çıktı boyutunu doğrudan etkileyen başka bir parametredir. Şekil 14'te evrişim işlemi sırasında 3 piksellik adım kaydırma uygulanmıştır.



Şekil 14. Adım kaydırma

3.2.13. Dolgu İşlemi

Evrişim uygulandıktan sonra giriş ile çıkış arasındaki boyut farkı dolgu (padding) işlemi (piksel ekleme) yapılarak giderilebilir. Şekil 15'te 12×12'lik matris 2 piksellik dolgu ile 16×16'lık hale getirilmektedir.



Şekil 15. Dolgu işlemi

3.3. U-Net Mimarisi

U-Net, biyomedikal görüntü segmentasyonu için geliştirilmiş bir konvolüsyonel sinir ağıdır. U-Net, biyomedikal alanda ve diğer görüntü dönüştürme görevlerinde bölütleme problemlerini çözmek için kullanılan bir ESA mimarisidir. U-Net sınırlı verilerle çok etkili olduğu için piksel tabanlı görüntü bölütlemeye diğer evrişimli modellere göre daha başarılıdır (Ronneberger vd., 2015).


U-Net mimarisi, iki temel bölümden oluşur: kodlayıcı (encoder) ve kod çözücü (decoder). Kodlayıcı, girdi görüntüsünden daha küçük boyutlu öznitelik haritaları elde etmek için birkaç evrişimli katman ve toplama katmanları içerir. Dekodlayıcı ise öznitelik haritalarını girdi boyutuna geri dönüştürmek için birkaç katman içerir. U-Net mimarisinde ayrıca, kodlayıcı ve kod çözücü arasında atlama (skip) bağlantıları olarak bilinen, paralel bir bağlantı bulunur. Bu bağlantılar, daha yüksek çözünürlüklü öznitelik haritalarının kod çözücüye iletilmesini sağlar. Böylece modelin daha iyi bir görüntü bölütleme yapması amaçlanır.

U-Net, biyomedikal görüntüleme uygulamaları gibi daha küçük veri kümeleri için özellikle faydalıdır, ancak aynı zamanda başarılı bir şekilde genel amaçlı görüntü bölütlemeye de kullanılmıştır. Basit, esnek ve genişletilebilir bir yapıda olup yüksek kalitede piksel düzeyinde bölütleme sonuçları sunmaktadır. Bu özellikleri sayesinde, tıbbi görüntüleme toplulukları içerisinde çok yüksek bir fayda sağlamakta ve tıbbi görüntüleme bölütleme görevleri için U-Net ve varyasyonları yaygın bir şekilde kullanılmaktadır. (Koç vd., 2021).

Akciğer bölütlemesinde U-Net modelinin kullanılması ile ilgili literatürde birçok araştırma bulunmaktadır. Örneğin, Gazal ve Muhammed (2019) U-Net modelinin CT görüntülerindeki akciğerleri doğru bir şekilde bölümlendirdiğini göstermiştir. Çalışmanın sonucunda, U-Net modelinin yüksek hassasiyet ve doğruluk sağladığı sonucuna varılmıştır. Başka bir çalışmada Hussein ve Tizhoosh (2020) U-Net modelinin transfer öğrenme yöntemi ile kullanılması incelenmiştir. Araştırmacılar, modelin transfer öğrenme ile eğitilmesinin, modelin doğruluğunu ve performansını artırdığını göstermiştir. Ayrıca, çalışma sonucunda U-Net modelinin, diğer yöntemlere kıyasla daha iyi sonuçlar verdiği belirtilmiştir. Aydın ve Bingöl (2020) ise U-Net mimarisini bölütlemesi zor olan çocuk akciğer görüntüleri üzerinde başarılı bir şekilde uygulamışlardır.

U-Net mimarisinde her mavi kutu, çok kanallı bir özellik haritasına karşılık gelir. Kanal sayısı kutunun üstünde belirtilmiştir. x-y boyutu kutunun sol alt kenarında

verilmiştir. Beyaz kutular, kopyalanan özellik haritalarını temsil eder. Oklar farklı işlemleri gösterir (Ronneberger vd., 2015).



Şekil 16. Örnek bir U-Net Mimarisi (Ronneberger vd., 2015)

3.4. Kullanılan Veri Setleri

3.4.1. Veriseti-1

Kermany vd.,(2018)'nın hazırladıkları veritabanı, akciğer röntgen görüntülerinden oluşan bir veri kümesidir. Bu veritabanı, bilgisayarlı görüntüleme ve makine öğrenmesi tekniklerinin geliştirilmesi ve test edilmesi için kullanılmaktadır. Veritabanı, 5.856 göğüs tomografisi görüntüsü içermektedir ve bu görüntülerden 1.583'ü normal, 4.273'ü ise pnömoni hastalığına sahip 1-5 yaş arası çocuklara aittir. Veritabanı, ayrıca bu görüntülerin etiketli olduğu, yani pnömoni olan görüntülerin doğrulanabildiği bir yapıya sahiptir.

Bu veritabanı, araştırmacıların makine öğrenmesi algoritmalarını eğitmek, test etmek ve doğrulamak için kullanabilecekleri bir kaynak sağlamaktadır. Özellikle, akciğer hastalıklarının teşhisinde bilgisayarlı görüntüleme teknikleri kullanılabileceği için bu veritabanı, bu tür çalışmalar için oldukça faydalıdır.


Göğüs röntgen görüntülerinin analizi için, tüm düşük kaliteli veya okunamayan taramalar çıkarıldığı belirtilmiştir. Teşhisler için görüntüler; daha sonra yapay zekâ sistemini eğitmek amacıyla, onaylanmadan önce iki uzman doktor tarafından derecelendirilmiştir. Puanlama hatalarını hesaba katmak için değerlendirme seti üçüncü

bir uzman tarafından da kontrol edilmiştir (URL-1, 2022). Tablo 5’te Veriseti-1 (Kermany vd., 2018)’e ait bilgiler yer almaktadır.

Tablo 5. Veriseti-1’e ait bazı bilgiler

Eğitim Verisi		Test Verisi		Doğrulama Verisi		Format	TOPLAM
Normal	Pnömoni	Normal	Pnömoni	Normal	Pnömoni	JPG Farklı boyutlarda	5856
1.341	3.875	234	390	8	8		


Şekil 17’de veri setin içerisinde seçilmiş normal (ilk satır) ve pnömoni (ikinci satır) görüntü görüntülere örnekler verilmiştir.



Şekil 17. Veriseti-1’e ait normal ve pnömoni görüntü örnekleri

3.4.2. Veriseti-2

Veriseti-2, Veriseti-1’den seçilen bazı çocuk akciğer görüntüleri ile oluşturulmuştur (Pham, 2021). Bu setin ilkinde farkı seçilen görüntülere ait sadece akciğer bölgelerini temsil eden maske görüntülerine sahip olmasıdır. Kullanılan görüntüler ve bunlar için işaretlenen maske görüntülere örnekler Şekil 18’de gösterilmiştir. İlk satırda normal görüntüler ve bu görüntülere ait maske görüntüleri, ikinci satırda ise benzeri şekilde pnömoni görüntüler verilmiştir.



Şekil 18. Veriseti-2'ye ait örnek görüntüler

Tablo 6'da Veriseti-2 içerisindeki görüntülerin özellikleri verilmiştir. Tablodan da anlaşılacağı üzere normal ve pnömoni görüntü sayıları birbirine yakın olarak tercih edilmiş ve toplamda 2.686 adet görüntü kullanılmıştır.

Tablo 6. Veriseti-2'deki görüntülerin sayısı ve özellikleri

	Normal		Pnömoni	
	Resim	Maske	Resim	Maske
Adet	1341	1341	1345	1345
Çözünürlük	299×299	256×256	299×299	256×256
Format	PNG	PNG	PNG	PNG

3.5. Değerlendirme Metotları

3.5.1. Karışıklık Matrisi

Makine öğrenmesindeki sınıflandırma probleminde, bir karışıklık matrisi (Confusion Matrix), bir algoritmanın performansının değerlendirilmesini sağlayan özel bir tablo düzenidir. Matrisin her satırı veya sütunu öngörülen değerleri temsil ederken, her satır veya sütun, gerçek bir değerdeki değerleri temsil eder (Powers, 2020). Karışıklık matrisi, verilerin mevcut durumu ile sınıflandırma modelinin doğru ve yanlış tahminlerinin miktarlarını gösterir. Karışıklık matrisi Şekil 16'da görülebilir. Matris elemanı, tahmin edilen değerlerin sayısına göre değişir. Gerçek değerler veri setinde bulunan çıkış değerleridir. Pozitif bir durum için pozitif bir değer ve negatif bir durum için negatif bir değer alır. Burada derin öğrenme yöntemi ile oluşturulan modelin amacı, hem pozitif hem de negatif değerleri doğru tahmin etmektir (Yıldız ve Karadeniz 2019).

Karışıklık Matrisi (Confusion Matrix)		Gerçek Değerler	
		Pozitif	Negatif
Tahmin Edilen Değerler	Pozitif	Doğru Pozitif (True Positive) (TP)	Yanlış Pozitif (False Positive) (FP)
	Negatif	Yanlış Negatif (False Negative) (FN)	Doğru Negatif (True Negative) (TN)

Şekil 19. Karışıklık matrisi

Karışıklık matrisindeki değerlerin açıklamaları şu şekildedir:

- Gerçek pozitif (TP) : Doğru olup pozitif olarak işaretlenen örneklerin sayısı.
- Yanlış pozitif (FP) : Yanlış olup pozitif olarak işaretlenen örneklerin sayısı.
- Gerçek negatif (TN) : Doğru olup negatif olarak işaretlenen örnek sayısı.
- Yanlış negatif (FN) : Yanlış olup negatif olarak işaretlenen numune sayısı.

