

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKCİĞER ANOMALİLERİNİN ÇOK SINIFLI SINIFLANDIRILMASI: FANTOM
MALZEMELERDEN AKCİĞER DOKULARINA

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DERYA NARİN

ŞUBAT 2022

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKCİĞER ANOMALİLERİNİN ÇOK SINIFLI SINIFLANDIRILMASI: FANTOM
MALZEMELERDEN AKCİĞER DOKULARINA

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Derya NARİN

DANIŞMAN: Dr. Öğr. Üyesi Tuğba Özge ONUR

ZONGULDAK
Şubat 2022

KABUL:

Derya NARİN tarafından hazırlanan “Akciğer Anomalilerinin Çok Sınıflı Sınıflandırılması: Fantom Malzemelerden Akciğer Dokularına” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir. 08/02/2022

Danışman: Dr. Öğr. Üyesi Tuğba Özge ONUR

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü

Üye: Doç. Dr. Rukiye UZUN ARSLAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü

Üye: Dr. Öğr. Üyesi Veli BAYSAL

Bartın Üniversitesi, Mühendislik, Mimarlık ve Tasarım Fakültesi, Bilgisayar Mühendisliği Bölümü

ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

....../....../2022

Prof. Dr. Ahmet ÖZARSLAN
Fen Bilimleri Enstitüsü Müdürü



“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Derya NARİN

ÖZET

Yüksek Lisans Tezi

AKCİĞER ANOMALİLERİNİN ÇOK SINIFLI SINIFLANDIRILMASI: FANTOM MALZEMELERDEN AKCİĞER DOKULARINA

Derya NARİN

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Tuğba Özge ONUR

Şubat 2022, 45 sayfa

Başta ülkemiz olmak üzere tüm dünyada kanserin, kanser benzeri dokuların ya da insanları hızlı bir şekilde ölüme götürebilen hastalıkların tespit edilmesi ile ilgili yapılan araştırmalar hızlı bir şekilde gelişmektedir. Çünkü, bu yapıların erken tanı ve tespiti, hızlı müdahale edilebilmesini kolaylaştırarak kişilerin daha kısa sürede sağlığına kavuşmasını mümkün kılmaktadır. Bu araştırmaların, doğrudan kişiler üzerinden yapılması etik olarak ciddi problemlere yol açabilmektedir. Örneğin, medikal görüntüleme cihazlarının tasarımı ve kalibrasyonu, görüntüleme cihazlarının kullanımının uygulayıcılara öğretilmesi süreci, bilimsel araştırmaların birçoğunda doğrudan insanlar üzerinden görüntüleme yaparak ölçüm almak, vb. durumlar ciddi problemlere yol açabilmektedir. Bu problemlerin çözümü için doku benzeri olarak oluşturulan fantomlar veya yazılımsal olarak benzetim çalışmalarıyla üretilen sentetik fantomlar kullanılabilir. Bu tez çalışmasında, derin öğrenme modelleri üzerinden elde edilen öznitelikler ve geleneksel sınıflandırma algoritmaları kullanılarak yazılımsal olarak üretilen iyi huylu ya da kötü huylu kitlelerden oluşan sentetik göğüs fantom

ÖZET (devam ediyor)

görüntülerinin otomatik tanı ve tespiti amaçlanmıştır. Ayrıca, oluşturulan model X-ışını (X-ray) ve Bilgisayarlı Tomografi (BT) görüntülerine de uygulanarak performans karşılaştırılması yapılmıştır. Sonuç olarak, üretilen sentetik fantom görüntüleri ile %100 başarımlar elde edilmiştir.

Anahtar Kelimeler: Fantom, Derin Öğrenme, Sınıflandırma, Akciğer Tümörü.

Bilim Kodu: 608.05.00



ABSTRACT

M.Sc. Thesis

MULTI-CLASS CLASSIFICATION OF LUNG ANOMALIES: FROM PANTOM MATERIALS TO LUNG TISSUES

Derya NARİN

Zonguldak Bülent Ecevit University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Thesis Advisor: Assist. Prof. Dr. Tuğba Özge ONUR

February 2022, 45 pages

Researches on the detection of cancer, cancer-like tissues or diseases that can lead people to death rapidly are developing rapidly all over the world, especially in our country. Because the early diagnosis and detection of these structures facilitates rapid intervention and makes it possible for people to regain their health in a shorter time. Conducting these studies directly on individuals can lead to serious ethical problems. For example, the design and calibration of medical imaging devices, the process of teaching the use of imaging devices to practitioners, taking measurements by imaging directly on humans in most scientific researches, etc. situations can cause serious problems. To solve these problems, phantoms created as tissue-like or synthetic phantoms produced by software simulation studies can be used. In this thesis, it is aimed to automatically diagnose and detect synthetic chest phantom images consisting of benign or malignant masses produced by software using features obtained from deep learning models and traditional classification algorithms. In addition, the performance comparison was made by applying the created model to X-ray and Computed Tomography images. As a result, 100% performance values were obtained with the synthetic phantom images produced.

ABSTRACT (continued)

Keywords: Phantom, Deep Learning, Classification, Lung Tumor

Science Code: 608.05.00



TEŞEKKÜR

Yüksek lisans tez çalışmamda her türlü bilgi, deneyim ve tecrübelerini benden esirgemeyen, hayatımın her alanında örnek alacağım çok değerli danışman hocam Dr. Öğretim Üyesi Tuğba Özge ONUR'a teşekkür ederim.

Eğitim-öğretim hayatım boyunca her zaman yanımda olan, beni her koşulda destekleyen ve benden maddi manevi desteklerini esirgemeyen babam merhum Hasan TEKELİ'ye, annem Fatma TEKELİ'ye, babaannem Satı TEKELİ'ye tüm varlığımla teşekkür ederim.

Ailenin en küçüğü olarak hayatlarına dahil olduğumdan beri beni koruyup kollayan ve kimi zaman yol gösterici kimi zaman arkadaş olan abimler Cengiz ve Hüseyin TEKELİ'ye, ablamlar Dilek ABACI, Hacer YILDIRIM ve Sümeyra BAYRAKTAR'a ve eşlerine ayrıca teşekkür ederim

Şu gök kubbenin altında her daim beni cesaretlendiren, bana destek olan sevgili eşim Ali NARİN'e ve biricik yavrularım Muhammed Yusuf NARİN ve Hatice Yusra NARİN'e sonsuz teşekkür ederim.

Bu çalışmayı (Proje No: 2021-75737790-01) destekleyen Zonguldak Bülent Ecevit Üniversitesi Rektörlüğüne, Bilimsel ve Teknolojik Araştırma Projeleri Koordinatörlüğüne (BAP) teşekkür ederim.



İÇİNDEKİLER

	<u>Sayfa</u>
KABUL:	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ.....	xv
 BÖLÜM 1 GİRİŞ	 1
 BÖLÜM 2 LİTERATÜR	 3
 BÖLÜM 3 DENEYSEL OLARAK VE BENZETİM İLE FANTOM ÜRETİMİ.....	 5
3.1 FANTOM NEDİR?	5
3.2 FANTOM ÜRETİMİNDE KULLANILAN MALZEMELER.....	5
3.3 BENZETİM İLE FANTOM ÜRETİMİ	6
3.3.1 Filtrelenmiş Geri İzduşüm (FGİ) Algoritması	6
3.3.2 Shepp-Logan Fantomu.....	8
 BÖLÜM 4 EVRİŞİMLİ SİNİR AĞLARI VE SINIFLANDIRMA ALGORİTMALARI	 11
4.1 DERİN ÖĞRENME	11
4.1.1 Evrişimli Sinir Ağı.....	11
4.1.1.1 Evrişim Katmanı	12
4.1.1.2 Havuzlama Katmanı.....	13
4.1.1.3 Tam Bağlaşimli Katman/lar	14

İÇİNDEKİLER (devam ediyor)

4.2 ÖN EĞİTİMLİ ESA MODELLERİ.....	15
4.2.1 AlexNet ESA Modeli.....	15
4.2.2 ResNet50 ESA Modeli.....	15
4.3 ESA ÜZERİNDEN ÖZNİTELİK ÇIKARIMI.....	16
4.4 SINIFLANDIRMA ALGORİTMALARI	17
4.4.1 Destek Vektör Makinaları.....	17
4.4.2 K-En Yakın Komşu Algoritması	18
 BÖLÜM 5 KULLANILAN VERİ SETLERİ ve PERFORMANS ÖLÇÜTLERİ	21
 5.1 VERİ SETLERİ.....	21
5.1.1 X-Işını (X-Ray) Veri Seti	21
5.1.2 Bilgisayarlı Tomografi (BT) Veri Seti.....	23
5.1.3 Fantom Veri Seti.....	23
5.2 PERFORMANS ÖLÇÜTLERİ	24
 BÖLÜM 6 SONUÇLAR.....	27
 6.1 X-IŞINI GÖRÜNTÜLERİ İLE COVID-19 HASTALARININ TESPİT PERFORMANSLARI	27
6.2 BT GÖRÜNTÜLERİ İLE AKCİĞER KANSERİ HASTALARININ TESPİT PERFORMANSLARI	30
6.3 BENZETİM FANTOMU İLE ELDE TÜMÖRLÜ GÖRÜNTÜLERİN TESPİT PERFORMANSLARI	35
 BÖLÜM 7 TARTIŞMA VE ÖNERİLER.....	39
 KAYNAKLAR.....	41
 ÖZGEÇMİŞ	45

ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 3.1 Oluşturulan göğüs boşluğu fantomu örneği.....	9
Şekil 4.1 ESA mimarisini oluşturan temel katmanlar	12
Şekil 4.2 Evrişim işleminin gösterimi	12
Şekil 4.3 Havuzlama işleminin gösterimi	14
Şekil 4.4 AlexNet mimarisi örneği.....	15
Şekil 4.5 ResNet50 mimarisi örneği	16
Şekil 4.6 ResNet50 ESA modelinden çıkarılan öznetelik haritaları	17
Şekil 4.7 DVM algoritma gösterimi.	18
Şekil 4.8 kNN algoritması gösterimi.....	19
Şekil 5.1 Normal, COVID-19 ve zatürre X-ışını veri örnekleri.....	22
Şekil 5.2 İyi huylu, kötü huylu ve normal BT veri örnekleri.	23
Şekil 5.3 Normal ve tümörlü sentetik göğüs fantom görüntü örnekleri.....	24
Şekil 6.1 X-ışını görüntülerinden elde edilen COVID-19 tespiti akış diyagramı.	28
Şekil 6.2 Orijinal X-ışını ve üç farklı kenar bulma algoritması ile elde edilen örnek görüntüler.....	28
Şekil 6.3 Dört farklı X-ışını görüntüleri ile elde edilen başarımlar a) Orjinal b) Canny c) Roberts d) Sobel.....	29
Şekil 6.4 Derin öğrenme mimarileri ile akciğer kanseri tespiti şematik gösterimi.	31
Şekil 6.5 AlexNet için ESA modelinin üç farklı parti büyüklüğünün performansları.....	31
Şekil 6.6 ResNet50 ESA modeli için üç farklı parti büyüklüğünün performansları.....	33
Şekil 6.7 Sentetik fantom görüntüleriyle gerçekleştirilen sınıflandırma akış şeması.	36
Şekil 6.8 Sentetik fantom görüntülerinin sınıflandırılmasında elde edilen hata matrisi.	37



ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 4.1 Sık kullanılan aktivasyon fonksiyonları.....	14
Çizelge 5.1 Veri seti sınıf bilgisi ve sayıları.	22
Çizelge 6.1 Genel doğruluk değeri sonuçları.	30
Çizelge 6.2 AlexNet için parti boyut 64 ve devir 200 iken performans ölçütleri.	32
Çizelge 6.3 ResNet50 için parti boyutu 64 ve devir 200 iken performans ölçütleri.	33
Çizelge 6.4 Aynı veri setini kullanan çalışmalar ile karşılaştırma.	34
Çizelge 6.5 Sentetik fantom görüntülerinin sınıflandırılmasında elde edilen tüm performans sonuçları.	37



SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

F	: Fonsiyon ifadesi
U	: Dikdörtgen koordinat sistemi
W	: Filtrenin frekans yanıtı
N	: İzdüşümler
θ_i	: Açıların sayısı
x_j^1	: 1. katmandaki j. öznitelik haritası
w_j^{j-1}	: (j-1). katmandaki j. kernel fonksiyonu
y_a^{k-1}	: (k-1). katmandaki a. öznitelik haritası
b_j^k	: k. katmandaki j. bias değeri
N	: (k-1). katmandaki toplam öznitelik sayısı
$*$	: Vektör konvolüsyon işlemi
$^\circ$	: Derece
$\%$	: Yüzde

KISALTMALAR

BDT	: Bilgisayar Destekli Tanı
BT	: Bilgisayarlı Tomografi
DVM	: Destek Vektör Makinaları
ESA	: Evrişimli Sinir Ağları
FGİ	: Filtrelenmiş Geri İzdüşüm
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
kNN	: K-En Yakın Komşuluk
MR	: Manyetik Rezonans
TN	: Doğru Negatif

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

TP	: Doğru Pozitif
UTE	: Çok Kısa Eko Zamanı
YSA	: Yapay Sinir Ağı



BÖLÜM 1

GİRİŞ

Teknolojinin gelişmesi ile medikal görüntüleme tekniklerinde de ilerleme kaydedilmiştir. Röntgen, Bilgisayarlı Tomografi (BT), Manyetik Rezonans (MR) ve ultrason (ses ötesi) vb. klinik araştırmalarda sıklıkla kullanılan medikal görüntüleme yöntemleridir. Ancak, canlılara zarar vermemesi, radyasyon yaymaması ve maliyeti diğer görüntüleme yöntemlerinden az olması gibi nedenlerden dolayı ultrason tabanlı yaklaşımlar mevcut görüntüleme yöntemleri arasında yaygın olarak tercih edilmektedir. Bununla birlikte, canlı dokularının fiziksel temasta bulunmadan incelenmesi ve araştırılması oldukça önemlidir (Sites at al. 2010). Doku benzeri yapılar (fantomlar) ile gerçekleştirilen bu işlemler, araştırmacılar için canlıların en az zarar görmesi adına önemli bir gelişmedir. Fantomlar, gerçek canlı dokusuna yaklaşık olarak benzer özellikleri gösteren yapılardır. Kanser ve benzeri yapıların taranması, çeşitli hastalıkların tespiti, vb. birçok alanda fantomlar kullanılmaktadır. Cihazların kalibrasyonu, görüntüleme cihazlarının kullanımının öğrenilmesi süreci ve bilimsel araştırmaların birçoğunda doğrudan insanlar üzerinden görüntüleme yaparak ölçüm alınması ciddi problemlere yol açabilmektedir (Hocking at al. 2011). Bu problemlerin çözümü için doku benzeri olarak oluşturulan fantomlar veya yazılım tabanlı olarak benzetim çalışmalarıyla üretilen sentetik fantomlar kullanılmaktadır.

Bu tez çalışması kapsamında, röntgen cihazından alınan X-ray görüntüleri, BT cihazından alınan görüntüler ve yazılım tabanlı olarak üretilen sentetik fantom görüntüleri kullanılarak hastalıklı yapıların otomatik tespiti derin öznitelikler ve geleneksel sınıflandırıcılarla yapılmıştır.

Tezin öne çıkan yönleri şu şekilde özetlenebilir.

- I) X-ray, BT ve üretilen sentetik fantom görüntülerinin otomatik tespitteki başarımları araştırılmıştır.
- II) Derin öğrenme modelleri üzerinden elde edilen öznitelikler ile geleneksel makine öğrenme yöntemlerinin birlikte yüksek performans sergilediği gösterilmiştir.

III) Yazılım tabanlı olarak üretilen sentetik fantom görüntülerinde çok yüksek başarımın elde edildiği gösterilmiştir.

IV) Derin öğrenme modellerindeki parametrelerin performansları etkilediği gösterilmiştir.

V) Hibrit bir yaklaşım ile derin öğrenme yaklaşımları ve geleneksel sınıflandırıcılar birleştirilmiştir.

Tezin takip eden diğer bölümlerinde sırasıyla, literatürde fantomlar üzerine yapılan çalışmalar, fantom görüntülerinin elde edilmesi, derin öğrenme modelleri ile geleneksel sınıflandırma algoritmaları, tez kapsamında kullanılan tüm veri setleri ve başarımlar ölçütleri, elde edilen tüm sonuçlar ve yorumları, son olarak tartışma ve öneriler ele alınacaktır.



BÖLÜM 2

LİTERATÜR

İnsan dokusunun etik sebeplerden dolayı sınırlı mevcudiyeti doku taklit eden fantomların benimsenmesine yol açmıştır. Bu sebeple insan dokularını taklit eden fantomlar uzun zamandır kullanılmaktadır. Literatürde akciğer dokusunu ve tümörlerini simüle eden çeşitli çalışmalar mevcuttur. Fushiki ve arkadaşları tümör ilerlemesini ve ilaç etkinliği değerlendirmesini izlemek için mikro-BT görüntüleme kullanarak, iki farklı fare akciğer kanseri modelinin tümör yükünü incelemiş ve akciğer kanseri ilerlemesinin gerçek zamanlı/invaziv olmayan nicel bir analizini gerçekleştirmişlerdir (2009). Diğer bir çalışmada Molinari ve arkadaşları, ultrakısa eko süresi (Ultrashort Echo Time: UTE) manyetik rezonans görüntüleme (MRG) kullanarak akciğerin hayali modeli olarak dikdörtgen bir selüloz köpük sünger kullanmışlardır ve MR deneyleri için proton yoğunluğunun güvenilir tahminlerini ve dolayısıyla bir sünger fantomunda bilinmeyen su içeriğinin analizi için normatif verileri sağlayabilecek tahmin edici bir model geliştirmişlerdir (2014). Sağlıklı bir akciğeri, kanserli akciğerden ayırmak ve akciğer kanserinin evrelerini sınıflandırmak amacıyla bir veri seti oluşturan Gupta ve arkadaşları, Rassal Orman (Random Forest) makine öğrenmesi algoritması uygulayarak veri setini %93,75 doğrulukla sınıflandırmışlardır (2022). Çeşitli akciğer patolojileri ile ilişkili olarak ultrason görüntüleme artefaktları olan B-çizgilerinin anlaşılmasını ve karakterizasyonunu incelemek için Demi ve arkadaşları doku taklit eden akciğer fantomları geliştirmiş standart ultrason görüntüleme ve çok frekanslı görüntüleme yaklaşımı kullanarak açık bir araştırma platformu üzerinden görüntülemişlerdir (2017). Zamani ve arkadaşları akciğer kanseri tespiti için endüstriyel bir gövde fantomu kullanarak frekans alanlı bir mikrodalga görüntüleme algoritması sunmuşlardır (2015). Yinelemeli rekonstrüksiyonlar kullanan Huber ve arkadaşları, ultra düşük doz BT çekimlerinde akciğer nodülü tespit oranını değerlendirerek maksimum yoğunluk projeksiyon rekonstrüksiyonlarının ve yazılımının ek kullanımını araştırmışlardır (2016). BT verileri üzerinden, akciğerlerdeki üç boyutlu bitişik yapıları tanımlamak için gri seviye eşikleme tekniklerinin kullanımını içeren bir bilgisayar algılama yöntemi kullanan Armato ve arkadaşları ise genel performansı, serbest yanıtı alıcı çalışma karakteristiği analizi ile değerlendirerek

görsel yorumlama sırasında gözden kaçabilecek akciğer kanserlerinin tanımlanmasını sağlamışlardır (2002).

