

T.C.
ISPARTA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

AKCİĞER KANSERİNİN TESPİT EDİLMESİNDE DERİN
ÖĞRENME ALGORİTMALARININ KULLANILMASI

Ayşen Özün TÜRKÇETİN

Danışman
Prof. Dr. Hilmi Cenk BAYRAKÇI

II. Danışman
Dr. Öğr. Üyesi Bekir AKSOY

ISPARTA-2019



© 2019 [Ayşen Özün TÜRKÇETİN]

TEZ ONAYI

AKCİĞER KANSERİNİN TESPİT EDİLMESİNDE DERİN ÖĞRENME ALGORİTMALARININ KULLANILMASI

Ayşen Özün TÜRKÇETİN tarafından hazırlanan bu tez çalışması aşağıdaki jüri tarafından Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü Mekatronik Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

İmza

Başkan	Prof. Dr. Hilmi Cenk BAYRAKÇI Isparta Uygulamalı Bilimler Üniversitesi	
Üye	Dr. Öğr. Üyesi Bekir AKSOY Isparta Uygulamalı Bilimler Üniversitesi	
Üye	Prof. Dr. Tuncay AYDOĞAN Isparta Uygulamalı Bilimler Üniversitesi	
Üye	Dr. Öğr. Üyesi Mevlüt ERSOY Süleyman Demirel Üniversitesi	
Üye	Dr. Öğr. Üyesi Okan ORAL Akdeniz Üniversitesi	

Yukarıdaki Jüri kararı Lisansüstü Eğitim Enstitüsü Yönetim Kurulu'nun / / tarih ve / sayılı kararıyla onaylanmıştır.

Prof. Dr. Yusuf UÇAR
Enstitü Müdürü


ETİK BEYANI

Isparta Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kurallarına uygun olarak ve bilimsel ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın hazırladığım bu tez çalışmasında;

Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, tezime ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

22-12/2019

Ayşen Özün TÜRKÇETİN



İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	i
ÖZET.....	iii
ABSTRACT.....	iv
TEŞEKKÜR.....	v
ŞEKİLLER DİZİNİ.....	vi
ÇİZELGELER DİZİNİ	vii
SİMGELER VE KISALTMALAR DİZİNİ	viii
1. GİRİŞ	1
1.1. Tıpta görüntüleme teknikleri.....	5
1.1.1. Bilgisayarlı tomografi görüntüsü (BT).....	5
1.1.2. Pozitron emisyon tomografi (PET/BT).....	5
1.2. Görüntü işleme	6
1.3. Yapay sinir ağları	7
1.4. Derin öğrenme.....	7
2. KAYNAK ÖZETLERİ	9
3. MATERYAL VE YÖNTEM	15
3.1. Akciğer kanseri PET/BT görüntü veri seti.....	15
3.2. Kullanılan programlama dili	16
3.3. Çalışmada kullanılan kütüphaneler	16
3.3.1. OpenCv	16
3.3.2. Pandas	16
3.3.3. Glob.....	17
3.3.4. Skimage.....	17
3.3.5. Numpy.....	17
3.3.6. SciPy	17
3.3.7. Skdata.....	17
3.3.8. Scikit-Learn.....	18
3.3.9. Matplotlib.....	18
3.3.10. Tensorflow	18
3.3.11. Keras	18
3.4. Kullanılan görüntü işleme yöntemi	19
3.5. Derin öğrenme modelleri	21
3.5.1. Konvolüsyon katmanı	22
3.5.2. Havuz katmanı	23
3.5.3. Düzleştirme katmanı	23
3.5.4. Bırakma katmanı	23
3.5.5. Doğruluk oranı	24
3.5.6. Kayıp oranı.....	24
3.5.7. Performans metriği.....	24
3.6. CNN derin öğrenme modeli	26
3.7. DNN derin öğrenme modeli.....	27
4. BULGULAR VE TARTIŞMA	29
SONUÇ VE ÖNERİLER	37
KAYNAKLAR	38
EKLER.....	44
EK-A Önerilen Dnn modeli katman özeti.....	45
EK-B Önerilen DNN modeli katmanlarının özet tablosu	46



ÖZET

Yüksek Lisans Tezi

AKCİĞER KANSERİNİN TESPİT EDİLMESİNDE DERİN ÖĞRENME ALGORİTMALARININ KULLANILMASI

Ayşen Özün TÜRKÇETİN

Isparta Uygulamalı Bilimler Üniversitesi
Lisansüstü Eğitim Enstitüsü
Mekatronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Hilmi Cenk BAYRAKÇI

II. Danışman: Dr. Öğr. Üyesi Bekir AKSOY

Türkiye’de yılda 163.500 civarında yeni kanser vakası teşhis edilmektedir. Akciğer kanseri, gelişmiş ülkelerin çoğunda olduğu gibi ülkemizde de kanserden dolayı meydana gelen ölümlerinin başını çekmektedir. Dolayısıyla başarılı ve erken teşhis hayati önem taşımaktadır.

Akciğer kanseri BT görüntülerindeki kanserli dokuların tanısında kullanılacak olan derin öğrenme metotları ile, akciğer kanseri teşhisinde derin öğrenme alanında çok az sayıda araştırma vardır. Bu sebepten dolayı yapılan çalışmada PET/BT görüntüleri üzerinden akciğer kanseri tümörlü doku tespiti için bir derin öğrenme modeli önerilmiştir.

Oluşturulan derin öğrenme modellerinde veri seti olarak iyi ve kötü huylu tümör bulunan 38 farklı hastadan 1968 tane BT görüntüsü kullanılmıştır. Yüksek lisans çalışmasında, akciğer kanserinin teşhisi öncesi sınıflandırma için derin öğrenme modelleri kullanılmıştır. Veri seti önce iyi ve kötü huylu tümör bulunma durumlarına göre etiketlenmiştir. Hastalardan alınan BT görüntülerine görüntü işleme metotlarından histogram eşikleme yöntemi uygulanmıştır. Histogram eşikleme metodu uygulanan veriler iyi ve kötü huylu olarak etiketlenmiş, % 80’i eğitim, % 20’si test olacak şekilde ayrılmıştır. Ayrılan bu veri setine önerilen CNN derin öğrenme modeli uygulandığında doğruluk oranı % 98.48 olarak tespit edilmiştir. Oluşturulan veri setinin DNN derin öğrenme modelindeki doğruluk oranı ise % 93.65 olarak tespit edilmiştir. Literatürdeki diğer çalışmalarla karşılaştırıldığında önerilen derin öğrenme modellerinin daha yüksek doğruluk oranına sahip olduğu görülmüştür.

Anahtar Kelimeler: Derin Öğrenme, CNN, DNN, Görüntü İşleme, Akciğer Kanseri Teşhisi, Python

2019, 48 sayfa

ABSTRACT

M.Sc. Thesis

USING DEEP LEARNING ALGORITHMS FOR DETECTION OF LUNG CANCER

Ayşen Özün TÜRKÇETİN

Isparta University of Applied Sciences
The Institute of Graduate Education
Department of Mekatronic Engineering

Supervisor: Prof. Dr. Hilmi Cenk BAYRAKÇI

Co-Supervisor: Asst. Prof. Dr. Bekir AKSOY

Of around 163 500 new cases of cancer are diagnosed annually in Turkey. Lung cancer is the leading cause of cancer deaths in our country as in most developed countries. Therefore, successful and early diagnosis is vital.

There are very few studies in the field of deep learning in the diagnosis of lung cancer, with the use of deep learning methods for the diagnosis of cancerous tissues on lung cancer CT images. For this reason, in the study, a deep learning model for lung cancer tumor tissue detection via PET / CT images was proposed.

1968 CT images of 38 different patients with benign and malignant tumors were used as the data set in the deep learning models. In the graduate study, deep learning models were used for classification before the diagnosis of lung cancer. The data set was first labeled according to the presence of benign and malignant tumors. Histogram thresholding method was applied to the CT images obtained from the patients. The histogram thresholding data were labeled as benign and malignant, 80% of which was divided into training and 20% of which were tested. When the proposed CNN deep learning model was applied to this separated data set, the accuracy rate was 98.48%. The accuracy of the data set in the DNN deep learning model was 93.65%. Compared to other studies in the literature, the proposed deep learning models have higher accuracy.

Key words: Deep Learning, CNN, DNN, Image Processing, Lung Cancer Detection, Python

2019, 48 pages

TEŐEKKÜR

Bu arařtırma için beni yönlendiren, karşılařtıđım zorlukları bilgi ve tecrübesi ile ařmamda yardımcı olan deđerli Danıřman Hocalarım Prof. Dr. Hilmi Cenk BAYRAKÇI ve Dr. Öğr. Üyesi Bekir AKSOY'a, tez çalıřmam da gerekli olan kanser veri setini oluřturmamda öncülük eden Tıp Fakóltesi Nükleer Tıp Anabilim Dalı Başkanı Prof. Dr. Sevim Süreyya ŐENGÜL'e, kanser verilerine erişimde yardımcı olan Teknisyen Ali ÖZDAMAR'a, tez konumu bulmamda bana yardımını esirgemeyen Öğr. Gör. Dr. Mehmet Erhan Őahin'e, tez ařamasındaki zorluklarda beni yalnız bırakmayan Prof. Dr. Ecir Uđur KÜÇÜKSİLLE'e, teknik çizimlerde yardımcı olan Yunus KAYA'ya, tezi düzenleme ařamasında bana yardımlarını esirgemeyen İbrahim ÇELİK'e teőekkürlerimi sunarım.