Bu matris yardımıyla değerlendirmede kullanılacak aşağıdaki değerler ayrıca hesaplanabilir:

Doğruluk (Accuracy): Doğru tahminlerin sistemdeki tüm tahminlere oranıdır. Eşitlik 8’de Doğruluk değeri hesabı gösterilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (\text{Eşitlik 8})$$

Kesinlik (Precision): Modelin pozitif tahmin edilenler açısından ne kadar doğru olduğunu hesaplar. Eşitlik 9’da Kesinlik değeri hesabı gösterilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (\text{Eşitlik 9})$$

Duyarlılık (Recall): Modelin etiketledikten sonra yakalayabildiği gerçek pozitiflerin sayısını hesaplar. Eşitlik 10’da Duyarlılık değeri hesabı gösterilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (\text{Eşitlik 10})$$


F1 Skor: Kesinlik ve duyarlılık arasında bir denge sağlar. Eşitlik 11’de F1 skor değeri hesabı gösterilmiştir.

$$\text{F1 Skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (\text{Eşitlik 11})$$

3.5.2. K Katlamalı Çarpaz Doğrulama

K-katlı çarpaz doğrulamada (K-Fold/Cross-Validation) veriler önce bölümlenir. K eşit (veya neredeyse eşit) boyutlu bölümlere veya parçalara ayrılır. Ardından, her yinelemede bu verilerin farklı katları, doğrulama için tutulur; kalan k-1 kat ise öğrenme için kullanılır. Veriler genellikle k’ye bölünmeden önce katmanlara ayrılır. Tabakalaşma,


bütün katmanların yeniden düzenlenmesi sürecidir. Her katlamanın iyi bir temsilcisi olmasını sağlayacak veriler; örneğin her sınıfın, verilerin %50'sini oluşturduğu bir ikili sınıflandırma probleminde, verileri her katlamada, her birinde yer alacak şekilde düzenlemek en iyisidir. Sınıf, örneklerin yaklaşık yarısını içerir (Refaeilzadeh vd., 2009). Şekil 20’de K Katlamalı Çarpaz Doğrulama şeklen izah edilmiştir.



Şekil 20. Çarpaz doğrulama

4. YAPILAN ÇALIŞMALAR

Tez çalışması kapsamında akciğer röntgen görüntülerinden yüksek doğrulukla pnömoni sınıflandırması yapacak derin ağ mimarisinin kurulması amaçlanmıştır. Literatüre bakıldığında yetişkin akciğer görüntüleri üzerinde yapılan çalışmalarda yüksek başarımlar elde edildiği görülmektedir. Fakat, çocuk röntgen görüntülerinde özellikle duruş bozukluklarından dolayı bu başarımın düştüğü söylenebilir. Çalışma kapsamında da önceki bölümlerde detayları verilen Kermay vd., (2018) tarafından hazırlanmış olan çocuk röntgen görüntülerinden oluşan veri seti ele alınmıştır. Bu veri seti ile yapılan çalışmaya bakıldığında ise yetişkin görüntülerinde elde edilen başarımlara göre düşük kaldığı, dolayısıyla iyileştirmelere ihtiyaç olduğu tespit edilmiştir. Bu amaçla veri seti üzerinde doğrudan sınıflandırma yapmak yerine ilk önce bölütleme yapılarak akciğer bölgeleri görüntüler içerisinde ayrıştırılmış, daha sonra bölütlenmiş görüntüler sınıflandırıcıya girdi olarak verilmiştir. Böylece hem bölütleme için hem de sınıflandırma için iki özgün ağ geliştirilmiştir. Şekil 21’te önerilen yaklaşımın genel blok diyagramı yer almaktadır. Şekilden de anlaşılacağı üzere maske görüntülerinin üretilmesini sağlayan bölütleme aşaması bir U-Net mimarisine dayalı ESA ile gerçekleştirilmiştir. Maske görüntü ile orijinal görüntünün çakıştırılması sonucunda bölütlenmiş görüntü elde edilmiş ve bu görüntü sınıflandırıcı ağı girdi olarak kullanılmıştır.



Şekil 21. U-Net ve sınıflandırma blok diyagramı

4.1. U-Net Tabanlı Bölütleme Ağ Mimarisi


Akciğer röntgen görüntülerinin bölütlenmesi özgün bir U-Net ağ mimarisi ile gerçekleştirilmiştir. Mimarinin geliştirilmesi sırasında yapılan deneysel çalışmalarda en iyi bölütleme değerlerini üreten yapıya ulaşmak için farklı denemeler yapılmış ve sonuçta Şekil 22’de verilen ağı kullanılabildiğine karar verilmiştir.

U-Net yapısının kodlayıcı kısmı 4 alt bloktan oluşmakta; her blok bir adet evrişim, bir adet seyreltme, bir adet evrişim ve bir adet de havuzlama katmanları içermektedir. İlk bloğa 128×128 ’li boyutlarda görüntü girişi sağlanırken, kodlayıcı blokların sonunda görüntü 8×8 boyutlarına kadar düşmektedir. Benzeri şekilde kod çözücü tarafında ise bir adet evrişim, bir seyreltme, bir adet evrişim ve bir adet de ters evrişim katmanı kullanılmıştır. Özellikle ters evrişim katmanı çıktı görüntülerin tekrar 128×128 boyutlarına ulaşmasını sağlamıştır. U-Net mimarisi gereği kodlayıcı ve kod çözücü bloklar arasında kurulması gereken birleştirme bağlantıları, kodlayıcı tarafındaki havuzlama katmanının hemen önünde yer alan evrişim katmanının kod çözücü tarafına taşınması ile sağlanmıştır. Kod çözücü tarafında ise ters evrişim katmanından hemen önce bu katman birleştirme sürecine dahil edilmiştir. Önerilen modelde son katman öncesindeki tüm evrişim katmanlarında Relu son katmanda ise Softmax aktivasyon fonksiyonu kullanılmıştır.

Pnömoni sınıflandırması yapılacak olan Veriseti-1’de bölütlenmiş akciğer görüntüleri mevcut olmadığı için önerilen mimarinin eğitimi Veriseti-2 içindeki maskeler kullanılarak eğitim yapılmıştır. Şekil 22’de gösterilen mimaride kullanılan parametreler Tablo 7’de verilmiştir. Bu parametreler elde edilen en yüksek sınıflandırma sonucuna ait deneysel çalışmalarla elde edilen parametre değerleridir.

Tablo 7. U-Net mimarisi parametreleri

Parametre	Değer
Çözünürlük	128×128
Optimizer	Adam
Hata(Loss) Fonksiyonu	Cross Entropy
Öğrenme Oranı(learning rate)	0.00081
Adım (Epoch)	150
Test	0.15
Doğrulama(validation_split)	0.12
Aktivasyon Fonksiyonu	Relu,Softmax



Şekil 22. Önerilen değiştirilmiş U-Net modeli


Şekil 22’de evrişim katmanlarında (3×3) lük evrişim uygulanmıştır.

Veriseti-2 ile eğitilmiş U-Net mimarisinden elde edilen başarımlar Tablo 8’de verilmiştir. 5856 görüntüden oluşan Veriseti-1’deki görüntülerin %89’u eğitim verisi, %10’u test verisi ve %1’i de doğrulama verisi olarak kullanılmıştır.

Tablo 8. Bölütleme başarımlar değerleri


Ölçütler	Değerler
Eğitim Verisi Başarısı (Accuracy)	0.9898
Eğitim Verisi Hata (Loss)	0.0227
Doğrulama Verisi Başarısı (Val Accuracy)	0.9878
Doğrulama Verisi Hatası (Val Loss)	0.0349

Şekil 23’te bölütleme işlemine ait eğitim/doğrulama başarımları ile eğitim/doğrulama hatası grafikleri verilmiştir. Model aşırı öğrenmeye gitmeden, 150 adımda kabul edilebilir düzeyde sonlandırılmıştır. Hem yukarıda verilen tablo hem de başarımlar grafikleri değerlendirildiğinde eğitim ve doğrulama değerlerinin birbirlerini destekler nitelikte olduğu sistemin aşırı uydurma veya zayıf öğrenme problemleri ile karşılaşmadığı anlaşılmaktadır. Bununla beraber hem eğitim de hem doğrulama 0.99’a çok yakın doğruluk değerleri elde edilmiş olup, bölütlemenin başarıyla gerçekleştirilebildiği söylenebilir.



Şekil 23. Bölütlemeye ait eğitim başarımları grafikleri

Eğitimi tamamlanmış bölütleme mimarisi ile hem Veriseti-1 hem de Veriseti-2 üzerindeki görüntülerin bölütlemeleri gerçekleştirilmiştir. Şekil 24’te bu denemeler sonucunda üretilen bazı görüntülere ait bölütleme sonuçları yer almaktadır.



Şekil 24. U-Net ile bölütlenmiş örnek görüntüler

4.2. Sınıflandırma Ağ Yapısı

Sınıflandırma ağ yapısı oluşturulurken başlangıçta çok basit ağlardan yola çıkılmış, daha sonra yavaş katmanlar eklenerek ve ağ üzerinde çeşitli optimizasyonlar yapılarak son haline ulaşılmıştır. Ağın ilkel halinde yalnızca evrişim katmanları tercih edilmiş fakat sadece öznetelik çıkarımına dayalı bir yaklaşımın ideal sonuçları vermeyeceği görülünce kod üretici bir mekanizma devreye sokulmuştur. Bu noktada havuzlama katmanları devreye girmiştir. Havuzlama için maksimum seçeneği kullanılmıştır. Bununla beraber evrişim katmanlarının sayısı havuzlama işlemine gelmeden önce sayısı artırılarak daha dayanıklı bir öznetelik üretici elde edilmeye çalışılmıştır.

Ağ yapısında regülasyon amacıyla her bir evrişim katmanında sonra normalizasyon katmanı kullanılmış, tam bağlantı katmanlarında ise seyreltme katmanları tercih edilmiştir. Böylece sınıflandırma ağının aşırı uydurma probleminden de kurtarılması düşünülmüştür. Tablo 9’da ağ katmanlarının detayları verilen evrişim katmanlarında (3×3) lük filtreler tercih edilmiştir.