Bu tez çalışması kapsamında literatürde mevcut olan ve yukarıda verilen fantom ile ilgili olan çalışmalardan farklı olarak, oluşturulan derin öğrenme modeli ile Filtrelenmiş Geri İzdüşüm (FGİ) yöntemi kullanılarak üretilen ve farklı konumlarda kitleler içeren 500 adet sentetik göğüs fantom görüntüsü sınıflandırılmıştır. Üretilen sentetik fantom ve oluşturulan derin öğrenme model başarımının test edilebilebilmesi için ayrıca, X-ışını görüntülerinden oluşan ve COVID-19 ve zatürre hastalarına ait göğüs görüntüleri içeren ve iyi huylu (bening), kötü huylu (malignant) ve normal olmak üzere üç farklı sınıfa ait akciğer BT görüntüleri içeren veri setleri kullanılmıştır. Bunun yanı sıra model performansı değerlendirilirken, ön işlem olarak iyi/kötü huylu kitlelerin ya da çevreleyen dokunun kenarlarının belirlenmesinin, parti büyüklüğü ya da dönem sayısı gibi model parametrelerinin etkisi incelenmiştir. Bu amaçla, ele alınan X-ışını görüntüleri üzerinde Canny, Roberts ve Sobel olmak üzere üç farklı kenar bulma algoritması uygulanarak, hem kullanılan model başarımları hem de ön işlemenin model başarımlarına etkisi irdelenmiştir. Elde edilen sonuçlara göre, orijinal X-ışını görüntüleri üzerinden alınan sonuçların diğer görüntülere göre çok daha yüksek performans göstermesi nedeniyle ele alınan diğer BT ve üretilen sentetik fantom görüntüleri veri setlerinde görüntüler üzerinde herhangi bir kenar belirleme ön işlemesi yapılmamıştır. Ayrıca, derin öğrenme yaklaşımlarının performansını önemli ölçüde değiştiren ağ parametreleri olan epoch (dönem) ve batch (parti) büyüklüğünün etkileri analiz edilerek BT görüntüleri ile akciğer kanseri tespitindeki rolleri irdelenmiştir. Böylece, yüksek başarımın elde edilebildiği derin öğrenme modeli ve ağ parametre değerleri belirlenmiştir.

BÖLÜM 3

DENEYSEL OLARAK VE BENZETİM İLE FANTOM ÜRETİMİ

3.1 FANTOM NEDİR?

Doku benzeri yapılar yani fantomlar, tıbbi fizikte ve medical alandaki çalışmalarda çok önemli bir yere sahiptir. Fantomların ortaya çıkış sebebi çok eskilere dayanmaktadır. X-ışınlarının keşfedilmesinden sonra, radyasyonun tıbbi faydalarına ilişkin haberler hızla yayılmıştır. Böylece ilk röntgen görüntüsü, 1896 yılında Prof. Wilhelm Roentgen'in eşinin elinden elde edilmiştir (Kevles 1997). Fakat radyasyonun zararlı etkileri ortaya çıkınca deneysel çalışmalara insanlar gönüllü olmak istememişlerdir. Bu nedenle, deneysel çalışmalardaki gelişmelerin kötü etkilenmemesi ve ilerleme kaydedilmesi için canlı dokularına benzer yapılar olan fantomlar ortaya çıkmıştır ve üretilmeye başlanmıştır (Hall at al. 1997). Daha sonra bu yapılar üzerinden radyasyonun etkileri vb. çalışmalar gerçekleştirilmiştir.

Canlı dokuların mekanik ve elektriksel özelliklerine benzer yapılar olan fantomlar, görüntüleme teknolojisinin gelişmesinde, kanser araştırmalarında, doğrudan insan kullanımının çok sıkıntılı olduğu çalışmalarda ve daha birçok alanda kullanılmaktadır. Fantomlar hem deneysel hem de benzetim ile sentetik olarak üretilmektedir. Özellikle bir fantomda amaç, fantom içindeki materyallerin genellikle insan dokusunu simüle etmesidir (Chmarra at al. 2013). Bu sebeple deneysel olarak üretilen fantomlarda birçok farklı malzeme kullanılmaktadır. Bölüm 3.2'de fantom üretiminde kullanılan malzemeler ele alınmaktadır.

3.2 FANTOM ÜRETİMİNDE KULLANILAN MALZEMELER

Fantom oluştururken, uygun malzemelerin seçimi kritik öneme sahiptir. Çoğu zaman fantomlar, kas, kemik veya akciğer gibi bir tür dokuyu simüle etmek için tasarlanır. Benzetimi yapılacak dokuların tümü hem fiziksel hem de radyolojik olarak farklı özelliklere sahiptir ve fantom materyallerinin amacı bu fiziksel ve radyolojik özellikleri mümkün olduğunca doğru bir şekilde temsil etmektir.

İnsan dokularını taklit etmek için kullanılan birçok fantom malzemesi bulunmaktadır. Radyolojik doku parametrelerinin sağlanması için hidrojel, organojel ve esnek elastomer malzemeler kullanılır (Hunt at al. 2013). Agar, agaroz ve jelatin jeller gibi malzemeler ise genellikle doku elektrik parametrelerini taklit etmek için kullanılır. Kolay temin edilmesi sebebiyle jelatin jellerin kullanımı oldukça yaygındır. İnsan dokusunun kolay ve ucuz yolla bir benzerinin gerçekleştirilmesi için jelatin fantomlarının kullanılması önerilmektedir. (Marchal at al. 1989).

Fantomların üretilmesinde en önemli kriter benzetilmek istenilen dokuların akustik özelliklerine sahip olunmasının sağlanabilmesidir. Doku fantomlarındaki akustik özellikler büyük oranda materyalin hazırlanması ve kullanımına bağlıdır (Onur 2016). Bununla beraber akustik özelliklerin belirlenmesinde oda sıcaklığı dikkate alınır. Gerçekte akustik özellikler sıcaklık ve dokulara bağlı olarak değişiklik gösterir. Bu materyallerin kullanımında karşılaşılabilecek en önemli sorun mikrobiyolojik unsurların (bakteri ve mantarların) zaman içinde gelişmesi ve hassas yapıları nedeniyle fantomların fiziksel ve akustik özelliklerini kaybedebilmeleridir (Bellingham 2010).

3.3 BENZETİM İLE FANTOM ÜRETİMİ

Tomografik rekonstrüksiyon, X-ray, BT, pozitron emisyon tomografisi, tek foton emisyon tomografisi ve manyetik rezonans görüntüleme için belirli kazanım yöntemleri dahil olmak üzere neredeyse tüm tanısal görüntüleme modalitelerinin temelini oluşturur. Radyografik görüntünün yeniden yapılandırılması teknolojilerinde matematiksel yöntemler önemli bir yer tutmaktadır. Geri İzdüşüm, yinelemeli ve analitik iki boyutlu Fourier, Filtrelenmiş Geri İzdüşüm (FGİ) yöntemleri, görüntünün yeniden yapılandırılmasında kullanılan en önemli yöntemlerdendir (Onur 2021). Bu tez çalışmasında, FGİ yöntemi ve Shepp-Logan filtresi kullanılarak göğüs sentetik fantom görüntüleri oluşturulmuştur. Ayrıca, elde edilen sentetik fantom görüntüleri ile, FGİ algoritmasının tıp ve endüstri alanındaki çeşitli uygulamalar için önemli olabileceği de gösterilmektedir.

3.3.1 Filtrelenmiş Geri İzdüşüm (FGİ) Algoritması

Tomografik görüntü rekonstrüksiyonu elde etmek için çeşitli algoritmalar kullanılmaktadır. Ancak, bir görüntünün X-ışını projeksiyonlarından yeniden yapılandırılması için en yaygın olarak kullanılan algoritma FGİ'dir (Shi at al. 2013). Çünkü, her projeksiyon yalnızca bir kez

dikkate alındığından, FGI hızlı bilgi işlemi sağlamaktadır. $f(x,y)$ ve $p(t,q)$ sırasıyla görüntü dilimi ve izdüşüm seti olarak kabul edilirse, görüntü rekonstrüksiyonu $f(x,y)$, $p(t, \theta)$ 'den tahmin edilebilmektedir. Tek bir izdüşüm işlenirse, bu izdüşümdeki Merkezi Dilim Teoremi aracılığıyla bu nesnenin iki boyutlu Fourier dönüşümü elde edilir. Bu teoreme göre, iki boyutlu bir $f(x,y)$ fonksiyonunun izdüşümünün tek boyutlu Fourier dönüşümü, aynı fonksiyonun iki boyutlu Fourier dönüşümünün orijininden geçen bir doğruya eşittir. Böylece bu işlemde bu izdüşümün Fourier dönüşüm değerleri için uygun yerler seçilirse ve diğer izdüşümlerin sıfır olduğu varsayılırsa basit bir yeniden yapılandırma yapılabilir. İki boyutlu ters Fourier dönüşümü kullanılarak, nesne işlevi Eşitlik (3.1) ile elde edilir.

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) e^{j2\pi(ux+vy)} du dv, \quad (3.1)$$

Burada u ve v değişkenleri dikdörtgen koordinat sistemini temsil eder. Eşitlik (3.1)'deki dikdörtgen koordinat sistemi kutupsal koordinat sistemi ile değiştirilir ise yeni koordinat sistemi ve diferansiyeller eşitlik (3.2)'deki gibi tanımlanabilir:

$$u = w \cos \theta, v = w \sin \theta, du dv = w dw d\theta, \quad (3.2)$$

Denklem (3.1) ve (3.2) kullanılarak, ters Fourier dönüşümü eşitlik (3.3)'te verilmektedir.

$$\begin{aligned} f(x, y) &= \int_0^{2\pi} \int_0^{\infty} F(w, \theta) e^{j2\pi w(x \cos \theta + y \sin \theta)} w dw d\theta \\ &+ \int_0^{\pi} \int_0^{\infty} F(w, \theta + 180^\circ) e^{j2\pi w[x \cos(\theta+180^\circ) + y \sin(\theta+180^\circ)]} w dw d\theta \end{aligned} \quad (3.3)$$

Daha sonra simetri özelliği olan $F(w, \theta + 180^\circ) = F(-w, \theta)$ ile eşitlik (3.3) basitleştirilerek aşağıda verildiği gibi yazılabilir:

$$f(x, y) = \int_0^{\pi} \left[\int_{-\infty}^{\infty} F(w, \theta) |w| e^{j2\pi w t} dw \right] d\theta \quad (3.4)$$

Burada $t = x \cos \theta + y \sin \theta$ olmak üzere, kolaylık sağlanması için, θ açısında elde edilen izdüşümün Fourier dönüşümü eşitlik (3.5) ile verilebilir:

$$f(x, y) = \int_0^{\pi} \left[\int_{-\infty}^{\infty} S_{\theta} |w| e^{j2\pi w t} dw \right] d\theta, \quad (3.5)$$

Eşitlik (3.5), $|w|$ teriminin filtrenin frekans yanıtını temsil ettiği bir filtreleme işlemini içermektedir. Bu nedenle bu işleme filtrelenmiş izdüşüm denir. Böylece, eşitlik (3.5) güncellenerek şu şekilde yazılabilir:

$$f(x, y) = \int_0^\pi Q_\theta (x \cos \theta + y \sin \theta) d\theta \quad (3.6)$$

Burada,

$$Q_\theta(t) = \int_{-\infty}^{\infty} S_\theta(w) |w| e^{j2\pi wt} dw \quad (3.7)$$

şeklindeir. Eşitlik (3.6) ile ilgili olarak, $f(x,y)$ 'yi tahmin etmek için ayrık formda farklı açıl izdüşümleri,

$$f(x, y) = \frac{\pi}{N} \sum_{i=1}^n Q_{\theta_i} (x \cos \theta_i + y \sin \theta_i) \quad (3.8)$$

şeklinde hesaplanır. Burada; N , izdüşümler ve θ_i , açılarn sayısıdır. Eşitlik (3.1)–(3.8)'de verilen denklemler dikkate alınarak uygulanan FGİ algoritması aşağıdaki şekilde özetlenebilir:

- Bir boyutlu Fourier dönüşümü alınır ve $|w|$ filtresi uygulanır.
- Görüntüden projeksiyonlar elde edilir.
- Ters bir boyutlu Fourier dönüşümü bulunur.
- Geri izdüşüm elde edilir.