Tezimin her ařamasında beni yalnız bırakmayan aileme ve gönül dostlarıma sonsuz sevgi ve saygılarımı sunarım.

Kanser hastalıđından vefat eden Anneannem ve tüm kanser hastalarına...

Ayřen Özün Türkçetin
ISPARTA, 2019

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Şekil Yapay zekâ ve bilgisayarlar	1
Şekil 1.2. Yapay zekâ venn diyagramı	2
Şekil 1.3. Erkeklerde en sık görülen bazı kanserlerin % dağılımları	3
Şekil 1.4. Kadınlarda en sık görülen 10 kanserin yaşa göre dağılımı	3
Şekil 1.5. Bilgisayarlı tomografi görüntüsü (BT)	5
Şekil 1.6. Pozitron emisyon tomografi (PET/BT).....	6
Şekil 1.7. Görüntü işleme adımları	6
Şekil 1.8. Yapay sinir ağı mimarisi	7
Şekil 1.9. Derin öğrenme mimarisi	8
Şekil 3.1. İş akış diyagramı	15
Şekil 3.2. Önerilen modelin iş akış diyagramı	19
Şekil 3.3. İşlenmemiş orjinal görüntü	20
Şekil 3.4. OpenCv ile histogram eşikleme öncesi ve sonrası görüntü	21
Şekil 3.5. Görüntüleri ölçekleme	22
Şekil 3.6. Evrişim işleminin gösterimi	22
Şekil 3.7. Maksimum havuzlama	23
Şekil 3.8. Düzleştirme (Flatten)	23
Şekil 3.9. Standart sinir ağı ve bırakma sonrası sinir ağı	24
Şekil 3.10. ROC eğrisi	26
Şekil 3.11. Önerilen CNN mimarisi	26
Şekil 3.12. DNN derin öğrenme mimarisi	28
Şekil 3.13. DNN'deki CNN katmanı	28
Şekil 4.1. Keras ile oluşturulan CNN modeli.....	30
Şekil 4.2. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan DNN modelinin katmanlarının bağlanma şekli	31
Şekil 4.3. CNN modeli doğruluk oranı	33
Şekil 4.4. CNN modeli kayıp oranı	33
Şekil 4.5. Önerilen DNN model için doğruluk oranı	34
Şekil 4.6. Önerilen DNN model için kayıp oranı	35

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 1.1. Erkeklerde en sık görülen ilk beş kanser türünün dağılımı.....	3
Çizelge 3.1. Karmaşıklık matrisi.....	25
Çizelge 4.1. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan CNN model özeti.....	30
Çizelge 4.2. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan DNN model özeti	32
Çizelge 4.3. Uygulanan derin öğrenme modelleri	32
Çizelge 4.4. Literatürdeki diğer çalışmalar ile karşılaştırma tablosu.....	36



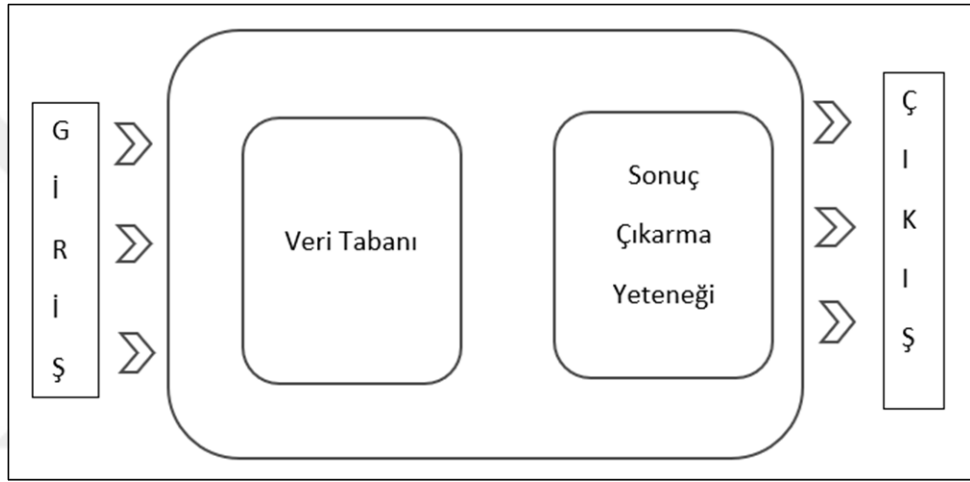
SİMGELER VE KISALTMALAR DİZİNİ

API	Application Programming Interface
BT	Bilgisayarlı Tomografi
CAD	Bilgisayar Destekli Tespit
CNN	Convolution Neural Network (Konvolüsyonel Sinir Ağı)
DICOM	Digital Imaging and Communications in Medicine
DLCS	Danimarka Akciğer Kanseri Taraması
DNN	Deep Neural Network (Derin Sinir Ağı)
IDRI	Lung Image Database Consortium
KNN	Kenar komşu algoritması
LIDC	Lung Image Database Consortium
MID	Çok Merkezli İtalyan Akciğer Saptama
MIT	Massachusetts Teknoloji Enstitüsü
MÖ	Makine Öğrenmesi
MR	Magnetik Rezonans Görüntüleme
PET	Pozitron Emisyon Tomografisi
RF	Radyo Frekansı
RNN	Tekrarlayan Sinir Ağı
ROC	Receiver Operating Characteristics
SAE	Stack Auto Encoder
SFT	Pulmoner Fonksiyon Testi
SOM	Self-Organizing Maps

1. GİRİŞ


Günümüzde bilgisayar teknolojilerinin gelindiği son nokta olarak yapay zekâ uygulamaları bunun yanı sıra yapay öğrenme, makine öğrenmesi gibi kavramlar ön plana çıkmıştır.

Yapay zekâ çalışmalarındaki amaç, insan beyin yapısının çalışma mantığı tanımlanarak, bu modeller sayesinde bilimsel çalışmalara katkı sağlamaktır. Şekil 1.1'de yapay zekâ ile bilgisayarların işleyiş yapısı gösterilmektedir.




Şekil 1.1. Şekil Yapay zekâ ve bilgisayarlar

Bilgi tabanına atılan bilgiler bilgisayar tarafından derlenip öğrenilerek sonuç çıkarması sağlanmaktadır. Bilgisayarın öğrenmesi bilgisayarlara öğretilen algoritmalar yoluyla gerçekleştirilmektedir. Çıkarılan bu sonuçlar neticesinde bilgisayar öğrenilmiş bir davranış sergilemiş olmaktadır. Şekil 1.2'de yapay zekâ, makine öğrenmesi ve derin öğrenme arasında ilişkiyi gösteren venn diyagramı verilmiştir.




Şekil 1.2. Yapay zekâ venn diyagramı (Raza, 2018)

Dünyada birçok üniversitede araştırma konusu olan yapay zekâ ve onun alt dalı olarak bilinen makine öğrenmesi konuları birçok farklı alanlarda; örneğin tıp, savunma sanayi gibi alanlarda gelişim göstermektedir. Bunun bir sebebi insan hayatını kolaylaştırmak ve insanların yapabildiği gibi tahmin yürütme, öğrenme, cevap verme gibi durumları bilgisayarların yapabilmesini sağlamaktır. Günümüzde bilgisayar kullanımı giderek yaygınlaşmakta ve hayatımızın vazgeçilmez bir parçası haline gelmektedir. Gündelik yaşantımızın büyük bir alanını oluşturan bilgisayarlardan birçok alanda daha fazla yararlanmak için yapılan geliştirme çalışmaları ise hızla devam etmektedir. Bilgisayarın yazılımsal ve donanımsal olarak gelişimi ile birlikte, birçok uygulama alanı da önem kazanmaya başlamıştır. Medikal ve bilgisayar bilimleri arasındaki ortak çalışmalar kapsamında PET/BT görüntüleme alanında yapılan kendi veri setleri üzerinden elde edilen bulgular ile literatüre katkıda bulunan çalışmaların sayısı da oldukça fazladır (Okyay, 2016). Ülkemizde kanserden meydana gelen ölümler çoğunlukla akciğer kanserinden olmaktadır (Demirkazık,2014). Şekil 1.3’de Erkekler için ve Şekil 1.4’de kadınlar için ülkemizdeki kanser istatistikleri görülmektedir.



Şekil 1.3. Erkeklerde en sık görülen bazı kanserlerin % dağılımları (Anonim, 2014)



Şekil 1.4. Kadınlarda en sık görülen 10 kanserin yaşa göre dağılımı (Anonim, 2014)

Türkiyede ve farklı ülkelerde erkeklerde görülen ilk beş kanser türünün dağılımı Çizelge 1.1’de verilmiştir. Çizelge 1.1’de görüldüğü gibi akciğer kanseri ülkemizde birinci sırada yer almaktadır.