Tablo 9. ESA sınıflandırma ağ yapısı

Katman	Giriş	Çıkış
1 Giriş	256, 256, 1	256, 256, 1
2 Evrişim2B	256, 256, 1	256, 256, 16
3 Normalizasyon	256, 256, 16	256, 256, 16
4 Evrişim2B_1	256, 256, 16	256, 256, 32
5 Normalizasyon_1	256, 256, 32	256, 256, 32
6 MaksimumHavuzlama2B	256, 256, 32	128, 128, 32
7 Evrişim2B_2	128, 128, 32	128, 128, 32
8 Normalizasyon_2	128, 128, 32	128, 128, 32
9 Evrişim2B_3	128, 128, 32	128, 128, 64
10 Normalizasyon_3	128, 128, 64	128, 128, 64
11 MaksimumHavuzlama2B_1	128, 128, 64	64, 64, 64
12 Evrişim2B_4	64, 64, 64	64, 64, 64
13 Normalizasyon_4	64,64,64	64, 64, 64
14 Evrişim2B_5	64, 64, 64	64, 64, 128
15 Normalizasyon_5	64, 64, 128	64, 64, 128
16 MaksimumHavuzlama2B_2	64, 64, 128	32, 32, 128
17 Evrişim2B_6	32, 32, 128	32, 32, 128
18 Normalizasyon_6	32, 32, 128	32, 32, 128
19 Evrişim2B_7	32, 32, 128	32, 32, 256
20 Normalizasyon_7	32, 32, 256	32, 32, 256
21 MaksimumHavuzlama2B_3	32, 32, 256	32, 32, 16
22 Normalizasyon_8	16, 16, 128	16, 16, 128
23 Evrişim2B_8	16, 16, 128	16, 16, 256
24 Normalizasyon_9	16, 16, 256	16, 16, 256
25 MaksimumHavuzlama2B_4	16, 16, 256	8, 8, 256
26 Düzleştirme	8, 8, 256	16384
27 Tam Bağlantı	16384	256
28 Seyreleme	256	256
29 Tam Bağlantı_1	256	128
30 Seyreleme_1	128	128
31 Tam Bağlantı_2	128	64
32 Seyreleme_2	64	64
33 Tam Bağlantı_3	64	32
34 Seyreleme_3	32	32
35 Tam Bağlantı_4	32	16
36 Seyreleme_4	16	16
37 Tam Bağlantı_5	16	2

4.3. Göğüs Bölgesinin (Thorax) Tespit Edilmesi


Bölütlenmiş görüntüler üzerinde sınıflandırma işlemi yapıldıktan sonra, sınıflandırma başarısını artırmak adına bölütlenmiş görüntüler ayrıntılı olarak incelendiğinde, bazı görüntülerin bölütleme işleminde akciğer bölgelerinin düzgün şekilde bölütlenmediği tespit edilmiştir. Bu görüntüleri düzgün bölütlenenler arasına katmak ve sınıflandırma başarısını artırmak adına görüntüler, morfolojik işlemlerden yayma (dilation) işlemine tabi tutuldu.

Morfolojik operatörlerden yayma işlemi sorunlu bölütlenen akciğer loblarını da içine alacak şekilde tüm görüntüler üzerinde uygulanmıştır. Bu işlem farklı maske boyutlarında en iyi sınıflandırma değerleri üretecek değerler bulunmaya çalışılmıştır. Şekil 25’de 10×10 ve 22×15 boyutlarında yayma işleminin uygulanması sonucunda elde edilen görüntüler gösterilmiştir.



Şekil 25. Yayma işlemi uygulanan maskelenmiş görüntüler

Yayma işleminden sonra genişletilmiş maske görüntüler üretilmiş ve bu görüntülere Şekil 26’da gösterildiği (22×15) boyutlarında yeniden yayma işlemi uygulanmıştır. Böylece göğüs bölgesini tamamen içerecek yeni maskeler üretilmiştir.




Şekil 26. Yayma işlemi uygulanan maske görüntüleri

Bu yöntem geliştirilmeden önce literatürde mevcut verisetlerine ait göğüs kafesi (thorax) maskesi araştırılmış; fakat böyle bir veriye rastlanmamıştır. Bu nedenle yayma


işlemleri bölütlenmiş akciğer lobları baz alınarak yapılmıştır. Aynı sınıflandırma ölçekleri, aynı şartlar ve parametreler kullanılarak sınıflandırma başarısını artırmak için yeni bir yöntem geliştirilmiştir. Bu yöntem ile kullanılan Veriseti-2'deki tüm akciğer görüntülerine ait bölütlenmiş lobların kenarlara en yakın ve en uzak noktalarının toplamalarının ortalaması alınarak, elde edilen piksel değeri kadar genişleme yapılıp, genişlemenin yapıldığı kenarlardan (X veya Y) uzun kenar ölçüsünde kare oluşturacak şekilde, diğer kenar (kısa kenar) bu kenara eşitlenerek karesel alan elde edilmiştir. Elde edilen karesel alanlar 255×255 boyutuna genişletilerek yeni akciğer görüntüleri olarak kaydedilmiştir. Tüm görüntülere geliştirilen bu algoritma uygulandıktan sonra sınıflandırma işlemi yapılmıştır. Aşağıda geliştirilen algoritma ve yöntemle beraber kullanılan diğer yöntemlere ait bilgiler yer almaktadır.

Loblara ait uç noktalar hesaplandıktan sonra, bölütlenmiş lobların diğer kenarlarıyla birlikte bu alanlar birleştirilerek Şekil 28'in sağında gösterilen siyah-beyaz alanlar elde edilmiştir.




Şekil 27. Loblara ait uç noktaların tespiti ve birleştirilmesi

Lobların birleştirilmesi tüm görüntüler için yaklaşık olarak göğüs kafesi görüntülerinin elde edilmesini sağlamıştır. Fakat çocuk görüntülerinde sıklıkla rastlanan duruş bozuklukları Şekil 28'de de görüldüğü üzere göğüs kafesi maskelerine de yansımaktadır.




Şekil 28. Lobların uç noktalarına göre üretilen göğüs bölgesi maske görüntüleri

Sınıflandırma ağ girişinde standart bir yapıya kavuşturmak için lobların uç noktalarına dayalı yeni bir yaklaşım uygulanmış ve görüntüler bu yaklaşıma göre ölçeklendirilmiştir. Her bir resim için elde edilen siyah-beyaz alanlara Şekil 29’da da gösterildiği üzere ilk atamada yer alan (x_1 , x_2 , y_1 , y_2) değerleri elde edilmiştir. Bunun devamında Şekil 30’da gösterilen kısa kenar, uzun kenar kullanılarak Şekil 31’de verilen karesel alan ve diğer hesaplamalar gerçekleştirilmiştir. Hesaplamalara ilişkin formüller ise Eşitlik 8 ve 9’da verilmiştir.



Şekil 29. X ve Y değerlerinin görsel olarak gösterimi



Şekil 30. Uzun ve kısa kenar


O_{KD} (Ortalama Kenar Değeri) Eşitlik (8-9-10)'da ki gibi hesaplanmıştır.

$$O_{KD} = \frac{1}{n_n} \sum_{i=0}^{n_n} K_{k(i)} + \frac{1}{n_p} \sum_{i=0}^{n_p} U_{k(i)} \quad (\text{Eşitlik 8})$$

$$O_{KD} = \frac{1}{1341} \sum_{i=0}^{1341} K_{k(i)} + \frac{1}{1345} \sum_{i=0}^{1345} U_{k(i)} \quad (\text{Eşitlik 9})$$

Bu denklemlerde ifadeler şu şekilde tanımlanmıştır:


OKD	:	Ortalama Kenar Değeri
n_p	:	Dizideki Pnömoni Görüntü Sayısı
n_n	:	Dizideki Normal Görüntü Sayısı
K_k	:	Kısa Kenar
U_k	:	Uzun Kenar
i, n	:	Tam Sayı, Toplam



Şekil 31. Görüntü bölgeleri-1

Şekil 31’de yeşil çizgili alan; Veriseti-2’de yer alan maskelerden elde edilen uç noktaların birleştirilmesinden elde edildi. Açık mavi çizili alan; yeşil alana ilaveten 32 piksel olarak hesaplanan ortalama kenar değeri her bir kenara eklenerek elde edildi. Bordo çizili alan; açık yeşil kenar değerlerinden uzun olan kenar değeri kareye tamamlayacak şekilde, karesel bölge elde edildi. Karesel bölge sınırlarını veren yaklaşım Algoritma - 1’de gösterilmiştir.

Şekil 32’de orijinal görüntü ve bu görüntüden hesaplamalar sonucunda elde edilen yeni görüntü gösterilmektedir.



Şekil 32. Orijinal görüntü – Yeni görüntü

Algoritma – 1: Karesel Alanın sınırlarını tespit eden algoritma

Girdi: Maskelenmiş alan pikselleri, (x_i, y_i) , $i: 1..n$, n : piksel sayısı

Çıktı: ROI bölgesi koordinatları $(x_{min}, y_{min}, x_{max}, y_{max})$

O_{KD} ’yi Eşitlik – 8 ve 9’a göre hesapla

$$x_{min} \leftarrow \min(\forall x_i) - O_{KD}$$

$$x_{max} \leftarrow \max(\forall x_i) + O_{KD}$$

$$y_{min} \leftarrow \min(\forall y_i) - O_{KD}$$

$$y_{max} \leftarrow \max(\forall y_i) + O_{KD}$$

$$x_{temp} \leftarrow x_{max} - x_{min}$$

$$y_{temp} \leftarrow y_{max} - y_{min}$$

eğer $(y_{temp} > x_{temp})$ **ise**

$$x_{fark} \leftarrow y_{temp} - x_{temp}$$

$$x_{kay} \leftarrow \lceil x_{fark} / 2 \rceil$$

$$x_{min} \leftarrow x_{min} - x_{kay}$$

$$x_{\max} \leftarrow x_{\max} + (x_{\text{fark}} - x_{\text{kay}})$$

değilse

$$y_{\text{fark}} \leftarrow x_{\text{temp}} - y_{\text{temp}}$$

$$y_{\text{kay}} \leftarrow \lfloor y_{\text{fark}} / 2 \rfloor$$

$$y_{\min} \leftarrow y_{\min} - y_{\text{kay}}$$

$$y_{\max} \leftarrow y_{\max} + (y_{\text{fark}} - y_{\text{kay}})$$

eğer ($x_{\min} < 0$) **ise** $x_{\max} \leftarrow x_{\max} - x_{\min}$

eğer ($x_{\max} > 255$) **ise** $x_{\min} \leftarrow x_{\min} - (x_{\max} - 255)$

eğer ($y_{\min} < 0$) **ise** $y_{\max} \leftarrow y_{\max} - y_{\min}$

eğer ($y_{\max} > 255$) **ise** $y_{\min} \leftarrow y_{\min} - (y_{\max} - 255)$

$$x_{\min} \leftarrow \max(x_{\min}, 0)$$

$$y_{\min} \leftarrow \max(y_{\min}, 0)$$

$$x_{\max} \leftarrow \min(x_{\max}, 255)$$

$$y_{\max} \leftarrow \min(y_{\max}, 255)$$


Demir ve Bingöl (2021) yaptıkları çalışmada aynı veri setini kullanmış ve varılan sonuçlardan birinde şu şekilde bahsedilmektedir: “5 yaş altı çocuklara ait görüntülerde duruş bozuklukları, boyun, kol gibi uzuvların röntgende çıkması ESA’nın performansını önemli ölçüde etkilemektedir. Bu görüntülerde çeşitli veri ön işleme adımları ile performansın arttığı gözlenmiştir”. Geliştirilen algoritma ile göğüs kafesi hesaplamaları sonucunda yaklaşık 32 piksellik yayma-genişletme yapıldığında pnömoni sınıflandırma başarısının arttığı görülmüştür.