Eşitlik (3.1)–(3.8) ve FGİ algoritmasının özeti incelendiğinde, yalnızca bir boyutlu Fourier dönüşümünün kullanıldığı ve dolayısıyla daha az hesaplama ihtiyacı duyulduğu görülebilir.

3.3.2 Shepp-Logan Fantomu

Fantomlar insan vücudundaki anatomik yapıların dikey bir dilimden görüldüğü şekliyle kabaca bir kopyasıdır. Çeşitli cihazların, algoritmaların, vb. performansının test ve simüle edilebilmesi için sentetik fantomlar kullanılabilir. Bu amaçla kullanılan en popüler modellerden olan Shepp- Logan fantomu, değişken yoğunluktaki bölgeleri tanımlamak için farklı elipsler ve daireler içerir (Clackdoyle et al. 2004). Bu tez çalışması kapsamında veri setinde kullanılmış olan torasik model, farklı yoğunluktaki bölgelerin ayırt edilebilmesi için elipsler ve daireler kullanması bakımından Shepp-Logan kafa modeline çok benzemektedir. Oluşturulan sentetik

fantomlar, bu geometrilerin benzerliği nedeniyle analitik bir model olarak ele alınabilir. Başka bir deyişle, oluşturulan modelde çözünürlükte herhangi bir keyfi limit kullanılarak izdüşümler herhangi bir açıdan alınabilir. Belirlenmiş bir çözünürlükle tanımlanan modeller, belirli örnekleme ızgarası ve sınırlı bir alt küme ile sınırlı olacaktır.

Torasik model, göğüs kafesi olmadan akciğerler, kalp ve omurga olmak üzere üç ana anatomik yapıyı temsil etmektedir. Şekil 3.1'de, bu unsurlar açık bir şekilde gösterilmektedir. Benzer işlevsel aktivite bölgelerine (örneğin sağ ve sol akciğer) tam olarak aynı olmasa da benzer yoğunluklar atanmaktadır (URL-1). Fonksiyonel bileşenler çok çeşitli yoğunluklara sahiptir. Bu, yeniden yapılandırma algoritmasının çözünürlüğünü ve aralığını test etmek için uygulanmıştır. Şekil 3.1'de üretilen sentetik fantom görüntülerinden bir tanesi fantom yapısının anlaşılabilmesi açısından örnek olarak verilmektedir.



Şekil 3.1 Oluşturulan göğüs boşluğu fantomu örneği.



BÖLÜM 4

EVRIŞİMLİ SİNİR AĞLARI VE SINIFLANDIRMA ALGORİTMALARI

4.1 DERİN ÖĞRENME


Derin öğrenme, beynin yapısından esinlenerek ortaya atılmış, makine öğrenme alanının bir alt dalıdır. Bir başka ifade ile derin öğrenme, insanların doğal olarak yaptıkları herşeyi bilgisayarlar ile yaptırmayı amaçlayan bir yaklaşımdır (Klompensburg et al. 2020). Geleneksel yaklaşımlardan farklı bir tekniği olan bu yöntem, çok farklı alanlarda kullanılmaktadır. Otonom araçların sıfır hata ile kullanımı, uydulardan gelen örüntülerden anlamlı bilgilerin tespit edilmesi ve haritalama işlemlerinde kullanımı, kanser hücrelerinin otomatik olarak tespit edilmesi, insanların veya nesnelerin güvenli olmayan bir makine mesafesinde olduğunun otomatik olarak algılanması ve işçi güvenliği uygulamaları, vb. gibi farklı birçok alanda kullanımı mevcuttur. Derin öğrenme algoritmalarından en çok kullanılanı evrişimli sinir ağıdır. Bölüm 4.1.1'de evrişimli sinir ağları detaylı bir şekilde ele alınmıştır.

4.1.1 Evrişimli Sinir Ağı

Makine öğrenmesi kapsamında kullanılan bir çok yöntem ve teknik bulunmaktadır. Geleneksel makine öğrenmesi yaklaşımları, artan veri boyutları karşısında zayıf kalmaktadır. Yani, veri miktarının artması, yeni yaklaşımların ortaya çıkmasına neden olmuştur. Derin öğrenme de bu yaklaşımlardan en yenileri arasındadır. Derin öğrenme denilince genellikle akla ilk evrişimli sinir ağları (ESA) gelmektedir. ESA modelleri doğrudan ham verilerle son derecede yüksek performansta çalışmaktadır. Özellikle Tesla veya Google gibi büyük teknoloji firmalarının bu yaklaşımı yaygın olarak kullandığı bilinmektedir.

Temel yapay sinir ağlarından farklı olarak uçtan uça bir yöntem uygulayan ESA hem öznetelik çıkarımını hem sınıflandırma aşamasını içerisinde barındırmaktadır (Lizuka et al. 2016). Temel bir ESA mimarisinde Şekil 4.1'de gösterilen katmanlar bulunmaktadır. Geleneksel ESA


mimarisi girdi, evriřim, havuzlama, tam baęlařımlı katman ve çıktı katmanından oluřmaktadır (Afshar at al. 2019). Bu katmanlara ek olarak, normalizasyon katmanları, dropout katmanları gibi katmanlar da kullanılmaktadır. Literatürde, evriřim, havuzlama gibi katmanların farklı diziliřleriyle oluřturulmuř çok fazla sayıda ESA mimarisi bulunmaktadır(URL-2 2021). Bunların bařlıcaları AlexNet, ResNet, Inception, VGG gibi modellerdir.



Şekil 4.1 ESA mimarisini oluřturan temel katmanlar.

4.1.1.1 Evriřim Katmanı

Evriřimsel Katman, bir ESA'nın adını aldıęı olmazsa olmaz katmanıdır. Bu katman, bir girdi görüntüsünü alır ve belirlenen boyutlardaki filtreler yardımıyla görüntü üzerinde bir dizi evriřim (konvolüsyon) iřlemi gerekleřtirir(Türkoęlu vd. 2021). Bařka bir deyiřle, evriřim katmanı bir görüntü tensörünü girdi olarak alır, görüntü tensörüne belirli sayıda evriřimsel filtre (ekirdek) uygular (Şekil 4.2). Elde edilen bu ıktılar aktivasyon fonksiyonlarından geirilerek nihai sonu üretilir.



Şekil 4.2 Evriřim iřleminin gsterimi.

Şekil 4.2’de açıkça görülmektedir ki, giriş görüntüsü 3x3’lük belirlenen filtre üzerinden geçirilmiş ve çıkış görüntüsü oluşturulmuştur. Burada asıl işi belirlenen filtre işlemleri yapmaktadır. Evrişimli katmanda birden çok evrişimli filtre de kullanılmaktadır.


Mimaride kullanılan her bir evrişimsel katmanın amacı, bir örüntüden çok farklı desenler ve bilgiler çıkarmaktır. Modelin başında kullanılan evrişimsel filtreler/çekirdekler, renk, gradyan oryantasyonu vb. gibi düşük seviyeli özellikleri yakalarken, modelin daha derinlerindeki evrişimsel filtreler/çekirdekler, kenarlar gibi yüksek seviyeli özellikleri tespit etmekten sorumludur. Böylece filtrelemeden elde edilen değerler ile özellik haritası oluşturulur. Genel bir evrişim katmanı çıktısı eşitlik (4.1)’de verilmektedir,

$$x_j^1 = f \left(\sum_{a=1}^N w_j^{j-1} * y_a^{k-1} + b_j^k \right) \quad (4.1)$$

burada x_j^1 , 1. katmandaki j. öznitelik haritasını; w_j^{j-1} , (j-1). katmandaki j. kernel fonksiyonunu; y_a^{k-1} , (k-1). katmandaki a. öznitelik haritasını; b_j^k k. katmandaki j. katmandaki bias değerini, N değeri, (k-1). katmandaki toplam öznitel sayısını ve (*) notasyonu ise vektör konvolüsyon işlemini göstermektedir.

4.1.1.2 Havuzlama Katmanı

ESA yapısını oluşturan diğer önemli katman ise havuzlama katmanıdır. Havuzlama katmanının asıl amacı, örüntü boyutlarının azaltılması ve aşırı öğrenme probleminin önüne geçilmesidir. Böylece model içerisinde de hesaplama yükü hafifletilmiş olmaktadır. Bu katmanda belirlenen boyuttaki filtreler ile örüntü üzerinde maksimum, minimum veya ortalama değerleri elde edilerek, yeni bir örüntü oluşturulmaktadır (Türkoğlu vd. 2021). Fakat, bilgi kaybının yaşanması dezavantajları arasındadır. Ayrıca, yalnızca tamamen bağlı katmandan önce kullanılan ve verileri tek bir boyuta indirgeyen küresel bir ortalama havuzlama katmanı vardır. Global ortalama havuzlama katmanından sonra tam bağlı katmana bağlanır. Kullanılan diğer ara katman ise bırakma katmanıdır. Şekil 4.3’te 4x4 boyutundaki bir örüntüye 2x2 boyutunda bir filtreleme yapılarak maksimum, minimum ve ortalama değerlerinin üretildiği bir örnek gösterilmiştir.



Şekil 4.3 Havuzlama işleminin gösterimi.

4.1.1.3 Tam Bağlısımlı Katman/lar

Tam bağılısımlı katman, düzleştirilmiş bir örüntü vektörünü (1-D görüntü tensörü) girdi olarak almaktan ve eğitim veri kümesindeki her etiket için bir olasılık puanı bulmaktan sorumludur.