Çizelge 1.1. Erkeklerde en sık görülen ilk beş kanser türünün dağılımı (Anonim, 2014)

	Türkiye	Dünya	IARC'a üye 24 ülke	AB (28 ülke)	ABD
1	Akciğer	Akciğer	Prostat	Prostat	Prostat
2	Prostat	Prostat	Akciğer	Akciğer	Akciğer
3	Kolorektal	Kolorektal	Kolorektal	Kolorektal	Kolorektal
4	Mesane	Mide	Mide	Mesane	Mesane
5	Mide	Karaciğer	Mesane	Böbrek	Böbrek

Amerika’da her yıl 225000 kiři akciđer kanserinden etkilenmekte ve bunun tedavi giderleri aısından karřılıđıda 12 milyar dolar olarak ifade edilmektedir. Bu nedenle bařarılı ve erken teřhis hayati nem tařımaktadır. Akciđer kanserini tespit edebilen bilgisayarlı grntleme yntemleri akciđer kanserlerinden oluřacak lmleri azaltacaktır (Demirkazık, 2014). Akciđer kanserinde tanı ve evrelemede hastalarda ayrıntılı bir fizik muayenenin ardından akciđer grafisinde tmr saptanması halinde atılacak 2. adım genellikle akciđerin BT grntsnn ekilmesidir. BT’de grlen tmr hakkında detaylı bilgi elde edilmektedir.

Tıp alanında bilgisayar bilimlerinden faydalanılarak, bazı terimlerin ortaya ıkmasına sebebiyet vermiřtir. Bunlardan birisi Bilgisayar Destekli Tespit (BDT) bir diđer de Uzman Sistemlerdir. BDT sistemler grnt iřleme tekniklerini kullanarak medikal grntlerdeki anormal dokuların tespiti ařamasında yardımcı olmaktadır. BDT sistemleri sonuca ulařmadaki sreci hızlandırırken bu sreteki insandan kaynaklanan hata olasılıđını da azaltmaya olanak sađlamaktadır (Dođan vd, 2016).

BDT, vcutta bulunan tmrlerin saptanması ve sınıflandırılması, kırılan kemiklerin tespit edilmesi, kanserlerin teřhisi ve kategorileřtirilmesi gibi pek ok anlamda bilgisayar sistemleri tıbbi grntlemeyle birlikte kullanılmaktadır (Ekři vd., 2012). Uzman sistemler ise belirli bir disiplin alanında, gerek kiřilerden elde edilen bilgilerden yola ıkarak, zamanla kendi kendini geliřtirebilen, karar srecinde kısmen de olsa insan gibi karar verebilme yeteneđine sahip sistemlerdir. Uzman sistem geliřtirildikten sonra karar ařamasında, insanla aynı sonucu verebilmesi olduka nemlidir. Yaygın olan grřn aksine, geliřtirilen sistemin amacı bir uzmanın yerini almak deđil, sadece teřhis safhasında konu zerinde alıřan uzmanlara elde edilen bilgilerin iřıđında verilecek kararlara destek olmaktır (Kutukız, 2014).


Akciđer zerinde oluřan tmrler bazı durumlarda ok kk ya da yuvarlak yapıda olduklarından dolayı teřhis ařaması olduka zor olmaktadır. Bu nedenle, geliřtirilecek bir BDT sistemi akciđer tmrlerinin erken safhada teřhisinde nemli bir yntem olacađı dřnlmektedir. Radyologlar ve hekimlere akciđer tmrlerini bařarıyla tespit etmeleri iin bir bilgisayar yardımıyla kullanılan tanı / tespit sistemi kullanılması nemlidir (Dandıl, 2017). Tıbbi grntlerin analiz edilebilmesi tmrlere ait lm bilgilerinin elde edilebilmesi iin, grntlerin bir dizi grnt iřleme tekniđine tabi tutulması gerekmektedir (evik, 2011).

1.1. Tıpta görüntüleme teknikleri

Tıbbi görüntülemede veriler x-ray radyografi, ultrasonografi, bilgisayarlı tomografi (BT), manyetik rezonans (MR), pozitron emisyon tomografisi (PET) gibi yöntemler kullanılarak elde edilmektedir (Radsite, 2011). Akciğer kanseri tespitinde PET/BT yöntemleri kullanılmaktadır.

1.1.1. Bilgisayarlı tomografi görüntüsü (BT)


Bilgisayarlı Tomografi (BT) yöntemi, bir hastanın vücudundaki belirli alanların enine kesit görüntülerini oluşturmak için birden fazla açıdan ve konumlardan alınan röntgen verilerini birleştirilerek oluşturulan tıbbi bir görüntüleme yöntemidir. Görüntülenmesi istenilen alanı dijital dilimlere ayırır. Hekimlerin kemikler, dokular ve organlardaki sorunları belirlemek için insan vücudunu görmelerini sağlar (Radsite, 2011). Şekil 1.5’de örnek bir BT görüntüsü verilmiştir (Erbaş, 2011).



Şekil 1.5. Bilgisayarlı tomografi görüntüsü (BT) (Erbaş, 2011)

1.1.2. Pozitron emisyon tomografi (PET/BT)


PET taramaları, radyotraktör tarafından yayılan pozitronlardan kaynaklanan imha fotonlarını ölçer. Bu pozitronlar kısa bir mesafe kat ederler ve elektron üreten yok etme fotonları ile kabaca zıt yönlerde yok olurlar. PET tarayıcı, bu “yok etme fotonlarının” rastgele emisyonlarını ölçer, bu sayede bir organda veya dokuda meydana gelen metabolik değişiklikleri ortaya çıkaran daha yüksek çözünürlüklü görüntüler sağlar (Radsite, 2011). Şekil 1.6’da örnek bir PET/BT görüntüsü verilmiştir.



Şekil 1.6. Pozitron emisyon tomografi (PET/BT) (Çağırıcı, 2019)

1.2. Görüntü işleme

Görüntü işleme yöntemi görüntüdeki bazı problemleri gidererek, normal görüntüdeki alacağımız bilgilerden daha fazla bilgi etmemize olanak sağlamaktadır. Görüntü işleme tekniklerinin önemli kullanım alanlarından birisi de medikal sektördür. Medikal görüntülerin görüntü işleme teknikleri kullanılırken düşük çözünürlük, gürültü, görüntüleme yapılarının görünümü gibi bazı problemlerle karşılaşmaktadır. Bu sorunların sebepleri kullanılan teknolojik aletler ve görüntü alma sırasında dışarıdan karşılaşılan olumsuz etmenlerdir (Hamdi, 2016). Şekil 1.7’de görüntü işleme adımlar gösterilmiştir.



Şekil 1.7. Görüntü işleme adımları


Şekil 1.7’de görüldüğü üzere medikal görüntülerde oluşan sorunları, görüntü iyileştirme, görüntü önileme vb. gibi işlemlerle çözmek mümkündür.

Görüntü işleme işlemleri Matlab, C++, Python, Java gibi birçok bilgisayar programlama dili ile gerçekleştirilebilmektedir. Bilgisayar programlama dilinin seçiminde önemli olan faktör ise, en kısa sürede ve en optimize sonucu verecek olan dili tercih etmektir. Yapılan yüksek lisans çalışmasında görüntü işleme yönünden

kullanımı kolay ve zengin kütüphanelerinden dolayı Python programlama dili kullanılmıştır.

1.3. Yapay sinir ağıları

Yapay sinir ağıları insanda bulunan sinir sisteminin çalışma şekline benzetilerek oluşturulmuş, nöronların çeşitli şekillerde birbirlerine bağlanmasıyla oluşmuş yapılardır. Basit bir yapay sinir ağı nöron dediğimiz tek bir hücreden oluşur. Sinir ağlarının veriye uygun modelinin çıkarımını doğrusal olmayan hesaplamalar ile gerçekleştirmektedir (Özcan, 2014). Şekil 1.8’de yapay sinir ağlarının yapısı gösterilmiştir (Nielsen, 2015).




Şekil 1.8. Yapay sinir ağı mimarisi (Nielsen, 2015)

1.4. Derin öğrenme

Derin Öğrenme ilk defa 2012 yılında bilim insanları tarafından kullanılmaya başlanmıştır. Derin öğrenmenin ortaya çıkmasıyla birlikte görüntü/ses tanıma, kanser teşhisleri ve sanal gerçeklik v.b. birçok alanda uygulamalar geliştirilmiştir. Derin öğrenme yaygın bir kullanım alanına sahip olmasının en önemli sebebi problemlerin çözümünü yüksek doğruluk oranlarında bulmasıdır (Özkan, 2017). Derin öğrenme algoritması, makine öğrenmesi algoritmasının bir alt dalıdır. Derin öğrenme, verilerin kullanımında makine öğrenmesi algoritması gibi birebir değil, katman olarak isimlendirilen özel bir türünü temsil etmektedir (STM, 2018).

Derin öğrenme algoritmaları yapay sinir ağları kökenli ve enerji tabanlı modellerden oluşmaktadır. Mimarisi birçok katman ve saklı değişkenden meydana gelmektedir (Özcan, 2014). Şekil 1.9’da derin öğrenme mimarisi gösterilmiştir (Nielsen, 2015).