5. BULGULAR VE TARTIŞMA

Çalışmanın bu bölümünde üzerinde asıl çalışılması düşünülen Veriseti-1'deki pnömoni ve normal görüntülerin sınıflandırma başarısının adım adım nasıl artırıldığına ilişkin Yöntemler bölümünde anlatılan yaklaşımlardan elde edilen bulgular verilmiştir. Çalışmanın hipotezi olan bölütlemenin sınıflandırma başarısını artıracağı fikri orijinal görüntülerin ve bölütlenmiş görüntülerin bulgularının karşılaştırılmasını gerektirmektedir. Bu nedenle öncelikle iyi bir bölütleme elde edilecek U-net yapısı ile elde edilen sonuçlar ilk önce verilmiştir. Daha sonra sırasıyla Veriseti-1 ve Veriseti-2 için hem bölütlenmemiş orijinal görüntüler ile bölütlenmiş görüntüler için sınıflandırma sonuçları verilmiştir. Bu sonuçlar çalışmamızın özellikle göğüs bölgesine odaklanılması yönünde fikir ortaya koymuştur. Dolayısıyla bölümün son başlığında yine Yöntemler bölümünde göğüs bölgesinin tespit edilmesi olarak verilen yöntem ile elde edilen görüntülere ait sınıflandırma sonuçları verilmiştir.

5.1. U-Net Mimarisi İle Bölütleme

Tasarlanan değiştirilmiş U-Net mimarisinin eğitimi akciğer maske görüntüleri içeren Veriseti-2 ile gerçekleştirilmiştir. Eğitimde görüntülerin %85'i eğitim için %15'i doğrulama için kullanılmıştır. Eğitim süreci Şekil 33'te gösterildiği üzere yaklaşık 50. iterasyondan sonra yüksek doğruluk/düşük hata oranlarına ulaşmaktadır. Dolayısıyla eğitim süreci 80. iterasyona kadar sürdürülmüştür.



Şekil 33. Bölütlemeye eğitim ve doğrulama verilerine ait başarı grafikleri

Şekil 33'te hem eğitim hem doğrulama verilerinde elde edilen başarı oranlarında birbirine yakın değerlere ulaşıldığı açık bir şekilde görülmektedir. Bu da eğitimin aşırı öğrenmeye gitmediğini ve başarılı süreç olarak ilerlediği göstermektedir. Bölütleme ağ mimarisinden elde edilen sonuçlar Tablo 10'da detaylı olarak verilmiştir. Tablodaki sonuçlara bakıldığında ise eğitim ve doğrulama verilerinin her ikisinde de yaklaşık %98.9 gibi yüksek düzeyde başarıma ulaşılabilirdiği görülmektedir. Doğrulama hatası kısmen eğitim hatasına göre büyük olmasına rağmen beklenen bir sonuçtur.

Tablo 10. Bölütlemeye eğitim ve doğrulama verilerine ait başarı değerleri

Ölçütler	Değerler
Eğitim Verisi Başarımı	0.9893
Eğitim Verisi Hatası	0.0242
Doğrulama Verisi Başarımı	0.9891
Doğrulama Verisi Hatası	0.0311

Bölütleme sonucunda ulaşılan değerler bir model için ideale yakın değerlerdir. Dolayısıyla sonraki aşamalarda bölütlenmiş görüntüler diye bahsedilen tüm görüntüler bu bölütleme ağ mimarisi ile elde görüntülerdir.


5.2. Veriseti-1 Orijinal Görüntüler İçin Sınıflandırma İşlemi

Bölütlenmiş görüntülerin sınıflandırmada başarılı sonuçlar verip vermediğini görebilmek için ilk önce Veriseti-1'e ait görüntülerin bölütlenmemiş olan orijinal görüntüleri üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi özgün sınıflandırıcı olarak tasarlanan ve Yöntemler bölümünde detaylı katman yapısı verilmiş olan sınıflandırıcı ağ yapısı üzerinde gerçekleştirilmiştir. Bu aşamda ağın eğitim, doğrulama ve test başarımları için çapraz doğrulama tekniklerinden k-katlamalı (k-fold) tercih edilmiş olup, k=5 olarak alınmıştır. 5856 görüntünün önce %20'si yani 1172 adet görüntü test verisine, kalan 4684 görüntünün 1/5'i 937 görüntü çapraz doğrulama-2'ye, kalan 3747 görüntünün 1/4'ü 937 görüntü çapraz doğrulama-3'e, kalan 2810 görüntünün 33/100'ü 928 görüntü çapraz doğrulama-4'e, en son kalan 1882 görüntünün 1/2'si 941 görüntü çapraz doğrulama-1'e ve diğer 1/2'si 941 görüntü çapraz doğrulama-5'e ayrılmıştır. Bu işlem görüntüler için elle yapılmış olup, her bir ağ denemesine doğru parametrelerin tespiti için farklı görüntülerin başarıma olan etkileri azaltılmaya çalışılmıştır. Buna göre test ve katlamalar başına düşen görüntüler Tablo 11'de verilmiştir.

Tablo 11. K katlamalı çapraz doğrulama ve diğer parametrik değerler


Veriseti-1	Görüntü Sayısı
Test	1172
Katlama - 1	941
Katlama - 2	937
Katlama - 3	937
Katlama - 4	928
Katlama - 5	941
Toplam	5856

Şekil 34'teki eğitim başarı ve eğitim doğrulama grafiklerinden görüleceği üzere 80 adımda çapraz doğrulama işlemi ideal seviye ulaşmış ve eğitim sonlandırılmıştır.



Şekil 34. Veriseti-1 orijinal görüntüleri için eğitim başarı grafikleri

Her bir eğitim iterasyonu sonucunda test başarıları ve hatası üretilmiş olup Şekil 35'teki grafikler ile bu değerlerin nasıl ilerlediği gösterilmiştir.



Şekil 35. Veriseti-1 orijinal görüntüleri için test başarı grafikleri


Tablo 12’de Veriseti-1 orijinal görüntülerinin sınıflandırılmasına ilişkin değerlendirme değerleri verilmiştir. Tablodaki her bir satır k-katlamının bir aşamasına denk gelmektedir. Buna göre ulaşılan ortalama %97.18’lik doğruluk değeri literatürdeki birçok çalışmadan daha başarılı sonuçlar elde edildiğini göstermiştir. Bu da çalışma kapsamında oluşturulan sınıflandırıcı ağ yapısının aslında başarılı olduğunu göstermektedir. Doğruluk ile beraber verilen kesinlik, duyarlılık, özgüllük ve F1-skor değerleri de bu sonucu desteklemektedir.

Tablo 12. Veriseti-1 orijinal görüntüler için sınıflandırma başarımları sonuçları

K	Kayıp	TN	FN	FP	TP	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
1	0.148	290	10	25	847	0.9701	0.9713	0.9883	0.9206	0.9798
2	0.267	281	19	10	862	0.9753	0.9885	0.9784	0.9656	0.9835
3	0.192	283	17	17	855	0.9710	0.9805	0.9805	0.9433	0.9805
4	0.206	292	8	27	845	0.9701	0.9690	0.9906	0.9154	0.9797
5	0.223	286	14	18	854	0.9727	0.9794	0.9839	0.9408	0.9816
ORTALAMA DEĞERLER:						0.9718	0.9778	0.9844	0.9372	0.9810


5.3. Veriseti-1 Bölütlenmiş Görüntüler İçin Sınıflandırma

Veriseti-1’e ait orijinal görüntülerden elde edilen sınıflandırma değerlerinin bölütlenmiş görüntülerde elde edilecek sonuçlarla karşılaştırılması için bu veri setinde ki tüm görüntülerden U-Net tabanlı ağ mimarisi ile akciğer bölgelerinin gösteren maske görüntüler üretildi. Bu maske görüntüler tüm görüntüler üzerine uygulanarak Şekil 36’da örnekleri gösterilen bölütlenmiş görüntüler üretildi.




Şekil 36. Normal(N) ve bölütlenmiş-maskelenmiş(M) görüntüler

İlk aşamada orijinal görüntüler için kullanılan sınıflandırıcı ağ yapısı bu aşamada bölütlenmiş görüntüler için kullanıldı ve benzer bir süreçten geçirilerek hem eğitim hem de doğrulama değerlerine ulaşıldı. Şekil 37’de eğitim başarı ve eğitim doğrulama grafiklerinden görüleceği üzere 80 adımda çapraz doğrulama işlemi ideal seviye ulaşmış ve eğitim sonlandırılmıştır.



Şekil 37. Veriseti-1 bölütlenmiş görüntüler için eğitim başarı grafikleri

Şekil 38’deki test başarıları ve test hatası grafiklerinden görüleceği üzere 80 adımda çapraz doğrulama işlemi ideal seviye ulaşmış ve test işlemi sonlandırılmıştır.



Şekil 38. Bölütlenmiş görüntüler için test başarı grafikleri

Tablo 13’te gösterildiği üzere bölütlenmiş görüntüler için sınıflandırma doğruluk değeri %95.24, F1 skor %96.81 olarak gerçekleşmiştir. Bu değerler orijinal görüntüler için üretilen değerlerden yaklaşık olarak %2 oranında düşük çıkmıştır. Bu durum tez için

öngörülen bölütlenmiş görüntülerde daha yüksek oranların elde edilmesi düşüncesine tersi bir sonuç ortaya çıkarmıştır. Doğruluk değerleri dışında diğer değerler de benzeri sonuçlar üretmiştir.

Tablo 13. Veriseti-1 Bölütlenmiş Görüntüler için Sınıflandırma Başarım Sonuçları

K	Kayıp	TN	FN	FP	TP	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
1	0.135	277	23	39	833	0.9471	0.9553	0.9731	0.8766	0.9641
2	0.258	268	32	25	847	0.9514	0.9713	0.9636	0.9147	0.9674
3	0.370	269	31	24	848	0.9531	0.9725	0.9647	0.9181	0.9686
4	0.291	271	29	24	848	0.9548	0.9725	0.9669	0.9186	0.9697
5	0.369	266	34	18	854	0.9556	0.9794	0.9617	0.9366	0.9705
ORTALAMA DEĞERLER:						0.9524	0.9702	0.9660	0.9129	0.9681

5.4. Veriseti-2 Orijinal Görüntüler için Sınıflandırma İşlemi


Veriseti -1'deki bölütlenmiş görüntülerden elde edilen sonuçların orijinal görüntülerden düşük çıkması durumu çalışma için beklenmeyen bir sonuç olduğundan bunun nedenleri araştırılmış ve Veriseti-1'in görüntü sınıflarındaki dengesiz bir dağılımın buna neden olacağı düşünülmüştür. Bu durumu irdelemek adına pnömoni ve normal görüntü sayısı daha dengeli olan Veriseti-2 için hem orijinal görüntülerde hem de bölütlenmiş görüntülerde benzeri süreçler yürütülmüştür. Ayrıca Veriseti-2 bölütleme ağ yapısının eğitimi için kullanıldığından sınıflandırmada da pozitif bir katkı sağlayabileceği fikri öne çıkmıştır.