İlk iki katman (evrişim ve havuzlama) görüntülerden özellik çıkartmaktan sorumlu iken bu katman, eldeki göreve göre görüntüyü sınıflandırmaktan sorumludur. Aktivasyon fonksiyonlarının yoğun bir şekilde kullanıldığı bu katmanda Çizelge 4.1’de sık kullanılan fonksiyonlar verilmiştir (Ramachandran at al. 2017).

Çizelge 4.1 Sık kullanılan aktivasyon fonksiyonları.


Fonksiyon Adı	Matematiksel Gösterimi
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$
ReLU	$f(x) = \max(0, x)$
Leaky ReLU	$f(x) = \begin{cases} mx, & x < 0 \\ x, & x \geq 0 \end{cases}$
Softmax	$f(x) = \frac{e^{z_j}}{\sum_k e^{z_k}}$

4.2 ÖN EĞİTİMLİ ESA MODELLERİ

Veri sayılarının çok fazla olduğu ve milyonlarca parametrenin de olduğu düşünülünce, bir ESA modelinin sıfırdan eğitilip kullanılmasının oldukça zaman alıcı bir iş olmasının yanısıra yüksek performanslı ekipmanların kullanımına ihtiyaç olduğu görülmektedir. Bu durum, zaman ve ekipman konusunda çok ciddi problemlere yol açmaktadır. Bu problemin üstesinden gelebilmek için farklı veri setleri üzerinde eğitilen modellerin parametreleri ve ağırlıklarının kullanıldığı ön eğitilmiş modeller kullanılmaktadır. Böylece, çok fazla veriye ihtiyaç duyulmadan yüksek performans gösteren modeller oluşturulabilmektedir.

4.2.1 AlexNet ESA Modeli

AlexNet öğrenilebilir parametrelere sahip sekiz katmana sahiptir (Alruwaili et al. 2019). Model, maksimum havuzlama ve ardından 3 tam bağlantılı katman kombinasyonu ile beş katmandan oluşur ve çıktı katmanı hariç bu katmanların her birinde Relu aktivasyonunu kullanır (Şekil 4.4). Model, 2012'de AlexKrizhevsky ve meslektaşları tarafından tasarlanarak, "Imagenet" adlı büyük ölçekli bir yarışmada çok yüksek bir başarı kazanmıştır (Levine et al. 2018).




Şekil 4.4 AlexNet mimarisi örneği.

4.2.2 ResNet50 ESA Modeli

ResNet50 modeli klasik yaklaşımlardan farklı olarak artık değerlerin (residual value) ve sonraki katmanları besleyen blokların (residual block) modele eklenmesiyle oluşmaktadır (Şekil 4.5).

50 katmandan oluşan ResNet50 mimarisi 2015 ILSVRC (ImageNet Large Scale Visual Recognition Challenge) ve 2015 COCO (Common Objects in Context) yarışmalarında birincilik kazanan bir modeldir (He et al 2016). Evrişim işlemleri içerisinde 1×1 , 3×3 ve 1×1 evrişim aşamaları yer almaktadır (Arora et al. 2020). ResNet50 mimarisi 25,6 milyon parametreden oluşmaktadır.




Şekil 4.5 ResNet50 mimarisi örneği.

4.3 ESA ÜZERİNDEN ÖZNİTELİK ÇIKARIMI

ESA'nın uçtan uça gerçekleştirilen yöntemlerin yanı sıra sadece öznitelik çıkarım işlemlerinde de kullanıldığı görülmektedir. ESA'dan elde edilen öznitelikler geleneksel sınıflandırıcılara uygulanarak hibrit yaklaşımlar geliştirilmektedir.

Öznitelik çıkarma işlemi ESA modelinin istenilen katman ya da katmanlarından elde edilebilir. Bu tez çalışmasında, AlexNet ve ResNet50 modellerinin sınıflandırma aşamasında bulunan ve tam bağlaşımlı katmanlarından (fully connected layers) elde edilen öznitelikler kullanılmıştır. Özniteliklerin çıkarıldıkları tam bağlı katmanlar, AlexNet için “fc8”, ResNet50 için “fc1000” katmanlarıdır(Narin 2021). Örneğin, ResNet50 ESA modeli üzerinden üç farklı katmandan elde edilmiş bir örnek Şekil 4.6’da verilmiştir.



Şekil 4.6 ResNet50 ESA modelinden çıkarılan öznetelik haritaları.


4.4 SINIFLANDIRMA ALGORİTMALARI

Makine öğrenmesinin vazgeçilmez aşamalarından biri de sınıflandırma algoritmalarıdır. İnsanların öğrenme süreçleri bu algoritmalar üzerinden gerçekleştirilmektedir. Gösterilen örnekler üzerinden öğrenme işini yapan bu algoritmalar, daha sonra gelen girdileri tahmin edebilme kabiliyeti sergilemektedirler. Her algoritmanın kendine has bir yaklaşımı mevcuttur. Dolayısıyla elde edilen performans sonuçları da değişiklik göstermektedir. Bölüm 4.4.1 ve 4.4.2'de bu tez çalışmasında kullanılan sınıflandırma algoritmaları hakkında bilgi verilmektedir.

4.4.1 Destek Vektör Makinaları

Destek vektör makinaları (DVM), Vapnik tarafından geliştirilen ve hem sınıflandırma hem de regresyon işlemleri için sıklıkla kullanılan denetimli bir makine öğrenimi algoritmasıdır.


(Vapnik 1999). Veriyi sınıflandırırken sınıfların birbirlerine en yakın olan örneklerini bularak, bu örnekleri iki sınıfa ayıracak olan ayırıcı yüzeye dik uzaklıklarını maksimize etmeyi amaçlar. Ayırıcı yüzeyin veri kümesi üzerindeki başarısı değişmeden birçok farklı kombinasyonu olabilir. DVM sayesinde ayırıcı yüzey her iki sınıfa da aynı mesafede ve maksimum uzaklıkta olur. Bu işlemin gerçekleştirilmesinde, bir fonksiyonun en küçük ve en büyük değerlerini bir kısıda bağlı olarak bulan Lagrange yöntemi kullanılabilir. Bu tez çalışmasında, DVM algoritmasının lineer, quadratic ve cubic kernel fonksiyonları kullanılarak sonuçlar elde edilmiştir. Şekil 4.1'de bu işlem şekil üzerinde gösterilmektedir.



Şekil 4.7 DVM algoritma gösterimi.

4.4.2 K-En Yakın Komşu Algoritması

K-en yakın komşuluk (kNN), eğitici ve örnek tabanlı bir sınıflandırma algoritmasıdır. kNN sınıflandırıcı algoritmasında eğitim aşaması, eğitim kümesinin ayrılması ile gerçekleşmektedir (Tan 2006). Ayrıca bir eğitim aşaması yoktur. Bu sebeple eğitim aşamasına ayrıca bir zaman ayrılmamaktadır. Bu algorithmada sınıflandırma, belirlenen k değerine hangi komşusu daha yakın ise veriler o sınıfa ait olacak şekilde yapılmaktadır. K değeri için genellikle tek sayılar tercih edilmektedir. Çünkü çift sayılarda aynı çıkan uzaklıklarda algoritmanın kararsız kalmaması sağlanır. Uzaklık ölçütü olarak Euclidean ölçütü kullanılmaktadır. Şekil 4.8'de kNN algoritmasının gösterimi verilmiştir.



Şekil 4.8 kNN algoritması gösterimi.



BÖLÜM 5

KULLANILAN VERİ SETLERİ VE PERFORMANS ÖLÇÜTLERİ


5.1 VERİ SETLERİ

Bu tez çalışmasında, X-ışını ve BT göğüs görüntülerinden oluşan veri setlerinin yanı sıra benzetim ile elde edilen sentetik göğüs fantomu görüntülerinden oluşan veri seti kullanılmıştır.

5.1.1 X-Işını (X-Ray) Veri Seti

X-ışını görüntülerinden oluşan veri seti, halka açık Kaggle web sitesinden elde edilmiştir (URL-3 2021). Veri seti içinde 219 adet COVID-19, 1341 adet normal ve 1345 adet zatürre hastalarına ait X-ışını göğüs görüntüleri yer almaktadır. Örnek görüntüler Şekil 5.1'de gösterilmiştir. Orjinal görüntüler 1024x1024 boyutundadır.

Kullanılan veri setindeki COVID-19 hastalarına ait verilerin az olması sebebiyle veri seti dengesizliğinin ortaya çıkmaması için diğer sınıflardaki verilerden geliş güzel bir şekilde yakın sayıdaki değerler seçilmiştir. Bu tez çalışmasında kullanılan X-ışını verilerinin sınıf bilgileri ve sayıları Çizelge 5.1'de verilmiştir.




Şekil 5.1 Normal, COVID-19 ve zatürre X-ışını veri örnekleri.

Çizelge 5.1 Veri seti sınıf bilgisi ve sayıları.

Sınıf	Veri Sayısı
COVID-19	219
Normal	220
Zatürre	220

5.1.2 Bilgisayarlı Tomografi (BT) Veri Seti

Şekil 5.2’de örnek olarak verilen veri seti, iyi huylu (benign), kötü huylu (malignant) ve normal olmak üzere üç farklı sınıfa ait BT göğüs görüntüsü verilerinden oluşmaktadır. Veri seti, 110 kişiden (15 iyi huylu, 40 kötü huylu, 55 normal) alınmış BT tarama dilimlerini temsil eden toplam 1097 görüntü içermektedir. Veriler, Irak-Onkoloji eğitim hastanesi/ulusal kanser hastalıkları merkezi (IQ-OTH/NCCD) akciğer kanseri veri setidir. Halka açık olan bu veri seti Mendeley Data sayfasında URL-4 (2021) ve Kaggle sayfasında URL-5 (2021) bulunmaktadır.




Şekil 5.2 İyi huylu, kötü huylu ve normal BT veri örnekleri.

5.1.3 Fantom Veri Seti

Sentetik olarak üretilen akciğer fantomu, insan vücudundaki anatomik yapıların dikey bir dilimden görüldüğü şekliyle elde edilmiştir. En popüler modellerden biri olan Shepp ve Logan kafa fantomunun göğüs fantomu olarak inşa edilmesi ile veri seti oluşturulmuştur. Normal sentetik göğüs fantomu ve tümörlü sentetik göğüs fantomu olmak üzere iki farklı sınıfa ait

görüntülerden oluşan veri seti oluşturulmuştur. Her bir sınıfa ait 250 adet veri üretilmiştir. Şekil 5.3'de üretilen farklı sınıflara ait örnek görüntüler verilmektedir. Her bir görüntü 250x250 boyutundadır.