Şekil 1.9. Derin öğrenme mimarisi (Nielsen, 2015)

Derin öğrenme Şekil 1.8’de gösterilmiş olan yapay sinir ağı modelinin katman sayısının artırılmış halidir. Şekil 1.9’da gösterildiği gibi yapay sinir ağına birçok gizli katman eklenmiş ve bu katmanlar yardımıyla çıkış katmanında sonucun bulunması sağlanmıştır. Derin öğrenme çok fazla gizli katman bulunmasından dolayı parametre sayısı oldukça fazladır. Her bir katman kendi arkasına yerleştirilmiş birden fazla eğitilebilir katmanlardan oluşur (Özkan, 2017).

2. KAYNAK ÖZETLERİ

Alakwaa ve arkadaşları (2017) çalışmalarında Data Science Bowl ve Kaggle'dan aldıkları akciğer BT görüntülerini sınıflandırmak için Konvolüsyonel Sinir Ağı'nı (CNN) önermişlerdir. LUNA veri setinde nodül tespiti için U-net CNN mimarisini kullanmışlardır. Sonuçta kullanılan yöntemde U-net CNN mimarisinin doğruluk oranı % 86.6 olarak tespit etmişlerdir.

Anthimopoulos ve arkadaşları (2016) çalışmalarında akciğer hastalıklarında farklı doku türlerini sınıflandırmak için CNN modelini önermişlerdir. Önerilen ağda 5 evrimsel katman, 1 havuz katmanı ve 3 tane birbirine bağlı katman kullanılmıştır. CNN mimarisi ile karşılaştırıldığında LeNet, AlexNet ve VGG Net dokuların sınıflandırılması ve tespiti için önerilen CNN algoritmasının diğer algoritmalara göre % 85.61 doğruluk oranı ile daha başarılı sonuç verdiğini tespit etmişlerdir.

Bektaş ve arkadaşları (2016), çalışmalarında, meme kanserinin teşhisi için farklı makine öğrenmesi algoritmaları kullanılarak, bu algoritmaların birbirlerine göre doğruluk oranları karşılaştırılmışlardır. Yapılan çalışma sonucunda 139 öznitelik ile % 90,72 doğruluk oranında meme kanserindeki etkin gen tespiti etmişlerdir.

Ciampi ve arkadaşları (2017) çalışmalarında akciğer kanseri görüntülerinde bulunan nodüllerin sınıflandırmasında çok ölçekli CNN modeli önermişlerdir. Akciğer kanseri nodüllerinin tanılanmasında, Çok Merkezli İtalyan Akciğer Saptama (MID) ve Danimarka Akciğer Kanseri Taraması (DLCS) veri setleri kullanılmıştır. Radyologların tanılanması ile karşılaştırılan CNN modeli radyologların tahminine yakın bir değer bulmuştur. Sonuçta CNN modelinin % 79.5 doğruluk oranında verdiğini tespit etmişlerdir.

Çevik (2011)'in çalışmasında, tıbbi görüntüler üzerindeki bulunan birçok özneliğin, sonuçlar üzerindeki kullanıcı bağımlılığının minimuma indirilmesiyle analiz edilmesini sağlayacak bir uygulama oluşturmuştur. Tasarlanan uygulama, tıbbi görüntü işleme rutinlerini sıraya koyularak gerçekleştirilmiştir. Radyoloji uzmanları,

beyin tümörlerinin tanısında ve tedavi süreçlerinde destek oluşturacak bir uygulama ile sonuçlar üzerindeki varyasyonu düşürmeyi hedeflemiştir.

Dastjerdi vd. (2017) çalışmalarında hastaların torakal BT görüntülerinin işlenmesi yoluyla tespit aşamasında karakterize edilen KOAH şiddetini doğru bir şekilde değerlendirmek için yeni bir uzman sistem tekniği önermişlerdir. Teknik, solunum döngüsü boyunca akciğerde hava hacmi değişikliği ve dağılımının 23 özelliğini otomatik olarak çıkarmak için torakal BT görüntülerini kullanmaktadır. Güçlü korelasyon gösteren özelliklerle Pulmoner Fonksiyon Testi (SFT) ölçümleri arasındaki ilişkiler geliştirildi. Ayrıca, tüm özelliklerin ayırt edici gücü sıralı özellik seçimi algoritması kullanılarak ileri ve geri yönlerde incelemişlerdir. Sınıflandırma için, Naive Bayes sınıflandırıcısının eğitimi için 12 özellik seçmişlerdir. Çalışma, çeşitli evreleri olan 13 normal ve 56 COPD hastasını içeren 69 kişinin akciğer inspiratuvar / ekspiratuvar BT görüntüleri ve PFT ölçümlerini içermektedir. Sınıflandırıcının performansı $m = 7$ olan leave-m-out çapraz doğrulama yöntemi kullanılarak değerlendirilmiştir. Bu araştırmada elde edilen sonuçlar, % 84 'ün üzerinde bir genel doğruluğun göstergesi olup, KOAH evresinin belirlenmesindeki etkinliğini sadece BT görüntülerine dayanarak ve SFT ölçümlerini kullanmadan göstermiştir. Bu, önerilen uzman sistemler potansiyelini klinik olarak uygulanabilir bir görüntü tabanlı KOAH teşhisi yöntemi olarak göstermektedir.

Dandıl (2017) çalışmasında tasarladığı bir Bilgisayar Destekli Tespit (CAD) sistemi akciğer tümörlerinin erken aşamada teşhisi için bir yöntem olmuştur. Bu çalışmada, BT görüntüler üzerinde Self-Organizing Maps (SOM) sinir ağları modeli ile tümörlerin bölütlemesi işlemi gerçekleştirilmiştir. Sistemde, 40 hastadan alınan 1128 adet BT görüntüsü başarılı olarak bölütlenmiş ve akciğer tümörlerinin sınıflandırılmasında SOM yönteminin kullanılabilirliği gösterilmiştir.

Deperlioğlu vd. (2018) çalışmasında Retina Fundus görüntülerinden diyabetik retinopatiyi teşhis etmek için görüntü işleme ve derin öğrenmeyi kullanmışlardır. Retina Fundus görüntülerini iyileştirmek için V dönüşümü algoritması ve histogram

eşikleme işlemlerini içeren bir yöntem sunmuşlardır. Görüntü işleme adımından sonra, sınıflandırma algoritması olarak CNN kullanmışlardır.

Doğan vd. (2016) çalışmalarında, beyin MR görüntülerinde tespit edilen ilgili alanların öznitelikler kullanılarak yeniden oluşturulması ve sınıflandırılması üzerine bir sistem geliştirmişlerdir. Geliştirilen sistem MR görüntülerinde ön işleme, tümör tespiti ve bölütleme gibi aşamalardan oluşmaktadır. Geliştirilen sistem 10 hastaya ait 497 kesit görüntüsünden oluşan REMBRANDT veri seti ile denenmiştir. Sınıflandırma işleminde sistemin performansı karar ağaçları ile %93,36, yapay sinir ağları ile %94,89, K-en yakın komşu ile algoritması ile %96,93 ve Meta-Learner algoritması ile %96,93 doğruluk oranlarında tespit etmişlerdir. Bu sonuçlar ile önerilen yöntemin MR görüntülerinden beyin tümörü tespitinde sınıflandırma işleminin performansını arttırdığını tespit etmişlerdir.

Dunet vd. (2016) çalışmasında, küratif ameliyatta uygun hastaları tanımlamak için klinik TNM (T=tümör çapı büyüklüğü, N=komşu lenf nodu tutulumu, M= uzak metastaz) evrelemede BT'nin rolü, katkıları tanımlamışlardır. 2009'da en son güncellenen TNM evreleme kriterleri, 2016 yılının sonlarında yayınlanacak 8. baskının yeni önerileri ile birlikte tartışılmış, çalışmalarında tedavi öncesi değerlendirme için en önemli BT özellikleri vurgulamışlardır.

Fıçıcı (2016) çalışmasında yüksek doğrulukla beyin tümörlerin tespiti ve hacim hesabı için bir metod geliştirmiştir. Çalışma 10 hastaya ait 500 beyin MR kesiti ile %99 tümör tespiti doğruluk oranı ve %92 hacim hesabı elde edilmiştir.

Gruetzemacher ve arkadaşları (2016) çalışmalarında akciğer kanseri nodül sınıflandırmasında Derin Sinir Ağı (DNN) önermişlerdir. Görüntüler için LIDC ve IDRI (Lung Image Database Consortium) veri tabanını kullanmışlardır. Farklı evrişim katmanına sahip dört farklı topoloji karşılaştırılmıştır. Sonuçta, diğer evrişimsel katmanlar tarafından doğruluk oranının birbirine yakın olduğunu ve beş evrişim katmanı ile Derin Sinir Ağının % 82.10 ile en yüksek başarı oranına sahip olduğu bulunmuştur.