Veriseti-2'ye ilk veri setinde olduğu gibi Tablo 14'te detayları belirtilen çapraz doğrulama yöntemi uygulanmıştır. Buna göre toplam 2686 görüntünün önce %20'si 538 görüntü test kısmına, kalan 2148 görüntünün 1/5'i 430 görüntü çapraz doğrulama-2'ye, kalan 1718 görüntünün 1/4'ü 430 görüntü çapraz doğrulama-3'e, kalan 1288 görüntünün 33/100'ü 426 görüntü çapraz doğrulama-4'e, en son kalan 862 görüntünün 1/2'si 431 görüntü çapraz doğrulama-1 ve diğer 1/2'si 4311 görüntü çapraz doğrulama-5'e ayrılmıştır. Burada yine her bir katlamaya girecek olan görüntüler elle ile seçilmiştir.

Tablo 14. K katlamalı çapraz doğrulama ve diğer parametrik değerler


Veriseti-2	Görüntü Sayısı
Test	538
Katlama - 1	431
Katlama - 2	430
Katlama - 3	430
Katlama - 4	426
Katlama - 5	431
Toplam	2686

Şekil 39’da gösterildiği üzere eğitim başarıları ve eğitim doğrulama grafiklerinden görüleceği üzere 80 adımda çapraz doğrulama işlemi ideal seviye ulaşmış ve test işlemi sonlandırılmıştır.



Şekil 39. Veriseti-2 orijinal görüntüler için eğitim başarı grafikleri

Şekil 40’ta Veriseti-2’ye ait orijinal görüntüler için test başarı grafikleri yer almaktadır.



Şekil 40. Veriseti-2 orijinal görüntüler için test başarı grafikleri

Veriseti-2 üzerinde orijinal görüntüler için yapılan sınıflandırma işlemi Tablo 15’deki değerlerden de anlaşılacağı üzere ilk veri setine ait orijinal görüntülerden daha başarılı sonuçlar üretmiştir.


Tablo 15. Orijinal görüntüler için sınıflandırma başarımları

K	Kayıp	TN	FN	FP	TP	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
1	0.172	254	10	3	271	0.9758	0.9891	0.9644	0.9883	0.9766
2	0.053	259	5	4	270	0.9833	0.9854	0.9818	0.9848	0.9836
3	0.038	261	3	3	271	0.9888	0.9891	0.9891	0.9886	0.9891
4	0.071	258	6	3	271	0.9833	0.9891	0.9783	0.9885	0.9837
5	0.042	262	2	6	268	0.9851	0.9781	0.9926	0.9776	0.9853
ORTALAMA DEĞERLER:						0.9833	0.9861	0.9812	0.9856	0.9836

Tablodaki sonuçlara göre ortalama doğruluk değeri %98.33 ile ilk veri setine göre yaklaşık olarak %1'in daha iyidir. Orijinal görüntülerde veri setinin dengeli olması durumu Veriseti-2 yönünde bir avantaj sağladığı düşünülmüştür. Bu durumun bölütlenmiş görüntülerde de benzeri bir sonuç üretmesi beklenerek bir sonraki aşamaya geçilmiştir.

5.5. Veriseti-2 Bölütleme Görüntüleri İçin Sınıflandırma İşlemi

Veriseti-2'ye ait görüntüler ilk veri setinde olduğu gibi U-Net tabanlı bölütleme ağına sokulmuş ve akciğer bölgelerinin olduğu maske görüntüler üretilerek bölütlenmiştir. Bu aşamada bölütlenmiş görüntülerin arka plan piksellerinin tamamen siyah olması ağ parametrelerinin eğitimi için olumsuz bir durum oluşturabileceği düşüncesi gelişmiş ve bu durumun etkisini görebilmek için bölütlenmiş görüntüler için 3 farklı arkaplanı sahip üç adet bölütlenmiş görüntüler oluşturulmuştur. Buna göre ilk sette yüne tüm görüntülerde arkaplan siyah olarak bırakılmış, ikinci sette tam tersi beyaz bir renk tercih edilmiştir. Son sette ise görüntüdeki tüm piksellerin renk değerlerinin ortalaması alınarak bir arkaplan rengi belirlenmiştir. Dolayısıyla son setteki arkaplan rengi tüm görüntülerde farklılık göstermektedir. Bu üç set için oluşturulan arkaplan renklerine ilişkin örnek görüntüler Şekil 41'de gösterilmiştir.



Şekil 41. Siyah (S), Beyaz (B), Ortalama arka plan (O)

Arkaplan değerlerinin bölütlemeye dayalı sınıflandırma işlemlerine etkisi her bir yeni veri seti için sırasıyla Tablo 16 (siyah arkplan), Tablo 17 (beyaz arkplan) ve Tablo 18 (ortalama arkplan)'daki verilerle ortaya konulmuştur.

Tablo 16. Siyah ark plan başarımlar sonuçları

K	Kayıp	TN	FN	FP	TP	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
1	0.114	256	8	9	265	0.9684	0.9672	0.9707	0.9660	0.9689
2	0.103	255	9	6	268	0.9721	0.9781	0.9675	0.9770	0.9728
3	0.131	253	11	10	264	0.9610	0.9635	0.9600	0.9620	0.9617
4	0.140	258	6	13	261	0.9647	0.9526	0.9775	0.9520	0.9649
5	0.100	253	11	5	269	0.9703	0.9818	0.9607	0.9806	0.9711
ORTALAMA DEĞERLER:						0.9673	0.9686	0.9673	0.9675	0.9679

Siyah arkaplana sahip bölütlenmiş görüntüler Veriseti-1 ile elde edilen sınıflandırma sonuçları ile karşılaştırılması açısından değerlidir. Burada elde edilen ortalama %96.73'lük doğruluk değeri Veriseti-1'e ait bölütlenmiş görüntülere göre daha başarılı gözükse de Veriseti-2'nin orijinal değerlerine göre %2 civarından daha düşüktür. Veriseti-1'de karşılaşılan ve literatüre ters düşen bu durum bölütlenmiş görüntülerin doğruluğunu tartışılır hale getirmiştir. Fakat yine de arkplan etkisini göstermek amacıyla beyaz ve ortalama arkplan değerlerine sahip görüntüler için işlemler devam ettirilmiştir.


Tablo 17. Beyaz ark plan başarımlar sonuçları

K	Kayıp	TN	FN	FP	TP	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
1	0.170	254	10	10	264	0.9628	0.9635	0.9635	0.9621	0.9635
2	0.236	259	5	13	261	0.9665	0.9526	0.9812	0.9522	0.9667
3	0.111	259	5	17	257	0.9591	0.9380	0.9809	0.9384	0.9590
4	0.119	257	7	9	265	0.9703	0.9672	0.9743	0.9662	0.9707
5	0.108	253	11	10	264	0.9610	0.9635	0.9600	0.9620	0.9617
ORTALAMA DEĞERLER:						0.9639	0.9569	0.9720	0.9562	0.9643

Tablo 18. Ortalama ark plan başarımlar sonuçları

K	Kayıp	TN	FN	FP	TP	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
1	0.130	255	9	12	262	0.9610	0.9562	0.9668	0.9551	0.9615
2	0.139	261	3	11	263	0.9740	0.9599	0.9887	0.9596	0.9741
3	0.217	256	8	6	268	0.9740	0.9781	0.9710	0.9771	0.9745
4	0.950	253	11	4	270	0.9721	0.9854	0.9609	0.9844	0.9730
5	0.170	257	7	6	268	0.9758	0.9781	0.9745	0.9772	0.9763
ORTALAMA DEĞERLER:						0.9714	0.9715	0.9724	0.9707	0.9719

Beyaz ve ortalama arkplan piksel değerlerine göre yapılan sınıflandırmalarda özellikle ortalama arkplana sahip görüntülerin kısmen diğer görüntülerden başarılı olduğu anlaşılmaktadır. Bu görüntülere ait eğitim başarı grafikleri Şekil 42'de verilmiştir.




Şekil 42. Ortalama arka plan eğitim başarımları grafikleri

Tablo 16, 17 ve 18'deki verilerden de görüldüğü üzere siyah ve beyaz arka planların akciğer bölütlemesine dayalı sınıflandırma işleminde sonuca etkisinin pozitif yönde olmadığı; ortalama piksel arka plan atamasının başarımları artırdığı, 0.9714 doğruluk değeriyle daha yüksek olduğu görülmektedir. Fakat bu değerde yine orijinal görüntülerin sınıflandırma başarısının altında kalmaktadır. Bu noktada arkaplan renginin değiştirilmesinin sınıflandırma başarısına olan etkisinin aslında akciğer alanı dışında kalan bölgelerinde sınıflandırmaya etki ettiğini göstermektedir. Fakat bu bölgelerde pnömoniye ilişkin bilgilerin yer almaması kafa karıştırıcıdır. Bunun nedenleri üzerine düşünüldüğünde aslında başarılı akciğer bölütlemesi gerçekleştirilmesine rağmen, bölütleme ağ yapısının eğitimi için kullanılan veri setinde akciğer bölgelerinin eksik olarak işaretlendiği anlaşılmıştır. Bu da akciğer bölgesinin mevcut bölütlenmiş görüntüler içerisinde daha geniş bir alana sahip olması gerektiğini göstermektedir. Bu nedenle akciğer bölgesini de içine alan bir göğüs bölgesi seçiminin sınıflandırma için daha başarılı sonuçlar vereceği düşünülmüştür.