Şekil 5.3 Normal ve tümörlü sentetik göğüs fantom görüntü örnekleri.

5.2 PERFORMANS ÖLÇÜTLERİ

Gerçekleştirilen modellerin veriler üzerindeki performanslarının ölçülmesi model eğitimlerinin ne kadar iyi yapıldığının bir göstergesidir. Dolayısıyla her bir modelin farklı eğitim ve test sonuçları olmaktadır. Böylece probleme özgü algoritmaların tespiti de yapılmaktadır. Bu sebeple, objektif ölçütler ile bu başarımlar tespit edilmelidir. Bu tez çalışmasında, genel olarak genel doğruluk (Acc) kullanılmıştır. Buna ek olarak, hatırlama (recall), kesinlik (precision) ve F1-ölçütü (F1-score) kıstaslarından yararlanılmıştır. Bu ölçütler matematiksel olarak eşitlik (5.1)-(5.4)'te verilmektedir.

$$\text{Genel Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.1)$$

$$\text{Hatırlama} = \frac{TP}{TP + FN} \quad (5.2)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (5.3)$$

$$F1 - \text{ölçütü} = \frac{2 \times \text{Hatırlama} \times \text{Kesinlik}}{\text{Hatırlama} + \text{Kesinlik}} \quad (5.4)$$

Burada, genel doğruluk değeri, modelin genel başarımını gösterir. Hatırlama ölçütü, pozitif örneklerin performanslarının tespitinde kullanılan bir ölçüttür. Kesinlik ise, modelin pozitif olarak ele aldığı örneklerin gerçekte pozitif olma olasılığını göstermektedir. F1 ölçütü, hatırlama ve kesinlik değerlerinin harmonik ortalamasıdır.

Eşitlik (5.1)-(5.3)'te yer alan TP, TN, FP ve FN değerleri, doğru olarak tespit edilen pozitif sayısını, doğru olarak tespit edilen negatif sayısını, gerçekte negatif olup yanlışlıkla pozitif olarak tespit edilenlerin sayısını, gerçekte pozitif olup yanlışlıkla negatif olarak tespit edilenlerin sayısını ifade etmektedir (Sokolava at al. 2006).

Kullanılan 3 farklı veri seti için eğitim ve test verileri %70 ve %30 olarak ayrılmıştır.




BÖLÜM 6

SONUÇLAR

Bu tez çalışması kapsamında elde edilen tüm sonuçlar, Intel(R) Core(TM) i7-3632QM CPU @ 2.20GHz işlemciye sahip bir bilgisayar kullanılarak, MATLAB 2020A programı yardımıyla bulunmuştur.

6.1 X-IŞINI GÖRÜNTÜLERİ İLE COVID-19 HASTALARININ TESPİT PERFORMANSLARI


X-ışını görüntüleri üzerinden elde edilen sonuçlar bu bölümde ele alınmıştır. Burada üç farklı sınıfa ait (COVID-19, Normal ve Zatürre) X-ışını görüntüleri kullanılmıştır. Bu tez çalışması kapsamında ele alınan diğer veri setlerinden elde edilecek model başarımındaki etkisinin de incelenmesi amacıyla, ele alınan X-ışını görüntülerinde Canny, Roberts ve Sobel algoritmaları olmak üzere üç farklı kenar bulma algoritması kullanılmıştır. Canny algoritması ile kenarların Gauss gürültüsü eklenmiş adım kenarlardan oluştuğu varsayılmakta olup komşularına bakılarak pikselin kenar üzerinde olup olmadığına karar verilmektedir. Görüntü üzerinde basit, hesaplaması hızlı, 2 boyutlu uzamsal gradyan ölçümü gerçekleştiren Robert algoritmasında ise uygulanan görüntüdeki her noktadaki piksel değerleri, o noktadaki giriş görüntüsünün gradyan uzamsal değerinin tahmini mutlak büyüklüğünü temsil etmektedir. Sobel algoritması da tipik olarak gri tonlamalı giriş görüntüsünün her bir noktasındaki yaklaşık mutlak gradyan büyüklüğü bir çift 3x3 evrişim maskesi kullanılarak, biri x- yönündeki gradyan tahmini ve diğeri y-yönünde gradyan tahmini yapılmaktadır. İncelenen akciğer bölgesinin belirtilen kenar bulma algoritmaları kullanılarak elde edilen görüntülerdeki model başarımları, orijinal görüntüler kullanılarak elde edilen başarımla karşılaştırılmıştır. Ayrıca, ele alınan kenar bulma algoritmalarının da sınıflandırma başarımına etkisi incelenmiştir. X-ışını veri setine oluşturulan ResNet50 ESA modeli uygulanmıştır. Bu aşamada uygulanan akış diyagramı Şekil 6.1’de detaylı bir şekilde sunulmuştur (Narin ve Onur 2021).



Şekil 6.1 X-ışını görüntülerinden elde edilen COVID-19 tespiti akış diyagramı.


Burada, X-ışını görüntülerinin kullanımı ile ResNet50 ESA modelinin tam bağlaşımlı katmanı olan “fc1000” den elde edilen öznitelik haritaları kullanılmıştır.

Kullanılan üç farklı kenar bulma algoritması ile elde edilen görüntü örnekleri Şekil 6.2’de gösterilmiştir.



Şekil 6.2 Orijinal X-ışını ve üç farklı kenar bulma algoritması ile elde edilen örnek görüntüler.

ESA modellerinden sıklıkla kullanılan ResNet50 mimari ile ele alınan tüm görüntüler üzerinden öznitelik haritaları çıkarılmıştır. Çıkarılan bu öznitelik haritalarının sınıflandırma performansları k-en yakın komşu algoritması ile karşılaştırılmıştır. Dört farklı yaklaşıma ait oluşturulan veri setleri üzerinden elde edilen hata matrisleri Şekil 6.3’de verilmiştir.



Şekil 6.3 Dört farklı X-ışını görüntüleri ile elde edilen başarımlar a) Orjinal b) Canny c) Roberts d) Sobel.

Şekil 6.3'te açıkça görülmektedir ki, orjinal X-ışını görüntüleri üzerinden alınan sonuçlar, diğer görüntülere göre çok daha yüksek performans göstermektedir. Tüm veri setinin %70'i eğitim %30'u test için kullanıldığında, 66 adet orjinal COVID-19 görüntüsünün tamamı doğru bir şekilde tespit edilmiştir. Kenar bulma algoritmalarından Sobel'in, diğer kenar bulma algoritmalarına göre kayda değer bir şekilde yüksek sonuç verdiği görülmektedir. Fakat orjinal görüntülerden düşük performans sergilemektedir. Ayrıca, Canny ve Roberts kenar bulma yaklaşımlarının yaklaşık olarak benzer sonuçlar verdiği görülmektedir. Çizelge 6.1'de tüm görüntülerden elde edilen genel doğruluk değerleri verilmiştir.


Çizelge 6.1 Genel doğruluk değeri sonuçları.

Yöntem	Genel Doğruluk (%)
Orjinal	94,44
Canny	74,75
Roberts	75,76
Sobel	82,30

Çizelge 6.1’de verilen sonuçlar değerlendirildiğinde, orjinal görüntüler üzerinden elde edilen genel doğruluk değerinin diğer yaklaşımlardan elde edilen performanslara göre yüksek olduğu görülmektedir. Buradaki tüm sınıfların genel başarımlarını gösterdiği için gerek COVID-19, gerekse diğer sınıfların doğru tespitinde orjinal görüntülerin başarımlarının %94,44 olduğu görülmektedir. Elde edilen sonuçlarda, kenar belirleme ön işlemesi uygulanarak incelenmek istenilen akciğer bölgesinin sınırlarının ön plana çıkarılmasıyla, görüntüde veri kaybı meydana geldiği için sınıflandırma performanslarının düştüğü gözlenmektedir. Bu nedenle, bu tez çalışması kapsamında ele alınan diğer veri setlerinde bulunan görüntülere herhangi bir kenar belirleme ön işlemesi uygulanmamış, ele alınan orjinal görüntüler bütünü ile incelenmiştir.


6.2 BT GÖRÜNTÜLERİ İLE AKCİĞER KANSERİ HASTALARININ TESPİT PERFORMANSLARI

Tez çalışmasının bu kısmında, Şekil 6.4’te gösterildiği gibi BT görüntüleri üzerinden önceden eğitilmiş ESA modelleri kullanılarak, akciğer kanserinin otomatik olarak saptanması gerçekleştirilmiştir (Narin ve Onur 2021). Bu amaçla, sık bir mimariye sahip AlexNet ile daha derin bir mimariye sahip ResNet50’nin performansları karşılaştırılmıştır ve DVM algoritmasının kullanıldığı hibrit bir sistem tasarlanmıştır.



Şekil 6.4 Derin öğrenme mimarileri ile akciğer kanseri tespiti şematik gösterimi.

ESA mimarilerinden olan AlexNet ve ResNet50 kullanılarak çıkarılan öz niteliklerin performansları DVM algoritması yardımıyla belirlenmiştir. Ayrıca derin öğrenme yaklaşımlarının performansını önemli ölçüde değiştiren ağ parametreleri olan epoch (dönem) ve batch (parti) büyüklüğünün etkileri analiz edilerek akciğer kanseri tespitindeki rolleri irdelenmiştir. Burada, eğitim için veri setinin %70'i ve test için %30'u kullanılarak sonuçlar elde edilmiştir. AlexNet mimarisi için elde edilen üç farklı parti büyüklüğünün beş farklı dönem numarasına göre doğruluk değerleri Şekil 6.5'te verilmiştir.




Şekil 6.5 AlexNet için ESA modelinin üç farklı parti büyüklüğünün performansları.

Dönem sayısındaki artışın AlexNet için genel performans değerlerinde aşağı yönlü bir eğilime neden olduğu Şekil 6.5'ten kolaylıkla görülebilir. En yüksek doğruluk değeri, parti büyüklüğü 64 ve dönem sayısı 200 olduğunda elde edilir. En yüksek doğruluk değerinin elde edildiği bu parametre değerleri için diğer performans kriterleri olan hatırlatma, kesinlik ve F1-ölçütü değerleri Çizelge 6.2'de verilmiştir.