Jacobs (2015) çalışmasında akciğer kanseri nodüllerini sınıflandırmak için Kenar komşu algoritması (KNN) kullanmıştır. Görüntüleri önceden işleyerek, bölütleme işleminin ardından özellik çıkarımı yapmıştır. Kullanılan yöntemin performansı ile uzmanların teşhisinin neredeyse aynı olduğunu ifade etmiştir.

Kahraman (2017) çalışmasında, DICOM (Digital Imaging and Communications in Medicine) görüntü formatıyla elde edilen BT göğüs görüntülerinden akciğer dokusunun bölütlenerek elde edilmesinde kullanılan farklı yazılımsal tekniklerin uygulanmasını ve bölütleme işlemindeki başarılarının karşılaştırmalı olarak ele alınmasını hedeflemiştir. Matlab tabanlı yazılım kodları ile görüntüdeki parazitleri azaltma, akciğerdeki kanserli yapı olan nodülün tespiti, görüntüden akciğer organını elimine etmek gibi uygulamalar hedeflenmiştir.

Karaçavuş vd. (2014) çalışmalarında maximum standardize tutulum değeri bilgisi ışığında PET/BT görüntülerinden elde edilen, tümörü oluşturan öznelikler ile sınıflandırma yaklaşımlarını denemişlerdir. Tümörün tespit edildiği görüntüleri, PET/BT sisteminin kendi arayüz yazılımı kullanılarak ayrı ayrı ve birleştirilmiş olarak incelemişlerdir. Sonraki aşamada görüntü işleme adımları ile PET görüntüsü üzerinde ve MATLAB programı kullanılarak gerçekleştirmişlerdir. Sınıflandırıcı olarak KNN sınıflandırıcısı kullanmışlardır.

Kulkani ve Panditrao (2014) çalışmalarında görüntü işleme ve Destek Vektör Makineleri (SVM) ve görüntü işleme yöntemlerini kullanmışlardır. BT görüntülerinin işlenmesinde gürültüleri kaldırmak için median filtre, görüntülerin iyileştirilmesi için gabor filtre, görüntü bölütleme işleminde ise Watershed algoritmasını önermişlerdir. Ön işlemeden sonra kanser nodüllerinin tespiti için SVM algoritması kullanılmış, sonuçta akciğer kanseri evresinde nodülün boyuta göre tespit edildiğini ifade etmişlerdir.

Kutukız (2014) çalışmasında çağımızın en ölümcül hastalığı olan kanserin tespiti için uzman bir sistem geliştirmiştir. Geliştirilen görüntü tanıma sisteminin de kullanıcı arayüzü olarak Matlab programından yararlanılmış, kanserli hücrelerinin saptanması ve sağlıklı hücrelerin kanser hücrelerinden ayırt edilmesi hedeflenmiştir.

Matsuki (2002) çalışmasında yapay sinir ağları ile normal ve anormal olan akciğer kanseri BT görüntülerinin teşhisi için yardımcı bir program önermiştir. Radyologların tanı koymasına ile kullanılan yapay sinir ağı karşılaştırıldığında, yapay sinir ağı modelinin iyi bir performans gösterdiği ifade edilmiştir. Çalışmada radyologların teşhis oranı sırasıyla 0.951 ve 0.831 olarak bulunmuştur. Yapay sinir ağı modelinin uygulanmasıyla bu oran 0.959'a yükseldiği görülmüştür.

Okyay (2016) çalışmasında beyin görüntüleme tekniklerinin Alzheimer hastalığı erken tanı tahmininde kullanılma alanında çalışma yapmıştır. Çalışmasında 19 adet Alzheimer hastalığı, 19 adet frontotemporal demans ve 25 adet vasküler demans olmak üzere üç farklı hastalıktaki 63 hastanın MR görüntülerini kullanmıştır. Dilimlenmiş beyin görüntü setleri Freesurfer beyin analiz yazılım aracı ile beraber işlenmiş ve farklı öznelik grupları oluşturulmuştur.

Niki ve arkadaşları (2001) çalışmalarında; akciğer kanseri teşhisi ve kümelenmesinde K-means kümeleme algoritmasını, iyi ve kötü huylu tümörlerin sınıflandırılmasında lineer karmaşıklık algoritmasını kullanmışlardır. Karar destek makine algoritması kullanılmış ve % 80 oranında başarı elde edilmiştir. Literatürde benzer çalışmalarla karşılaştırıldığında başarı oranı yüksek çıkmıştır.

Rao ve arkadaşları (2016) LIDC veri setinin kullanımı ile akciğer kanseri sınıflandırması için CanNet adında bir CNN mimarisi önermişlerdir. CanNet 2 tane evrimsel katman, 1 tane havuz katmanı ve 1 tane de ara birleştirici katmandan oluşturulmuştur. Literatürde bilinen yöntemlerden ANN ve LeNet ile CanNet karşılaştırıldığında başarı oranları sırası ile % 56, % 72,5 ve % 76 olmuş, en yüksek doğruluk oranını CanNet ile sağlandığını ifade etmişlerdir.

Song ve arkadaşları (2017) LIDC-IDRI veri kümesi yardımıyla akciğer kanseri BT görüntülerinin sınıflandırılmasında DNN, CNN ve SAE (Stack Auto Encoder)

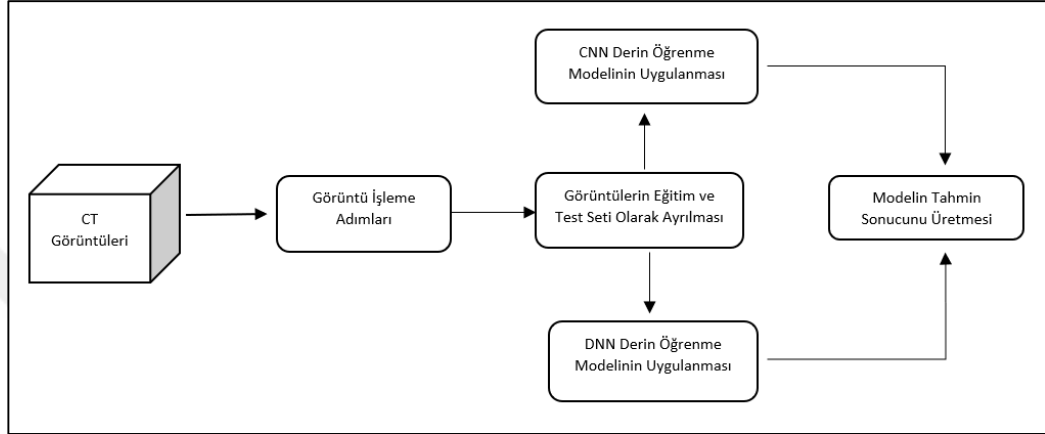
algoritmalarının başarımlarını karşılaştırmışlardır. Çalışma sonucunda CNN, DNN ve SAE ağlarının başarımları sırası ile % 84,15, % 82,37 ve % 82,59 olduğu görülmüştür.

Teramoto ve Fujita (2013) çalışmalarında, akciğer BT görüntülerinden kanserli nodül tespitinde silindirik nodül artışı filtre metodu uygulamışlardır. Çalışmalarında veri seti olarak LIDC veritabanından yararlanmışlardır. Nodül tespit ve bölütlemenin yanında nodül tespit hızını artırmayı amaçlamışlardır. SVM algoritması kullanılarak nodül tespitinde % 80 doğruluk oranına ulaşmışlardır.

Ural (2016), çalışmasında BT ile çekilmiş mide görüntüleri için kanserli bölgeleri tahmin eden, yeni bir sistem üzerinde çalışmıştır. Çalışmasının amacı, midede bulunan kanserli bölgelerin renk uzayındaki koordinatlarının belirlenerek, yüksek doğrulukta nodül içeren bu alanların sınırlandırılması ve kullanıcıya geri bildirilmesidir. Bahsedilen bu süreç, enerji haritalaması ve çoklu görüntü işleme metotları kullanılarak oluşturulmuş ve gelişmiş bir sistem ortaya çıkarmıştır.

3. MATERYAL VE YÖNTEM

Python programlama dili, hem görüntü işleme hem de makine öğrenmesi uygulamaları için kütüphane sayısı oldukça zengindir. Yapılan araştırmada python dili için Anaconda idesinde bulunan Spyder geliştirme ortamı kullanılmıştır. Şekil 3.1’de önerilen modelin iş akış diyagramı gösterilmiştir.



Şekil 3.1. İş akış diyagramı

Şekil 3.1’de görüldüğü üzere yapılan çalışmada ilk olarak görüntüler üzerinde görüntü işleme teknikleri uygulanmıştır. Görüntüler üzerindeki renk farklılıklarının gitmesi ve tümörlü bölgelerin daha iyi tespiti için histogram eşikleme işlemi yapılmıştır. Histogram eşikleme yapılan görüntüler etiketlenmiş, ardından derin öğrenme algoritmalarına tabii tutulup doğruluk ve kayıp oranları karşılaştırılmıştır.