5.6. Göğüs Bölgesi Bölütleme ve Sınıflandırma

Veriseti-1'deki görüntülerden seçilerek oluşturulan Veriseti-2 akciğer maske görüntüleri için çalışmam kapsamında özel olarak tercih edilmiştir. Literatürde ilk veri seti için bu görüntülerin başka bir maske görüntüsü içeren bir veri setine rastlanamamıştır. Fakat bu veri seti ile yapılan bölütlemede elde edilen sonuçların beklenenden düşük olması ve özellikle arkaplan renklendirmesinde farklı sonuçlar üretiyor olması Veriseti-2'ye ait maske görüntülerinin işaretlenmesinin yetersiz olabileceğini göstermiştir. Şekil

18 ve Şekil 41'deki görüntülere bakıldığında da maske görüntülerinin akciğer bölgesini tamamen almadığı dikkati çekmektedir. Bunun çözümü olarak çalışmanın son aşamasında sadece akciğer bölgesini seçmek yerine göğüs (thorax) bölgesinin tümüyle seçilebileceği bir yaklaşım önerilmiştir. Bu yaklaşımın detayları 4.3 bölümünde anlatılmıştır. Buna göre ilk önce morfolojik işlemin uygulandığı görüntülere ile bir bölütleme gerçekleştirilmiştir. Bu işleme ait bölütlenmiş görüntülerden bazı örnekler Şekil 43'de verilmiştir.



Şekil 43. Morfolojik işlemler sonucunda elde edilen bölütlenmiş görüntüler


Morfolojik işlemler şekilden de anlaşılacağı üzere daha geniş bir alanın seçimine olanak tanımıştır. Elde edilen yeni bölütlenmiş görüntüler sınıflandırıcı ağ mimarisine girdi olarak kullanılmış ve Tablo 19'da verilen başarı değerlerine ulaşılmıştır.

Tablo 19. Morfolojik işlemler sonucunda üretilen maskelere dayalı sınıflandırma sonuçları

K	Kayıp	TN	FN	FP	TP	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
1	0.248	287	14	17	850	0.9735	0.9804	0.9838	0.9441	0.9821
2	0.306	285	16	20	847	0.9692	0.9769	0.9815	0.9344	0.9792
3	0.468	292	9	23	844	0.9726	0.9735	0.9894	0.9270	0.9814
4	0.147	279	22	10	857	0.9726	0.9885	0.9750	0.9654	0.9817
5	0.357	279	22	17	850	0.9666	0.9804	0.9748	0.9426	0.9776
ORTALAMA DEĞERLER:						0.9709	0.9799	0.9809	0.9427	0.9804

Göğüs bölgesinin tespit edilmesi ile ilgili ilk aşama sınıflandırma sonuçları kısmı bir iyileştirme sağlamış olup, sonrasında göğüs bölgesinin tespit edilerek tamamının seçildiği maskelenmiş görüntüler üretilmiştir. Buna ilişkin bazı örnek görüntüler de Şekil 44'de gösterilmiştir. Bu şekilden de anlaşılacağı üzere bölütlenmiş görüntülerde sadece

akciğerlere ait loblar değil tüm göğüs bölgesi bu alan içerisine dahil edilmiştir. Böylece akciğer loblarının eksik seçimi durumu ortadan kaldırılmıştır.




Şekil 44. Göğüs bölgesine dayalı bölütlenmiş görüntüler

Daha önceki aşamalarda uygulana eğitim sürecine ait çapraz doğrulama süreçleri bu yaklaşımın eğitimi için de kullanılmıştır. Sonuç olarak elde edilen ve Tablo 20’de de gösterilen bu yaklaşıma ait değerler incelendiğinde başarımın önemli ölçüde iyileştirdiği görülmüştür. Doğruluk değeri için elde edilen %98.55’lik Veriseti-1 ve Veriseti-2’te ait hem orijinal görüntülerden elde edilen değerlerden hem de U-net ile bölütlenmiş görüntülerden elde edilen değerlerden dayalı yüksektir. Diğer sonuçlar da bu değeri destekler niteliktedir.

Tablo 20. Göğüs bölgesine dayalı bölütlenmiş görüntülerden elde edilen sınıflandırma değerleri

K	Kayıp	TN	FN	FP	TP	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
1	0.100	257	7	2	272	0.9833	0.9927	0.9749	0.9923	0.9837
2	0.123	262	2	6	268	0.9851	0.9781	0.9926	0.9776	0.9853
3	0.056	261	3	2	272	0.9907	0.9927	0.9891	0.9924	0.9909
4	0.102	259	5	4	270	0.9833	0.9854	0.9818	0.9848	0.9836
5	0.045	260	4	4	270	0.9851	0.9854	0.9854	0.9848	0.9854
ORTALAMA DEĞERLER:						0.9855	0.9869	0.9848	0.9864	0.9858

Önerilen yaklaşım ile elde edilen görüntülerin eğitim sürecine ait başarı ve hata grafikleri Şekil 45’te verilmiştir. Özellikle ilk şekilde eğitim ve doğrulama başarı oranlarının birbiri ile uyumlu olduğu dikkati çekmektedir.



Şekil 45. Sınıflandırmaya ait eğitim başarımları grafikleri

Göğüs bölgesine dayalı bölütleme yaklaşımında elde edilen başarılı sonuçlara ait çapraz doğrulamadaki doğru sınıflandırma değerleri ayrıca Tablo 21’de verilmiştir.

Tablo 21. Göğüs bölgesi bölütlemesine dayalı sınıflandırmaya ait çapraz doğrulama değerleri

	Tahmin Edilen Değerler				Test Doğruluğu	Test Hatası
			N	P		
	Gerçek Değerler					
Katlama-1	N	257	7		0.98	0.10
	P	2	272			
	Tahmin Edilen Değerler				Test Doğruluğu	Test Hatası
			N	P		
	Gerçek Değerler					
Katlama-2	N	262	2		0.99	0.12
	P	6	268			
	Tahmin Edilen Değerler				Test Doğruluğu	Test Hatası
			N	P		
	Gerçek Değerler					
Katlama-3	N	261	3		0.99	0.6
	P	2	272			
	Tahmin Edilen Değerler				Test Doğruluğu	Test Hatası
			N	P		
	Gerçek Değerler					
Katlama-4	N	259	5		0.98	0.10
	P	4	270			
	Tahmin Edilen Değerler				Test Doğruluğu	Test Hatası
			N	P		
	Gerçek Değerler					
Katlama-5	N	260	4		0.99	0.05
	P	4	270			

6. SONUÇLAR VE ÖNERİLER

Pnömoni dünya genelinde ölüm nedenli hastalıklar önde gelenlerinden biridir. Özellikle çocuklarda yetişkinlere göre daha etkili olan bu hastalığın tespitine yönelik son yıllarda makine öğrenmesi tabanlı yaklaşımların arttığı gözlemlenmektedir. Bu anlamda derin öğrenme alanındaki gelişmeler bu konu ile ilgili olan çalışmaları da etkilemiş olup, normal ve pnömoni hastaların birbirinden ayırt edebilecek güçlü sınıflandırıcılar oluşturulabilmektedir. Bu çalışmalarda farklı görüntüleme teknikleri kullanıldığı görülmektedir. Fakat uygulamasının yaygın olması ve maliyetinin diğer cihazlara göre düşük olmasından dolayı akciğer röntgen görüntüleri üzerinden sınıflandırma yapmak daha cazip görünmektedir. Tüm bu çalışmalara bakıldığında özellikle çocuk röntgen görüntülerinde sınıflandırma başarımlarının yetişkin görüntülerine göre daha düşük olduğu gözlemlenmektedir. Bu durumun çocukların röntgen çekimi sırasındaki duruş bozukluklarından kaynaklandığı düşünülmektedir.

Bu tez çalışması kapsamında da çocuk röntgen görüntüleri üzerinden pnömoni ve normal hasta sınıflandırması yapabilecek bir yaklaşım önerilmiştir. Çalışma; sınıflandırma işlemi yapmadan önce gerçekleştirilecek başarılı bir bölütleme sürecinin sınıflandırmayı olumlu yönde etkileyeceği üzerine kurgulanmıştır. Bu amaçla ilk önce U-Net tabanlı bir bölütleyici ağ modeli önerilmiş, daha sonra özgün bir sınıflandırıcı tasarlanarak sınıflandırma işlemi gerçekleştirilmiştir.

Çalışmada geliştirilen ağ modelleri Kermany vd. (2018)'in düzenlemiş olduğu çocuk röntgen görüntülerinden oluşan veri seti ile eğitilmiştir. Genel erişime açık olarak sunulan bu veri setinde toplamda 5.856 adet görüntü bulunmaktadır. Bu veri seti sınıflandırıcı ağ yapısında doğrudan kullanılmasına rağmen içerisinde maske görüntüler içermediği bölütleme ağ yapısında kullanılamamıştır. Bu noktada aynı veri setinden Pham (2021) tarafından 2686 adet görüntü seçilerek hazırlanan ikinci bir veri seti kullanılmıştır.

Ağ yapılarının eğitim ve testi için k-katlamalı çapraz doğrulama tekniği kullanılmış ve her iki veri setinde de %20 oranında görüntü test için ayrılmıştır. Buna göre veri setleri içerisindeki görüntülere doğrudan sınıflandırma işlemi yapıldığında sırasıyla %97,18 ve %98,33'lük doğrulama oranlarına ulaşılmıştır. Ulaşılan bu doğruluk değerleri geliştirilen sınıflandırıcı ağ yapısı ile literatürdeki birçok çalışmadan daha başarılı sonuçlar elde edilebildiğini göstermiştir.

Tez kapsamında ön işlem olarak kullanılacak bir bölütleme sürecinin sınıflandırma başarısını artırması beklenmiştir. Bu nedenle akciğer bölütlemesi gerçekleştirecek şekilde tasarlanan U-Net tabanlı ağ mimarisi Veriseti-2 ile eğitilmiş ve yaklaşık %98,9 gibi yüksek bir doğrulama oranına ulaşılabilmiştir. Bölütlemedeki bu başarılı sonuçların sınıflandırmaya olan etkisini incelemek için ilk önce Veriseti-1 üzerinde test edilmiştir. İşlemler sonucunda bölütlenmiş görüntüler için sınıflandırma doğruluk değeri %95,24 olarak gerçekleşmiştir. Bu değerler orijinal görüntüler için üretilen değerlerden yaklaşık olarak %2 oranında düşük çıkmıştır. Bu durum tez için öngörülen bölütlenmiş görüntülerde daha yüksek oranların elde edilmesi düşüncesine tersi bir sonuç ortaya çıkarmıştır. Bu durumun nedenleri araştırılmış ve Veriseti-1'in görüntü sınıflarındaki dengesiz bir dağılımın buna neden olacağı düşünülmüştür. Bu nedenle pnömoni ve normal görüntü sayısı daha dengeli olan Veriseti -2 için bölütlenmiş görüntülerde benzeri süreçler yürütülmüştür.