Çizelge 6.2 AlexNet için parti boyut 64 ve devir 200 iken performans ölçütleri.

Sınıflar	TP	TN	FP	FN	Doğruluk (%)	Hatırlatma (%)	Kesinlik (%)	F1-Ölçütü (%)
İyi Huylu	32	291	2	4	98,18	88,89	94,12	91,43
Kötü Huylu	168	160	1	0	99,70	100	99,41	99,70
Normal	122	200	4	3	97,87	97,60	96,83	97,21
Ortalama					98,58	95,50	96,78	96,14

Çizelge 6.2'den açıkça görülebileceği gibi, kötü huylu akciğer kanserli kişilerin genel doğruluğu %99,70'dir ve kötü huylu sınıfa ait görüntüler %100 hatırlatma değeri ile tespit edilmiştir. Tez çalışmasının bu bölümünde kullanılan diğer bir ESA modeli olan ResNet50 mimarisi için elde edilen üç farklı parti büyüklüğünün (batch büyüklüğü) beş farklı epoch (dönem) numarasına göre doğruluk değerleri ise Şekil 6.6'da detaylı olarak gösterilmiştir.



Şekil 6.6 ResNet50 ESA modeli için üç farklı parti büyüklüğünün performansları.

Şekil 6.6’da yüksek parti boyutunda, devir sayısının artışı genel doğruluk değerinde düşüşe sebep olmaktadır. ResNet50 mimarisi için parti boyutu 64 ve devir sayısı 200 iken en yüksek genel doğruluk değeri 97,97 olarak elde edilmektedir. ResNet50 mimarisi üzerinden elde edilen en yüksek genel doğruluk değeri için sınıfların tespit başarımları Çizelge 6.3’te verilmiştir.

Çizelge 6.3 ResNet50 için parti boyutu 64 ve devir 200 iken performans ölçütleri.

Sınıflar	TP	TN	FP	FN	Doğruluk (%)	Hatırlatma (%)	Kesinlik (%)	F1-Ölçütü (%)
İyi Huylu	30	291	2	6	97,57	83,33	93,75	88,24
Kötü Huylu	167	160	1	1	99,39	99,40	99,40	99,40
Normal	122	197	7	3	96,96	97,60	94,57	96,06
Ortalama					97,97	93,45	95,91	94,66

Çizelge 6.3'te elde edilen sonuçlar değerlendirildiğinde, kötü huylu sınıfa ait görüntülerin tespitinde %99,39 genel doğruluk sonucu elde edilmiştir. %99,40 oranında ise kötü huylu sınıfa ait görüntülerin tespiti mümkün olabilmektedir.

Sonuç olarak, AlexNet'in ResNet50'ye göre daha yüksek performans sergilediği görülmektedir. Parti boyutu ve devir sayısının akciğer kanser türlerini tespit performanslarına ciddi etki ettiği görülmektedir

Elde edilen sonuçlar, literatürde aynı veri setini kullanılarak derin öğrenmeye dayalı çalışmalar ile karşılaştırılmıştır (Çizelge 6.4). Al-Yasriy ve arkadaşlarının göğüs tomografi görüntülerinde AlexNet mimarisini kullanan evrişimli sinir ağı kullanılarak akciğer kanserini tespit etmek için normal, iyi huylu veya kötü huylu görüntülerinden akciğer kanseri teşhisine yardımcı olmak için bir CAD önermişlerdir. Önerilen model ile %93.55 yüksek doğruluk oranı elde etmişlerdir (2020). Başka bir çalışmada ise Hamdalla ve arkadaşları aynı veri setinde akciğer kanserini tespit etmek için üç ön işleme aşamasını içeren görüntü iyileştirme, görüntü bölütleme ve özellik çıkarma metotlarını uygulamışlar normal, iyi huylu veya kötü huylu olmak üzere üç sınıftan akciğer kanseri teşhisi için sınıflandırma tekniği olarak destek vektör makinesi (DVM) kullanmışlardır ve elde edilen en yüksek doğruluk %89.89'dur (2021). Prarthana ve arkadaşlarının yapmış oldukları kapsamlı çalışmada ise önceki çalışmalara göre daha fazla sayıda görüntü ile malign, normal ve iyi huylu akciğer nodüllerini sınıflandırmayı ve son olarak elde edilen tüm sonuçları karşılaştırmak için Evrişim Sinir Ağı (ESA) ve Yapay Sinir Ağını (YSA) Jupyter Notebook kullanılarak eğitmişlerdir (2021). Tüm bu algoritmalarından CNN, %98 en yüksek doğruluk ve YSA ise %71 en yüksek doğruluk değerini elde ettiklerini bildirmişlerdir.

Çizelge 6.4 Aynı veri setini kullanan çalışmalar ile karşılaştırma.


Çalışma	Doğruluk (%)
Al-Yasriy et al. (2020)	93,55
Hamdalla et al. (2021)	89,89
Prarthana and Bhavani (2021)	98,00
Bu çalışma	98,58

Tez çalışmasının bu bölümünde oluşturulan AlexNet ve ResNet50 ESA modelleri ile literatürdeki birçok çalışmaya göre daha yüksek bir genel doğruluk değeri elde edilmiştir. Ayrıca, sınıflandırma işlemi DVM algoritması ile gerçekleştirilmiş ve en yüksek doğruluk değeri 98,58 olarak AlexNet ile elde edilmiştir. Bunun yanı sıra, derin öğrenme yaklaşımlarının performansını önemli ölçüde değiştiren ağ parametreleri olan epoch ve batch büyüklüğünün etkileri incelenerek, en yüksek performansı sağlayan model parametreleri belirlenmiştir.

6.3 BENZETİM FANTOMU İLE ELDE TÜMÖRLÜ GÖRÜNTÜLERİN TESPİT PERFORMANSLARI


Bölüm 6.1 ve 6.2'de ele alınan X-ışını ve BT görüntüleri elde edilirken maruz kalınan yüksek radyasyon etkileri hastalarda ciddi kaygılara sebep olmaktadır. Ayrıca, canlı dokular kullanılarak bir takım test işlemlerinin yapılması etik işlemler gerektirmektedir. Bu sebeple, herhangi bir medikal cihazın, algoritmanın, vb. geliştirilmesi; cihaz kalibrasyonlarının yapılması vb. aşamalarda insan gereksinimini ortadan kaldırmak amacıyla doku benzeri yapılar olan fantomlar sıklıkla kullanılmaktadır. Bu amaçla, deneysel olarak üretilen fantomların yanı sıra yazılım tabanlı üretilen sentetik fantomlar da yaygın olarak kullanılmaktadır. Tez çalışmasının bu bölümünde, sırasıyla Bölüm 3.3.1 ve 3.3.2'de verilen FGI algoritması ve Shepp-Logan filtresi kullanılarak oluşturulan sentetik göğüs fantom görüntüleri ile akciğerleri sağlıklı ve tümörlü olan hastaların derin öğrenme tabanlı otomatik tespiti yapılmıştır. Oluşturulan modelde kullanılmak üzere, 250'şer adet 250x250 boyutunda normal ve tümörlü akciğerlere sahip hastalara ait sentetik fantom görüntüleri ile bir veri seti oluşturulmuştur. Fantom görüntüleri oluşturulurken tümör yapıları ve sayıları rastgele bir şekilde yerleştirilmiştir. Oluşturulan veri setinde bulunan birkaç örnek görüntü Şekil 5.3'te verilmiştir.

Çalışmaya ait akış diyagramı Şekil 6.7'de detaylı bir şekilde gösterilmiştir.



Şekil 6.7 Sentetik fantom görüntüleriyle gerçekleştirilen sınıflandırma akış şeması.

Şekil 6.7’de fantom görüntüleriyle oluşturulan veri setleri kullanılarak AlexNet ve ResNet50 ESA modeller üzerinden öznitelikler çıkarılmıştır. Çıkarılan bu öznitelikler sınıflandırma aşamasında destek vektör makinaları algoritması ile sınıflandırılıp sonuçlar elde edilmiştir. Şekil 6.8’de elde edilen hata matrisi verilmiştir.



Şekil 6.8 Sentetik fantom görüntülerinin sınıflandırılmasında elde edilen hata matrisi.

Elde edilen sonuçlar ışığında, tümörlü ve normal olan tüm veriler doğru bir şekilde tespit edilmiştir. Elde edilen tüm başarımlar ölçütleri Çizelge 6.5’de sunulmuştur.

Çizelge 6.5 Sentetik fantom görüntülerinin sınıflandırılmasında elde edilen tüm performans sonuçları.

Sınıflar	TP	TN	FP	FN	Doğruluk (%)	Hatırlatma (%)	Kesinlik (%)	F1-Ölçütü (%)
Tümörlü	75	75	0	0	100	100	100	100
Normal	75	75	0	0	100	100	100	100
Ortalama					100	100	100	100

Çizelge 6.5'ten açıkça görölmektedir ki, oluşturulan model sentetik fantomların sınıflandırılması için kullanıldığında %100 başarımlı değeri elde edilmiştir.