3.1. Akciğer kanseri PET/BT görüntü veri seti

Yapılan çalışmada akciğer kanseri BT görüntü veri seti Süleyman Demirel Üniversitesi Tıp Fakültesi Nükleer Tıp Anabilim Dalı’ndan temin edilmiştir. Derin öğrenme modelinde veri seti olarak iyi ve kötü huylu tümör bulunan 38 farklı hastadan 1968 tane BT görüntüsü kullanılmıştır. Her hastadan ortalama 50 civarı Pet/BT kesiti sadece akciğer kısmı olacak şekilde alınmıştır. Veri seti önce iyi ve kötü huylu tümör bulunma durumlarına göre etiketlenmiştir. Veri setinin % 80’i eğitim, % 20’si test için kullanılmıştır.

3.2. Kullanılan programlama dili

Derin öğrenme uygulamalarında geliştirme yaparken spesifik sorunlarda, probleme uygun olan dinamiklikte dil seçmek uygun olacaktır. Yapılan araştırmada derin öğrenme alanında çok fazla sayıda araştırma ve uygulamanın olması, projeyi geliştirirken karşılaşılabilecek bir sorunun çözümünün de bulunma ihtimalini arttıran açık kaynak kodlu Python programlama dili kullanılmıştır.

3.3. Çalışmada kullanılan kütüphaneler

Bir görüntü segmentasyon algoritması, görüntü piksellerinin sayısı ile doğrusal olarak orantılı bir zamanda çalışmalı ve verimli olmalıdır. Pratik kullanım için, segmentasyon yöntemlerinin kenar tespiti veya diğer düşük seviyeli görsel işleme tekniklerine benzer hızlarda çalışmasını gerektirmektedir (Felzenszwalb ve Huttenlocher, 2004). Bu nedenle akciğer BT görüntülerinde iyi huylu ve kötü huylu tümörlü doku bulunan görüntüler ilk olarak binary formata dönüştürülmüştür. Görüntüde histogram eşikleme işleme yapılarak görüntü işleme adımı gerçekleştirilmektedir. Bu işlemleri gerçekleştirebilmek için hazırlanan yazılımda Python programlama dilindeki opencv, pandas, glob, skimage, numpy, scipy, skdata, scikit-learn, matplotlib, tensorflow ve keras, kütüphaneleri kullanılmıştır.

3.3.1. OpenCv

OpenCV C++ dili ile geliştirilmiş, birçok bilgisayarlı görü algoritmasına sahip olan açık kaynak kodlu bir kütüphanedir. Görüntü işlemede kullanılır. Matematiksel sınıflandırma, regresyon ve veri kümeleme gibi kuvvetli makine öğrenme fonksiyonlarını kullanır (Doxygen, 2015).

3.3.2. Pandas

Pandas kütüphanesi veri çerçeveleme yapmak için kullanılır. Alınan verileri yeniden şekillendirme, dilimleme, birleştirme vb. gibi çeşitli özelliklerin kullanılmasını sağlar. Verileri düzenlemek için Numpy kütüphanesi ile beraber çalışır (Salomon, 2018).

3.3.3. Glob

UNIX'in modern işletim sistemlerinin temelini oluşturan bir kütüphanedir. Python dilinde dosya arama altyapısı özelliği glob modülü sayesinde kullanılır (Açıl, 2017).

3.3.4. Skimage

Python programlama dili için hazırlanan açık kaynak kodlu bir görüntü işleme kütüphanesidir. Segmentasyon algoritmaları, geometrik dönüşümler, analiz, filtreleme, morfoloji, özellik tanıma gibi konular yanında daha fazlasını içermektedir. Python'da bulunan NumPy ve SciPy ile beraber çalışmak üzere tasarlanmıştır (Wikipedia, 2009).

3.3.5. Numpy

N boyutlu dizi ve matrisleri kullanmak ve üzerinde hesaplamalar yapmanıza sağlayacak bir kütüphanedir. Bu kütüphane matematiksel işlemler için geliştirilmiştir (Salomon, 2018). Uygulama aşamasında Numpy, veri işleme öncesi ve hazırlığında kullanılır.

3.3.6. SciPy

SciPy, optimizasyon, lineer cebir, sinyal ve görüntü işleme gibi bilim ve mühendislikte yaygın olarak kullanılan modüller içerir. SciPy, NumPy dizi nesnesi üzerine kuruludur ve Matplotlib, Pandas gibi araçlar bir bilimsel kütüphane seti bulunduran NumPy yığınının bir parçasıdır (Wikipedia, 2019).

3.3.7. Skdata

Makine öğrenmesi alanında görüntü işleme ve doğal dil işleme alanında bazı problemlerin veri kümelerini içeren kütüphanedir (Jaberg, 2015).

3.3.8. Scikit-Learn

Makine öğrenmesi kütüphanesidir. Scikit-learn, 2D olarak oluşturulmuş dizilerin bir veya daha çok veri kümesinden gelen öğrenme bilgileriyle ilgilenir. Çok boyutlu dizilerde öğrenmelerin listesi olarak tanımlanabilir (Cournapeau, 2007).

3.3.9. Matplotlib

Çoğunlukla 2 boyutlu çizim ve grafikler için kullanılan bir kütüphanedir. Matplotlib büyük diziler için iyi performans sağlamak açısından NumPy ile birlikte kullanılır. Matplotlib, basit komut yapısıyla grafikler oluşturmamıza yardımcı olur (Hunter vd., 2017).


3.3.10. Tensorflow

Tensorflow, Google'ın açık kaynaklı bir derin öğrenme kütüphanesidir. Google Beyin firması üzerinde çalışan mühendisler tarafından makine öğrenmesi ve derin öğrenme çalışmalarında kullanılmak üzere geliştirilmiştir. Tensorflow bilgisayarın ekran kartı özelliğine göre cpu veya gpu da çalışma performansı gösterebilir (Salomon, 2018).

3.3.11. Keras

Keras derin öğrenme hesaplamaları için bir Python kütüphanesidir. Keras, Python programlama dili ile yazılmış ve TensorFlow gibi yapıların üzerinde çalışabilen bir sinir ağları API (Application Programming Interface)'sidir. Hızlı sonuçlar sağlamak amacıyla geliştirilmiştir (Gulli vd., 2017).

Şekil 3.2'de bu tez çalışmasında önerilen modelin ayrıntılı iş akış diyagramı gösterilmiştir.



Şekil 3.2. Önerilen modelin iş akış diyagramı


Çalışmada ilk olarak veri seti, veri ön işleme adımıyla iyi huylu ve kötü huylu veri seti olmak üzere ikiye ayrılmıştır. Daha sonrasında görüntü işleme ve derin öğrenme modelleri uygulanarak en uygun model elde edilmiştir.

3.4. Kullanılan görüntü işleme yöntemi

Medikal görüntülerde görüntü işleme yapılırken bölütleme ve yerleştirme işlemi yapılır. Bir görüntüdeki her piksel değeri bir sınıf etiketine sahip olmaktadır. Bundan dolayı medikal görüntü işleme de iki yaklaşım ele alınır: Bunlardan birincisi görüntüyü bir bütün olarak sınıflandırma yani iyi ve kötü huylu tümör varlığını gösterme, ikincisi ise görüntüyü parçalar halinde bölerek sınıflandırmadır. Veri setinin büyüklüğünün artması parçalar halinde sınıflandırmanın, bütün olarak sınıflandırmaya göre daha iyi sonuçlar verdiği ortaya çıkmıştır. Sınıflandırma için her piksel değerini bir alt ağ ile beslemek daha yüksek bir başarı oranı sağlayacaktır (Paul, 2018).

Akciğer BT görüntülerine bazı görüntü işleme adımları uygulanmış, yeni oluşan resimlerle beraber işlenmemiş görüntüler algoritmaya veri olarak sunulmuştur.

Yapılan çalışmada OpenCv kütüphanesinde bulunan `cv2.COLOR_BGR2GRAY` fonksiyonu ile görüntüler gri seviyeye getirilmiş, ardından `cv2.equalizeHist` fonksiyonu ile histogram eşikleme işlemi yapılmıştır. Oluşturulan derin öğrenme modellerine veri seti olan görüntülerin modellerin eğitimi sonucunda en iyi doğruluk oranını verebilmesi için, histogram eşikleme yapılan görüntülerde modele veri seti olarak sunulmuştur. Şekil 3.3'de görüntü işleme yapılmamış orijinal BT görüntüsü gösterilmiştir.




Şekil 3.3. İşlenmemiş orijinal görüntü

Tüm resimler için bir fonksiyon yazılmıştır. Bir döngü yardımıyla tüm resimler taranır. Ardından openCv kütüphanesinde bulunan `cvtColor` fonksiyonu ile resimleri gri seviyeye döndürme işlemi yapılmaktadır. Histogram işlemi için öncelikle openCv kütüphanesi yardımıyla görüntüye `equalizeHist` fonksiyonu uygulanmış, ardından görüntü numpy dizisine çevrilmiştir.

Görüntü İşleme Kod Bloğu;

```
img = cv2.cvtColor(img,cv2.COLOR_BGR2GRAY)
equ = cv2.equalizeHist(img)
img2 = Image.fromarray(uint8(img,equ))
```

Şekil 3.4’de Akciğer BT görüntüleri için OpenCv kütüphanesi ile histogram eşikleme yapılmış ve yapılmamış hali gösterilmiştir.