Bu aşamada bölütlenmiş görüntülerin arka plan piksellerinin tamamen siyah olması ağ parametrelerinin eğitimi için olumsuz bir durum oluşturabileceği düşüncesi gelişmiş ve bu durumun etkisini gösterebilmek için bölütlenmiş görüntüler için 3 farklı arka plana sahip üç adet bölütlenmiş görüntüler oluşturulmuştur. Buna göre ilk sette yüne tüm görüntülerde arka plan siyah olarak bırakılmış, ikinci sette tam tersi beyaz bir renk tercih edilmiştir. Son sette ise görüntüdeki tüm piksellerin renk değerlerinin ortalaması alınarak bir arka plan rengi belirlenmiştir. Dolayısıyla son setteki arka plan rengi tüm görüntülerde farklılık göstermektedir. Bu üç yeni veri setinde yapılan sınıflandırma doğruluk oranları sırasıyla %96,73, %.96.39 ve %97,14 olarak bulunmuştur.

Bu noktada arka plan renginin değiştirilmesinin sınıflandırma başarısına olan etkisinin aslında akciğer alanı dışında kalan bölgelerinde sınıflandırmaya etki ettiğini göstermektedir. Fakat bu bölgelerde pnömoniyeye ilişkin bilgilerin yer almaması kafa karıştırıcıdır. Bunun nedenleri üzerine düşünüldüğünde aslında başarılı akciğer bölütlemesi gerçekleştirilmesine rağmen, bölütleme ağ yapısının eğitimi için kullanılan veri setinde akciğer bölgelerinin eksik olarak işaretlendiği anlaşılmıştır. Bu da akciğer bölgesinin mevcut bölütlenmiş görüntüler içerisinde daha geniş bir alana sahip olması gerektiğini göstermektedir. Bu nedenle akciğer bölgesini de içine alan bir göğüs bölgesi seçiminin sınıflandırma için daha başarılı sonuçlar vereceği düşünülmüştür. Bunun çözümü olarak çalışmanın son aşamasında sadece akciğer bölgesini seçmek yerine göğüs (thorax) bölgesinin tümüyle seçilebileceği bir yaklaşım önerilmiştir. Bu yaklaşıma göre yapılan bölütleme ile elde edilen görüntüler üzerinden yapılan sınıflandırma çalışmaları sonucunda %98.55'lik bir doğruluk oranına ulaşılabilmiştir.

Sonuç olarak; doğrudan akciğer maske görüntülerinin bölütlenmesi sınıflandırma başarısını düşürdüğü görülmüş, fakat göğüs bölgesi seçiminin sınıflandırma başarımını artırdığı tespit edilmiştir. Bu durum akciğer bölütlemesi için kullanılan maske görüntülerin yeterli olmadığını akciğer bölgesinin tümünün seçilmesinin daha etkili sonuçlar üretebileceğini göstermektedir. Tezin önermesi olan bölütlemenin sınıflandırma başarısını artıracak fikri göğüs bölgesi seçimi ile doğrulanmıştır. Fakat, özellikle çocuklara ait röntgen görüntülerinde bu konuda veri eksikliği bulunmaktadır. Bu konuda çalışmak isteyen araştırmacılar, sınıflandırma için etkili bir değerler üretebilecek yetişkinlere ait röntgen görüntüleri ile bölütleme ağ yapısının eğitilmesi, bu eğitilmiş ağın çocuk görüntülerinde kullanılması uygun olabilir.

Özellikle çocuk röntgen görüntüleri ile ilgili literatürde veri seti eksikliği bulunmaktadır. Bu noktada hem çocuk hastalıkları konusunda uzman hem de tıbbi görüntüleme ve yorumlama konusunda uzman kişilerle beraber yapılacak çalışmalar büyük önem arz etmektedir. Böyle bir çalışma farklı çocuk hastalıklarının teşhisi konusunda yapılacak çalışmalar için literatüre önemli bir kaynak oluşturacaktır.

Bu çalışmada bölütleme ve sınıflandırma ağ yapıları birbirinden bağımsız çalışacak şekilde tasarlanmıştır. Bu alanda çalışmak isteyen araştırmacılar için bu iki ağ yapısını birleştirecek bir yaklaşım geliştirebilirler. Çünkü her iki ay yapısında da ortak evrişim ve havuzlama katmanları bulunmaktadır. Bunların birleştirilerek kullanılması hesaplanması gereken parametre sayısını azaltacak eğitim sürecini kısaltacaktır.

KAYNAKÇA

- Akcay, S. ve Bektas, M. (2021). Lung segmentation in chest radiographs using deep learning and saliency maps. *Biomedical Signal Processing and Control*, 66, 102446. doi: 10.1016/j.bspc.2020.102446
- Ali, A. R. I. ve Hanbay, D. (2018). Bölgesel evrimsel sinir ağları tabanlı mr görüntülerinde tümör tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34(3), 1395-1408.
- Ayan, E. ve Ünver, H. M. (2019, Nisan). Diagnosis of pneumonia from chest x-ray images using deep learning. In *2019 Scientific Meeting on Electrical-Electronics ve Biomedical Engineering and Computer Science (EBBT)* (pp. 1-5). Ieee.
- Aydın, İ. ve Bingöl, Ö. (2022). Göğüs radyografilerinden u-net tabanlı akciğer bölütlemesinin yapılması ve pnömoni tespitine etkisinin incelenmesi. *2nd International Conference on Engineering and Applied Natural Sciences*, 15-18 Oct. 2022, Konya.
- Cao, F. ve Zhao, H. (2021). Automatic lung segmentation algorithm on chest x-ray images based on fusion variational auto-encoder and three-terminal attention mechanism. *Symmetry*, 13(5), 814.
- Chen, H., Zhang, Y., Zhang, W., Liao, P. ve Shen, J. (2019). Automated lung segmentation in ct images using deep learning with covariance matrix adaptation evolution strategy. *IEEE Access*, 7, 149307-149316. doi: 10.1109/ACCESS.2019.2946047
- Cui, W., Xie, Y., Liu, X., Gao, Y., Wang, J. ve Xia, Y. (2020). An efficient convolutional neural network for thoracic organs segmentation. *Frontiers in Bioengineering and Biotechnology*, 8, 622824. doi: 10.3389/fbioe.2020.622824.
- Çiçek, Ö., Ümit Avcı, A. ve Ertürk, S. (2019). Multi-modal lung segmentation using 3d u-net for ct images. *Computerized Medical Imaging and Graphics*, 75, 40-47. doi: 10.1016/j.compmedimag.2019.05.005
- Dai, H. ve Cao, Y. (2020). An improved encoder-decoder deep learning method for pulmonary nodule detection in ct images. *Journal of Medical Systems*, 44(2), 43. doi: 10.1007/s10916-019-1507-5.

- Demir, Y. ve Bingöl, Ö. (2021, June). Pneumonia detection from pediatric lung x-ray images with convolutional neural network method. *In 2021 29th Signal Processing and Communications Applications Conference (SIU)* (s. 1-4). IEEE.
- Diniz, J. O., Quintanilha, D. B., Santos Neto, A. C., da Silva, G. L., Ferreira, J. L., Netto, S. ... ve Gattass, M. (2021). Segmentation and quantification of covid-19 infections in ct using pulmonary vessels extraction and deep learning. *Multimedia Tools and Applications*, 80(19), 29367-29399.
- Doğan, F., ve Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- Dong, X., Lei, Y., Zhu, X., Xu, S., Zhou, F. ve Yang, X. (2017). Automatic pulmonary lobe segmentation using a novel deep network with both V-Net and U-Net: A retrospective study. *Medical Physics*, 44(10), 5608-5619. doi: 10.1002/mp.12471
- DSÖ. (2013). Pocketbook of hospital care for children: Second edition. <https://www.who.int/publications/i/item/978-92-4-154837-3>, Erişim: 10 Şubat 2022.
- Efe, M., Özgür, L. ve Aydın, B. (1999). Yapay sinir ağları ve uygulamaları. *İTÜ Dergisi*, 1(1), 13-24.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. ve Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- Ferkol, T ve Schraufnagel D. (2014). The global burden of respiratory disease. *Ann. Am. Thorac. Soc*, 11(3), 404–406.
- Fırıldak, K., ve Talu, M. F. (2019). Evrimsel sinir ağlarında kullanılan transfer öğrenme aklaşımlarının incelenmesi. *Computer Science*, 4(2), 88-95.
- Gershenson, C. (2003). Artificial neural networks for beginners. *arXiv preprint cs/0308031*.
- Ghazal, M. ve Mohammed, S. A. (2019). Deep learning-based lung segmentation in ct images using unet. *In 2019 7th International Conference on Computing, Engineering, and Design (ICCED)* (pp. 1-4). IEEE. <https://doi.org/10.1109/ICCED.2019.8860966>
- Girshick, R., Donahue, J., Darrell, T. ve Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *IEEE Conference on Computer Vision and Pattern Recognition* (pp. 580-587).

- Gite, S., Mishra, A. ve Kotecha, K. (2022). Enhanced lung image segmentation using deep learning. *Neural Computing and Applications*, 1-15.
- Golan, R., Jacob, C., Denzinger, J., Oren, Y. ve Jerebko, A. (2018). Deep learning for automatic pulmonary nodule detection in medical ct images. *Journal of Imaging*, 4(3), 48. doi: 10.3390/jimaging4030048.
- Hahnloser, R. H., Sarpeshkar, R., Mahowald, M. A., Douglas, R. J. ve Seung, H. S. (2000). Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit. *Nature*, 405(6789), 947-951.
- Hao, X., Zhang, G. ve Ma, S. (2016). Deep learning. *International Journal of Semantic Computing*, 10(03), 417-439.
- Hashmi, M. F., Katiyar, S., Hashmi, A. W. ve Keskar, A. G. (2021). Pneumonia detection in chest X-ray images using compound scaled deep learning model. *Automatika*, 62(3-4), 397-406.
- Hashmi, M. F., Katiyar, S., Keskar, A. G., Bokde, N. D. ve Geem, Z. W. (2020). Efficient pneumonia detection in chest xray images using deep transfer learning. *Diagnostics*, 10(6), 417.
- Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*, Mac. Milan, New York.
- Hesamian, M. H., Jia, W., He, X. ve Kennedy, P. (2019). Deep learning techniques for medical image segmentation: achievements and challenges. *Journal of Digital Imaging*, 32(4), 582-596.
- Huang, C. H., Lee, T. I., Lin, C. J. ve Lin, C. (2018). Heart disease prediction using deep learning and big data analytics. In *2018 14th International Conference on Ubiquitous Intelligence and Computing and 2018 14th International Conference on Autonomic and Trusted Computing* (pp. 556-564).
- Huang, Y., Zhang, Y., Wang, X., Liao, P. ve Shen, J. (2020). Automatic segmentation of lungs with severe pathologies in ct using deep learning and synthetic data. *Computers in Biology and Medicine*, 120. 103758. doi: 10.1016/j.combiomed.2020.103758
- Hussein, S. ve Tizhoosh, H. R. (2020). Automated lung segmentation of ct images using unet with transfer learning. In *2020 IEEE International Symposium on Medical Measurements and Applications (MeMeA)* (pp. 1-6). IEEE.
- Jaiswal, A. K., Tiwari, P., Kumar, S., Gupta, D., Khanna, A. ve Rodrigues, J. J. (2019). Identifying pneumonia in chest X-rays: A deep learning approach. *Measurement*, 145, 511-518.