BÖLÜM 7

TARTIŞMA VE ÖNERİLER

X-ışını, BT ve sentetik fantom görüntülerinden oluşan veri setleri kullanılarak üç farklı uygulama gerçekleştirilen bu tez çalışmasında, sentetik fantom görüntü performanslarının derin öğrenme tabanlı öznetelikler ile nasıl sonuç verdiği analiz edilmiştir. Bu bağlamda, X-ışını göğüs görüntülerinden çıkarılan özellikler kullanılarak yapılan çalışmada, derin öğrenme tabanlı modeller ile öznetelik çıkarılabileceği ve bu özneteliklerin sınıflandırma için kullanılabileceği tespit edilmiştir. Bu tez çalışması kapsamında gerçekleştirilen ikinci uygulamada, BT görüntüleri kullanılmıştır. ESA mimarilerinden en yaygın olanlarından AlexNet ve ResNet50 modelleri kullanılarak, oluşturulan mimariler ile literatürdeki birçok çalışmaya göre daha yüksek bir genel doğruluk değeri elde edilmiştir. Ayrıca bu bölümde elde edilen sonuçlardan, derin öğrenme yaklaşımlarının performanslarının dönem ve parti büyüklüğü değerlerinden etkilendikleri tespit edilmiştir. Son olarak, ilk iki uygulamadan elde edilen sonuçlar, radyasyon riskinin sıfır olduğu yazılımsal olarak elde edilen sentetik fantom görüntülerine uygulanmış ve çok yüksek başarımlar elde edilmiştir. Oluşturulan sentetik fantom görüntülerinden elde edilen başarımların %100 olduğu ve X-ışını ve BT görüntülerine göre elde edilen başarımdan yüksek olduğu görülmüştür. Ayrıca, tez çalışması kapsamında oluşturulan sentetik fantom görüntüleri çok farklı boyutlarda ve yoğunluklarda olsalar bile, %100'e yakın yüksek başarımların elde edildiği tespit edilmiştir. Bu durum, sentetik fantom görüntülerinin çok kompleks olmaması ve aynı zamanda yüksek başarımların elde edildiği model ve parametreler kullanılarak sınıflandırmanın gerçekleştirilmesi ile açıklanabilir. Gelecek çalışmalarda, farklı algoritmalar kullanılarak daha kompleks ve farklı yapılarda sentetik fantom görüntülerinin oluşturulması ve yüksek başarımlarla sınıflandırılması hedeflenmektedir. Ayrıca, X-ışını ve BT gibi orjinal görüntülerin de daha kompleks modeller oluşturularak, yüksek performansların elde edilebilmesi planlanmaktadır.



KAYNAKLAR

- Afshar P, Mohammadi A, Plataniotis K N, Oikonomou A ve Benali H** (2019) From handcrafted to deep-learning-based cancer radiomics: challenges and opportunities. *IEEE Signal Processing Magazine*, 36(4): 132-160.
- Alruwaili M, Alanazi S, El-Ghany S A and Shehab A** (2019) An efficient deep learning model for olive diseases detection. *International Journal of Advanced Computer Science and Applications*, 10(8): 486-492.
- Arora K, Bist A S, Chaurasia S and Prakash R** (2020) Analysis of deep learning techniques for COVID-19 detection. *Int J Sci Res Eng Manag (ijsrem)*, 4(4): 1-5.
- Al-Yasriy H F, Al-Husieny M S, Mohsen F Y, Khalil E A and Hassan Z S** (2020) Diagnosis of Lung Cancer Based on CT Scans Using CNN. *IOP Conference Series (Thi-Qar, Iraq) Materials Science and Engineering (ISCAU)*, 928(2), 022035.
- Armato S G, Li F, Giger M L, MacMahon H, Sone S and Doi K** (2002) Lung cancer: performance of automated lung nodule detection applied to cancers missed in a CT screening program. *Radiology*, 225(3): 685-692.
- Bellingham G A and Peng P W** (2010) A low-cost ultrasound phantom of the lumbosacral spine. *Regional Anesthesia & Pain Medicine*, 35(3): 290-293.
- Chmarra M K, Hansen R, Mørvik R and Langø T** (2013) Multimodal phantom of liver tissue. *PloS one*, 8(5), e64180.
- Clackdoyle R, Noo F, Guo J and Roberts J A** (2004) Quantitative reconstruction from truncated projections in classical tomography. *IEEE Transactions on Nuclear Science*, 51(5), 2570-2578.
- Demi L, Hoeve W, Sloun R J, Soldati G, and Demi M** (2017) Determination of a potential quantitative measure of the state of the lung using lung ultrasound spectroscopy. *Scientific reports*, 7(1): 1-7.
- Fushiki H, Kanoh-Azuma T, Katoh M, Kawabata K, Jiang J, Tsuchiya N, ... and Hayakawa Y** (2009) Quantification of mouse pulmonary cancer models by microcomputed tomography imaging. *Cancer science*, 100(8): 1544-1549.

KAYNAKLAR (devam ediyor)

- Gupta S H, Goel S, Kumar M, Rajawat A, and Singh B** (2022) Design of terahertz antenna to detect lung cancer and classify its stages using machine learning. *Optik*, 249, 168271.
- Hamdalla F K, Al-Huseiny M S, Mohsen, F Y, Khalil E A, Hassan Z S** (2021) Evaluation of SVM Performance In the Detection of Lung Cancer in Marked CT Scan Dataset. *Indonesian Journal of Electrical Engineering and Computer Science (IAES)*, 21(3), 1731-1738.
- He K, Zhang X, Ren S, and Sun J** (2016) Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778)
- Hall T J, Bilgen M, Insana M F, and Krouskop T A** (1997) Phantom materials for elastography. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 44(6): 1355-1365.
- Hocking G, Hebard S, and Mitchell C H** (2011) A review of the benefits and pitfalls of phantoms in ultrasound-guided regional anesthesia. *Regional Anesthesia & Pain Medicine*, 36(2): 162-170.
- Huber A, Landau J, Ebner L, Bütikofer Y, Leidolt L, Brela B and Christe A** (2016) Performance of ultralow-dose CT with iterative reconstruction in lung cancer screening: limiting radiation exposure to the equivalent of conventional chest X-ray imaging. *European radiology*, 26(10): 3643-3652.
- Hunt A, Ristolainen A, Ross P, Öpik R, Krumme A, and Kruusmaa M** (2013) Low cost anatomically realistic renal biopsy phantoms for interventional radiology trainees. *European journal of radiology*, 82(4): 594-600.
- Kevles B** (1997) *Naked to the bone: Medical imaging in the twentieth century*. Rutgers University Press.
- Klompenburg T V, Kassahun A, and Catal C** (2020) Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture*, 177, 105709.
- Levine S, Pastor P, Krizhevsky A, Ibarz J, and Quillen D** (2018) Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection. *The International Journal of Robotics Research*, 37(4-5): 421-436.
- Lizuka S, Simo-Serra E, and Ishikawa H** (2016) Let there be color! Joint end-to-end learning of global and local image priors for automatic image colorization with simultaneous classification. *ACM Transactions on Graphics (ToG)*, 35(4): 1-11.

KAYNAKLAR (devam ediyor)

- Narin A** (2021) Accurate detection of COVID-19 using deep features based on X-Ray images and feature selection methods. *Computers in Biology and Medicine*, 137, 104771.
- Marchal C, Nadi M, Tosser A J, Roussey C and Gaulard M L** (1989) Dielectric properties of gelatine phantoms used for simulations of biological tissues between 10 and 50 MHz. *International journal of hyperthermia*, 5(6): 725-732.
- Molinari F, Madhuranthakam A J, Lenkinski R and Bankier A A** (2014) Ultrashort echo time MRI of pulmonary water content: assessment in a sponge phantom at 1.5 and 3.0 Tesla. *Diagnostic and Interventional Radiology*, 20(1): 34-40.
- Narin D and Onur T Ö** (2021) Investigation of the Effect of Edge Detection Algorithms in the Detection of Covid-19 Patients with Convolutional Neural Network-Based Features on Chest X-Ray Images. In *2021 29th Signal Processing and Communications Applications Conference (SIU) IEEE*. (pp. 1-4).
- Narin D and Onur T Ö** (baskıda) The Effect of Hyper Parameters on the Classification of Lung Cancer Images Using Deep Learning Methods. *Erzincan Üniversitesi Fen Bilimleri Üniversitesi Dergisi*.
- Onur T** (2016) Katı, Sıvı ve Doku Ortamlarında Darbe-Eko Kestirimi ile Ultrasonik Hedef Belirleme. *Doktora Tezi*, Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Zonguldak, 195 s.
- Onur T** (2021) An application of filtered back projection method for computed tomography images. *International Review of Applied Sciences and Engineering*, 12(2): 194-200.
- Prarthana K R and Bhavani K** (2021) Lung Cancer Classification Techniques. *International Journal of Engineering Science and Computing (IJESC)*, 11(6): 28054-28058.
- Ramachandran P, Zoph B and Le Q V** (2017) Searching for activation functions. *arXiv preprint arXiv:1710.05941*.
- Sites B D, Chan V W, Neal J M, Weller R, Grau T, Koscielniak-Nielsen Z J and Ivani G** (2010) The American Society of Regional Anesthesia and Pain Medicine and the European Society of Regional Anaesthesia and Pain Therapy joint committee recommendations for education and training in ultrasound-guided regional anesthesia. *Regional Anesthesia & Pain Medicine*, 35(1): 74-80.
- Shi H and Luo S** (2013) A novel scheme to design the filter for CT reconstruction using FBP algorithm. *Biomedical engineering online*, 12(1): 1-15.

KAYNAKLAR (devam ediyor)

- Sokolova M, Japkowicz N and Szpakowicz S** (2006) Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation. In *Australasian joint conference on artificial intelligence* (pp. 1015-1021). Springer, Berlin, Heidelberg.
- Tan S** (2006) An effective refinement strategy for KNN text classifier. *Expert Systems with Applications*, 30(2): 290-298.
- Türkoğlu M, Hangay K, Sivrikaya İ ve Hangay D** (2021) Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi* , 9(1): 334-345.
- Vapnik V** (1999) *The nature of statistical learning theory*. Springer science & business media.
- Zamani A, Rezaeieh S A and Abbosh A M** (2015) Lung cancer detection using frequency-domain microwave imaging. *Electronics Letters*, 51(10): 740-741.
- URL-1** (2021) <<https://www.clear.rice.edu/elec631/Projects99/mit/tcp.htm>>, Ziyaret tarihi :20.11.2021.
- URL-2** (2021) <<https://www.theclickreader.com/building-a-convolutional-neural-network/>>, Ziyaret tarihi:13.09.2021.
- URL-3** (2021) <<https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>>, Ziyaret tarihi:21.03.2021.
- URL-4** (2021) <<https://data.mendeley.com/datasets/bhmdr45bh2/1>>,Ziyaret tarihi:05.07.2021.
- URL-5** (2021) <[https://www.kaggle.com/hamdallak/the-iqothnccd-lungcancerdataset/ metadata](https://www.kaggle.com/hamdallak/the-iqothnccd-lungcancerdataset/metadata)>, Ziyaret tarihi:05.07.2021.

ÖZGEÇMİŞ

Derya NARİN İlk ve orta öğrenimini Çorum'da tamamladı. Çorum Cumhuriyet Lisesinden mezun olduktan sonra 2009 yılında Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği bölümüne girdi. 2014 yılında Elektrik-Elektronik Mühendisliği bölümünden mezun oldu. 2019 yılında Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü'nde yüksek lisans eğitimine başladı.