Şekil 3.4. OpenCv ile histogram eşikleme öncesi ve sonrası görüntü


Histogram eşikleme işlemi ile tümör bulunan ve bulunmayan BT görüntüleri etiketlendikten sonra sınıflandırma algoritması uygulanmıştır. Python dilinde hazırlanan yazılım ile CNN ve DNN derin öğrenme modelleri akciğer kanserin sınıflandırılma işlemleri için kullanılmıştır.

3.5. Derin öğrenme modelleri

Derin öğrenme modelleri temelinde sinir ağı katmanlarından oluşmaktadır (Özcan, 2014). Katmanların birbirine bağlanma şekli, sayısı ve daha birçok özellik yeni derin öğrenme modellerinin çıkmasını sağlamıştır.

3.5.1. Konvolüsyon katmanı

Modelde kullanılan doğrusal fonksiyon, konvolüsyon katmanı olarak isimlendirilir. Gizli katmanda bulunan herbir düğüm, görüntü işleme özelliğini kullanabilmemizde bize yardımcı olmaktadır (Salomon, 2018). Şekil 3.5'den de anlaşılacağı üzere bu katman ile resimde ölçeklendirme yapılmıştır.



Şekil 3.5. Görüntüleri ölçekleme (Salomon, 2018)


Giriş görüntüsünün 4×4 ve evrişim matrisini boyutununun, Şekil 3.6'da gösterildiği üzere 2×2 olduğunu varsayalım. Eğer konvolüsyon matrisini giriş görüntüsünün üstünde tutarsak, matrisin aynı konumdaki sayılar ile girdi arasındaki durumlarını hesaplanabilmektedir. Bu oluşan durumu toplayarak tek bir sayı elde edilir (Wu, 2017). Örneğin, matrise girişte sol üst bölge ile üst üste bindirirsek, bu uzamsal konumdaki evrişim sonucu şu şekilde olmaktadır: $1 \times 12 + 1 \times 20 + 1 \times 8 + 1 \times 34 = 52$. Bu durum Şekil 3.6'da gösterilmektedir.

$\begin{array}{c c} 1 & 1 \\ \hline 1 & 1 \end{array}$	<table border="1"><tr><td>12</td><td>20</td><td>30</td><td>0</td></tr><tr><td>8</td><td>12</td><td>2</td><td>0</td></tr><tr><td>34</td><td>70</td><td>37</td><td>4</td></tr><tr><td>112</td><td>100</td><td>25</td><td>12</td></tr></table>	12	20	30	0	8	12	2	0	34	70	37	4	112	100	25	12	<table border="1"><tr><td>52</td><td>64</td><td>32</td></tr><tr><td>124</td><td>121</td><td>43</td></tr><tr><td>316</td><td>232</td><td>78</td></tr></table>	52	64	32	124	121	43	316	232	78
12	20	30	0																								
8	12	2	0																								
34	70	37	4																								
112	100	25	12																								
52	64	32																									
124	121	43																									
316	232	78																									

Şekil 3.6. Evrişim işleminin gösterimi

3.5.2. Havuz katmanı


Havuzlama katmanı hesaplama alanıdır. Bu katmanın amacı konvolüsyon katmanındaki boyutlandırmayı yeniden yapmak ve modelin başarı oranını artırmak için özellik çıkarmaktır. Şekil 3.7’de görüldüğü gibi maksimum havuzlama modeldeki en yüksek piksel değerini çıkartmaktadır (Salomon, 2018).



Şekil 3.7. Maksimum havuzlama (FirelordPhoenix, 2018)

3.5.3. Düzleştirme katmanı


Bu katman Şekil 3.8’de görüldüğü gibi tüm özellik haritasındaki değerleri bir tek sütuna düzleştirme işlemidir (Mwiti, 2018).



Şekil 3.8. Düzleştirme (Flatten) (Escontrela, 2018)

3.5.4. Bırakma katmanı

Konvolüsyonel sinir ağlarında sinir ağları aralarındaki bağımlılıktan dolayı birbirini uyarıma eğilimleri yüksektir. Bu durum bazı fonksiyonların daha fazla ağırlık aldığı ve modele uygun hale geldiğini gösterir. Konvolüsyon ağının çok fazla yüklenmesini önlemek için bırakma fonksiyonu kullanılır (Salomon, 2018). Eğitim aşamasında rasgele seçilen nöronların bazıları ya tek tek ya da 1-p olasılıkla ağdan atılır. Böylece bir düğüm için gelen ve giden kenarlar azaltılmış olur. Şekil 3.9’da görüldüğü gibi bu durum ağın devamlılık sayısını iki katına artırsa da modelin eğitim süresi kısalmış olur (Budhiraja, 2016). Bırakma, 0 ile 1 arasında bir değer almaktadır (Sorokina, 2017).



Şekil 3.9. Standart sinir ağı ve bırakma sonrası sinir ağı (Budhiraja, 2016)

3.5.5. Doğruluk oranı

Bir modelin doğruluğu, genellikle modelin parametrelerini öğrenip sabitlendikten sonra ve hiçbir öğrenme gerçekleşmeden önce belirlenir. Daha sonra test verileri modele sunulup model eğitilir. Modelin yaptığı hataların sayısı hedeflerle karşılaştırıldıktan sonra kaybedilir. Son olarak kayıp oranı yüzdesi hesaplanır (Chen, 2017).

3.5.6. Kayıp oranı

Kayıp oranı, her eğitim seti grubundaki kayıpların ortalamasıdır. Uygulanan derin öğrenme modeli zaman içinde değiştiğinden, bir adımın ilk zaman üzerindeki kaybı genellikle son zamana göre daha yüksektir. Kayıp oranı, oluşturulan modelin eğitimi aşamasındaki her yinelemesinden sonra ne kadar güçlü veya zayıf olarak davrandığını gösterir. Genellikle, birkaç yinelemeden sonra kayıp oranının azaltılmasını hedefler (Chen, 2017).

3.5.7. Performans metriği

Genel olarak, sınıflandırma algoritmalarında performans değerlendirmesi için, sınıfların gerçek ve tahmini değerleri karışıklık matrisi ile karşılaştırılır (Polat, 2017). Alıcı İşletim Karakteristiği (Receiver Operating Characteristics-ROC), sınıflandırma performansını ölçmek için biyoinformatikte sıklıkla kullanılan bir yöntemdir (Lasko,

2005). Yüksek lisans çalışmasında veri kümesinde olası dört performans ölçüt sonucu Çizelge 3.1’de verilmiştir.

Çizelge 3.1. Karmaşıklık matrisi

Karmaşıklık Matrisi		Gerçek	
		Pozitif	Negatif
Tahmin	Pozitif	DP (Doğru Pozitif)	YP (Yanlış Pozitif)
	Negatif	YN (Yanlış Negatif)	DN (Doğru Negatif)

DP: Pozitif örneğin doğru sınıflandırılması işlemidir.

DN: Negatif örneğin doğru sınıflandırılması işlemidir.

YP: Negatif örneğin yanlış sınıflandırılması işlemidir.

YN: Pozitif örneğin yanlış sınıflandırılması işlemidir.

Doğruluk oranı, veri setinde her bir örneğin sınıf etiketlerinin sınıflandırılmasında algoritmanın performans değerlendirmesi doğrulukla hesaplanır. Doğruluk hesabı Denklem 3.1’de gösterilmektedir (Polat, 2017).

$$\text{Doğruluk} = \frac{(DP+DN)}{DP+YP+DN+YN} \quad (3.1)$$


Doğru pozitif oranı, sınıflayıcıya göre gerçek pozitif olanların ne kadarının pozitif sınıf olarak etiketlendiğini gösterir. Duyarlılık hesabı Denklem 3.2’de gösterilmektedir (Polat, 2017).

$$\text{Doğru Pozitif Oranı} = \frac{DP}{DP+YN} \quad (3.2)$$

$$\text{Yanlış Pozitif Oranı} = \frac{YP}{YP+DN} \quad (3.3)$$

Şekil 3.10’da ROC eğrisi, farklı eşik değerleri için doğru ve yanlış pozitiflik oranlarının, yatay ve dikey ekseninde yer aldığı bir eğridir (Metz, 2006). Kısaca


özetlemek gerekirse; sol üst köşeye en yakın olan ROC eğrisini veren test en kullanışlı test olarak bilinmektedir (Dirican, 2001). Şekil 3.10'da ki diagonal eğrinin üstünde kalan ve sol üst köşeye yaklaşan ROC eğrisinde x ve y sınıflandırıcılarından, sınıflandırma performansı başarısı olarak x daha başarılı kabul edilmektedir.



Şekil 3.10. ROC eğrisi (Lane, 2017)

3.6. CNN derin öğrenme modeli

CNN evrimsel ağ modellerindedir. Şekil 3.11'de görüldüğü gibi evrimsel ağlar bir görüntü verisinin çıktısından tek bir sınıf etiketi oluşturan sınıflandırma yöntemidir. Bunun yanısıra, birçok görsel olarak yapılan işlemlerde ve medikal görüntü işlemede, her piksel için bir sınıf olduğunu belirten etiket atamak gerekir (Ronneberger, 2015).