- Karami, E., Vafaei, A. ve Dargahi, J. (2020). A new approach for lung segmentation in ct images using encoder-decoder deep learning architecture. *Journal of Medical Signals and Sensors*, 10(4), 295-302. doi: 10.4103/jmss.JMSS_45_19
- Kaya, B. ve Önal, M. (2021). Covid-19 tespiti için akciğer bt görüntülerinin bölütlenmesi. *Avrupa Bilim veTeknoloji Dergisi*, (28), 1296-1303.
- Kermany, D., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., ... ve Hu, J. (2018). Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 172(5), 1122-1131.
- Kermany, D., Zhang, K., ve Goldbaum, M. (2018). Labeled optical coherence tomography (oct) and chest x-ray images for classification. *Mendeley Data*, 2(2).
- Keskenler, M. F., ve Keskenler, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.
- Kim, G., Lee, J. H., Lee, J., Lee, J. W. ve Kim, N. (2019). Multi-modal and multi-scale deep learning for lung segmentation on ct images. *Electronics*, 8(12), 1423. doi: 10.3390/electronics8121423
- Kizrak M.A., Bolat B. 2018. Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11 (3), 263-286
- Koç, A. B., ve Akgün, D. (2021). U-net mimarileri ile glioma tümör segmentasyonu üzerine bir literatür çalışması. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 407-414.
- Lakhani, P., Sundaram, B., Zhou, B. ve Yang, Q. (2017). Deep learning at chest radiography: Automated classification of pulmonary tuberculosis by using convolutional neural networks, *Radiology*, 284(1), 115-124.
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. doi: 10.1109/5.726791
- Li, C., Wang, X., Wang, Z., Zhou, Y. ve Zhang, Y. (2019). Multi-modal deep learning for robust segmentation of lung in ct. *Journal of X-Ray Science and Technology*, 27(1), 67-80. doi: 10.3233/XST-180414
- Li, X., Chen, H., Qi, X., Dou, Q., Fu, C. W. ve Heng, P. A. (2019). Lung segmentation from ct scans using convolutional neural networks with region proposals. *Medical Image Analysis*, 54, 1-11. doi: 10.1016/j.media.2019.02.004.

- Liang, G., ve Zheng, L. (2020). A transfer learning method with deep residual network for pediatric pneumonia diagnosis. *Computer Methods and Programs in Biomedicine*, 187, 104964.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... ve Sánchez, C. I. (2017). Deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y. ve Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11-26.
- Luo, D., Wang, G., Zhang, K. ve Bai, J. (2020). Deep Multi-modal learning for noninvasive diagnosis of lung cancer. *IEEE Transactions on Neural Networks and Learning Systems*, 31(2), 552-561. doi: 10.1109/TNNLS.2019.2904375
- Ma, M., Lu, Y., Li, Y., Chen, W. ve Liang, Z. (2015). Automatic segmentation of breast tumors in ultrasound images using watershed transform and active contour model. *Journal of Medical Systems*, 39(8), 89.
- Ma, X., Kim, J. ve Koehler, J. (2019). Deep learning for drug efficacy prediction. *Nature Communications*, 10(1), 1-12.
- McLuckie, A. (Ed.). (2009). Respiratory disease and its management. *Springer Science ve Business Media*.
- Monshi, M. M. A., Poon, J., Chung, V., ve Monshi, F. M. (2021). CovidXrayNet: Optimizing data augmentation and CNN hyperparameters for improved COVID-19 detection from CXR. *Computers in Biology and Medicine*, 133, 104375.
- Narin, A., Kaya, C., ve Pamuk, Z. (2021). Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *Pattern Analysis and Applications*, 24(3), 1207-1220.
- Öztemel, E. (2003). *Yapay sinir ağları*. İstanbul: PapatyaYayincılık.
- Öztürk, N. ve Öztürk, S. (2021). Bölütleme tabanlı yeni görüntü iyileştirme yöntemi. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 975-981.
- Pang, T., Guo, S., Zhang, X. ve Zhao, L. (2019). Automatic lung segmentation based on texture and deep features of HRCT images with interstitial lung disease. *BioMed Research International*, 2019.
- Patil, A., Kumar, A. ve Raghavendra, U. (2015). Automatic segmentation of MRI brain images with intensity inhomogeneity correction using fuzzy C-means clustering. *Journal of medical physics/Association of Medical Physicists of India*, 40(3), 157.
- Pham, T. D. (2021). Classification of COVID-19 chest X-rays with deep learning: new models or fine tuning?. *Health Information Science and Systems*, 9(1), 1-11.

- Powers, D. M. (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *arXiv preprint arXiv:2010.16061*.
- Puttagunta, M. ve Ravi, S. (2021). Medical image analysis based on deep learning approach. *Multimedia Tools and Applications*, 80(16), 24365-24398.
- Rahman, T., Khandakar, A., Kadir, M. A., Islam, K. R., Islam, K. F., Mazhar, R., ... ve Chowdhury, M. E. (2020). Reliable tuberculosis detection using chest X-ray with deep learning, segmentation and visualization. *IEEE Access*, 8, 191586-191601.
- Rajaraman, S., Candemir, S., Kim, I., Thoma, G. ve Antani, S. (2018). Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. *Applied Sciences*, 8(10), 1715.
- Refaeilzadeh, P., Tang, L. ve Liu, H. (2009). Cross-validation. *Encyclopedia of Database Systems*, 5, 532-538.
- Ronneberger, O., Fischer, P. ve Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing And Computer-Assisted Intervention* (s. 234-241). Springer, Cham.
- Rudan, I., Boschi-Pinto, C., Biloglav, Z., Mulholland, K. ve Campbell, H. (2008). Epidemiology and etiology of childhood pneumonia. *Bulletin of the World Health Organization*, 86, 408-416B.
- Schmidt, U., Weigert, M., Broaddus, C. ve Myers, G. (2018, September). Cell detection with star-convex polygons. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (s. 265-273). Springer, Cham.
- Setio, A. A. A., Traverso, A., de Bel, T., Berens, M. S. N., Bogaard, C. V. D., Cerello, P., ... ve Ciompi, F. (2017). A deep learning framework for lung segmentation in CT images using Convolutional Neural Networks and Unsupervised Feature Learning. *Medical Image Analysis*, 42, 60-70. doi: 10.1016/j.media.2017.06.007.
- Tursyngaliyeva, A. (2019). Deep Learning for medical image segmentation: *Pneumonia Detection by Assem Tursyngaliyeva*. August). doi, 10.
- Türkoğlu, M., Hanbay, K., Sivrikaya, I. S., ve Hanbay, D. (2021). Derin evrışimsel sinir ağı kullanılarak kayısı hastalıklarının sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334-345.
- URL-1, <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia> 30 Kasım 2022
- Wand, M., Gültekin, S., Bergtholdt, M. ve Hahn, H. K. (2020). Two-step convolutional neural network for pulmonary lobe segmentation. In C. R. Houck (Ed.), *Medical*

- Imaging 2020: Computer-Aided Diagnosis (Vol. 11314, p. 113142D). *International Society for Optics and Photonics*. doi: 10.1117/12.2551325
- Wang, W., Li, L., Li, Y., Han, X., Li, Y. ve Li, B. (2019). Deep learning for automatic lung segmentation from ct scan images. *Medical Physics*, 46(5), 2168-2179. doi: 10.1002/mp.13463
- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagci, U. ve Liu, H. (2016). Computer-aided diagnosis with deep learning architecture: applications to breast lesion classification. *arXiv preprint arXiv:1606.05718*.
- Wani, MA, Bhat, FA, Afzal, S. ve Khan, AI (2020). Derin öğrenmedeki gelişmeler. *Springer*.
- Wu, S., Zheng, Q., Chen, X. ve Guo, X. (2019). Lung tumor segmentation based on fuzzy c-means clustering and convolutional neural networks. *Journal of Healthcare Engineering*, 2019.
- Yıldız, İ., ve Karadeniz, A. T. (2019). Enhancement of breast cancer diagnosis accuracy with deep learning. *Avrupa Bilim ve Teknoloji Dergisi*, 452-462.
- Yue, Z., Ma, L., ve Zhang, R. (2020). Comparison and validation of deep learning models for the diagnosis of pneumonia. *Computational Intelligence and Neuroscience*.
- Zhang, H., Lu, W. ve Zhang, Y. (2020). An improved encoder-decoder network for lung segmentation in ct images. *Journal of Healthcare Engineering*, 2020, 8886146. doi: 10.1155/2020/8886146
- Zhang, Q., Li, W. ve Wang, H. (2018). Automatic segmentation of lung nodules in ct images using convolutional neural networks and active contour model. *Journal of Healthcare Engineering*, 2018, 3194691. doi: 10.1155/2018/3194691.
- Zhao, B., Guo, Y., Zheng, C., Zhang, M., Lin, J., Luo, Y., ... ve Liang, H. (2019). Using deep-learning techniques for pulmonary-thoracic segmentations and improvement of pneumonia diagnosis in pediatric chest radiographs. *Pediatric Pulmonology*, 54(10), 1617-1626.

ÖZGEÇMİŞ

İlk ve ortaöğrenimini Zigana İlköğretim Okulunda, lise eğitimini 1996 yılında Trabzon Teknik Lisesi Bilgisayar Bölümünde tamamlamıştır. Lisans eğitiminde 2002 yılında KTÜ Fatih Eğitim Fakültesi Bilgisayar ve Öğretim Teknolojileri Öğretmenliğinden mezun oldu. 2002-2018 yılları arasında Gümüşhane Kız Teknik ve Meslek Lisesinde; bilgisayar öğretmenliği, müdür yardımcılığı ve müdür başyardımcılığı yaptı. 2017 yılında KTÜ Eğitim Bilimleri Enstitüsü Eğitim Teknolojileri alanında Yüksek Lisans (Tezsiz) yaptı. 2018'in Ekim ayından itibaren Gümüşhane Üniversitesi Bilgi İşlem Daire Başkanlığında şube müdürü olarak görev yapmaktadır.