Şekil 3.11. Önerilen CNN mimarisi (Kurita, 2017)

Bir Konvolüsyonlu Sinir Ağı (CNN) en düşük ön işleme sahip görüntülerden görsel içerikleri doğrudan tanımlamak için tasarlanmış çok katmanlı bir sinir ağı türüdür


(Şeker, 2017). Şekil 3.11’de görüldüğü gibi görüntü verisini ilk katmana ilettiğimizde algoritma bize bir aktivasyon haritası olarak sonuç döndürür. Evrişim katmanındaki filtreler, öğrenme sayısını artırmak için giriş görüntüsünden özellikleri çıkarır. Her filtre, doğru tahmine yardımcı olmak için farklı bir özellik sonucu vermektedir. Daha sonra parametre sayısını en aza indirmek için havuz katmanları ağa eklenir. Tahmin sonucu yapılmadan önce birkaç tane evrişim katmanı ve havuzlama katmanı eklenir. Evrişim katmanı, özelliklerin çıkarılmasına yardımcı olur. Ağda daha iç kısma indiğimizde, çıkarılan özelliklerin normal bir ağa kıyasla daha belirgin özellikte olduğu sonucu görülmektedir. Havuzlama katmanından bir sonraki adım düzleştirmedir. Düzleştirme (Flatten katmanı), toplanmış tüm özellik haritası matrisini tek bir sütuna çevirmeyi içerir ve sinir ağını beslemek için ağa eklenir. Bir sonraki adım, Keras'taki Dense işlevini kullanarak oluşan katmanı sinir ağının girişi olarak kullanmaktır. İlk parametre, gizli katmandaki düğümlerin sayısıdır. Boyutların sayısı arttıkça, daha fazla kaynağın model için uyması gerekmektedir. İkinci parametre aktivasyondur. ReLu aktivasyon fonksiyonunu tercihen çoğunlukla gizli katmanda kullanılır (Mwiti,2018). Daha sonra ağırlıkların yarısını düşüren bir Dropout katmanı eklenmektedir. Dropout katmanının eklenmesinin sebebi overfitting’i (aşırı uyum) engellemektir (Genç,2016). Aşırı uyum, yapılan modelin eğitim örneğini ezberlediği, fakat test örneği üzerinde zayıf öğrenme oranı sonucu verdiği durumdur. CNN'deki çıkış katmanı, diğer katmanlardan gelen giriş parametrelerinin istenilen sınıf sayısına dönüştürülmek üzere gönderilen bağlanmış bir katmandır (FC-Full Connection Layer). Sonraki adımda çıktı katmanı, hata üretimi için ile karşılaştırılır. Ortalama kare kaybını hesaplamak için bağlı çıktı katmanında bir kayıp fonksiyonu tanımlanmaktadır. CNN modelinin derlenme aşamasında üç parametre kullanılır: optimizer, loss ve metrics parametreleridir. Optimizer, öğrenme oranını kontrol eden bir parametredir. Optimizer olarak Adam parametresi kullanılmıştır. Adam çoğunlukla tercih edilen iyi bir optimize edicidir. Adam eğitim boyunca ağda öğrenme oranını ayarlamaktadır (Allibhai, 2018).

3.7. DNN derin öğrenme modeli

DNN’ler ikiden fazla katmana sahip bir sinir ağıdır. DNN derin öğrenme modelinin, CNN derin öğrenme modelinden farkı ilk katmandan sonraki havuzlama katmanından sonra gizli katman sayısı bir eksiltilir ve bu durum for döngüsü ile tekrarlanmaktadır.


Gizli katman sayısı bittikten sonra düzleştirme işlemi yapılır ve CNN modelinden çok daha fazla sayıda katmana sahip bir model elde edilir.

Şekil 3.12’de görüldüğü gibi her DNN katmanı, evrişim, havuzlama ve normalizasyon gibi bir CNN algoritması adımlarına benzer uygulanabilecek işlemler gerçekleştirir. Bu derin öğrenme modelinde gizli katmanların sayısının daha fazla olması dışında, diğer sinir ağları ile aynı yapıya sahiptir. Şekil 3.12’de görüldüğü gibi DNN mimarisi 8 katmandan oluşmaktadır. Katmanlardan her biri bir tane evrişim, maksimum havuzlama ve normalizasyon aşamalarının bir türevlerini içermektedir. Fakat son üç katman tamamen birbirine bağlanmış durumdadır.



Şekil 3.12. DNN derin öğrenme mimarisi (Jordan, 2018)

Şekil 3.13’de görüldüğü gibi, DNN derin öğrenme modeli, giriş olarak piksel değerlerini alır ve katmanlar arasında ileriye doğru bilgi iletir, model nöronları her bir katmanda art arda belirli aktivasyon değerleri ile aktive edilir (Cichy, 2016). DNN verileri karmaşık yollarla işlemek için karmaşık matematiksel modellemeyi kullanır (Ali, 2018).

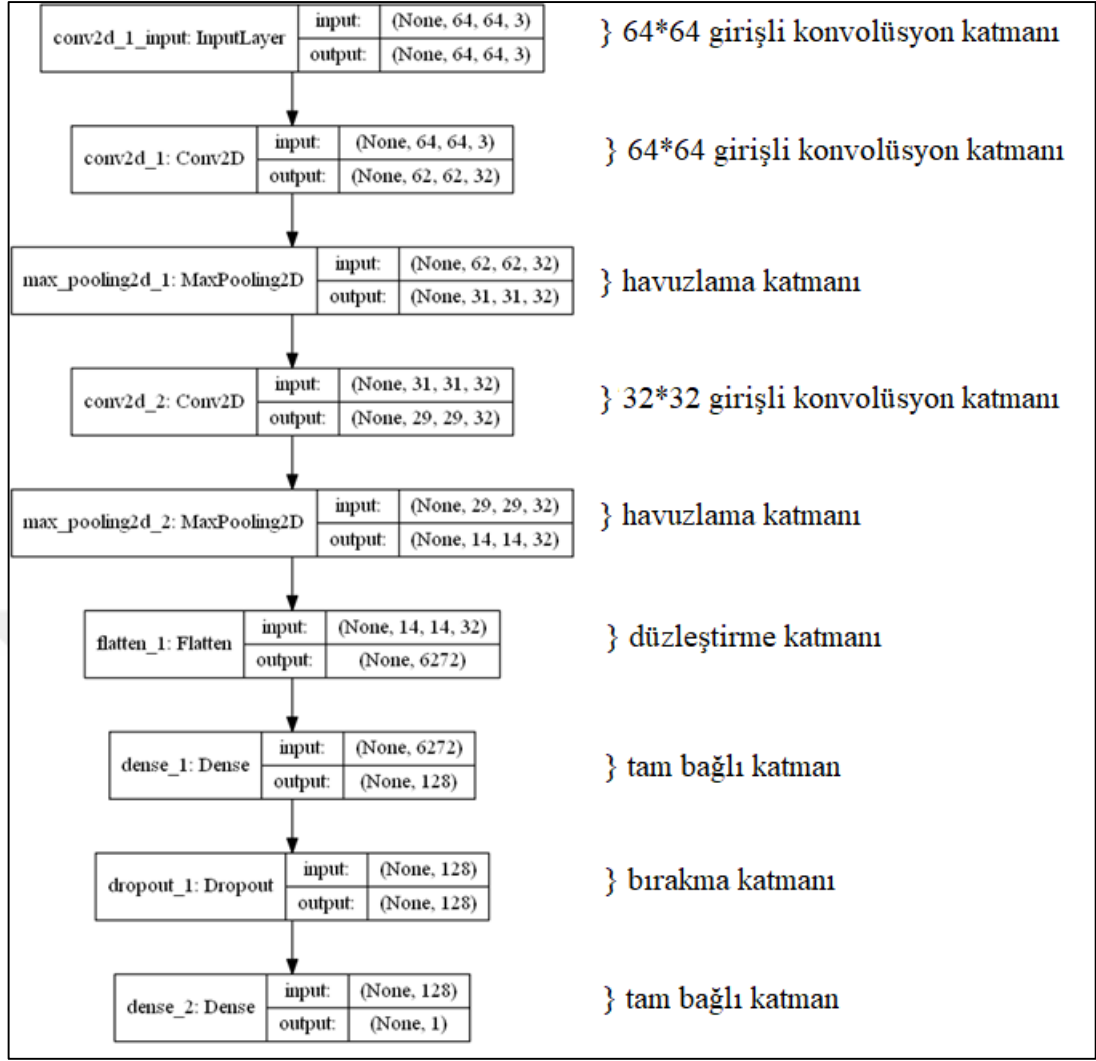


Şekil 3.13. DNN'deki CNN katmanı (Tu, 2017)

4. BULGULAR VE TARTIŞMA

Nükleer tıp alanda çalışan doktorlar, gün içinde çok fazla BT taraması görüntüsünü izlemekten yorulma durumundadır. Yapılan araştırmalar neticesinde BT görüntülerini inceleyen bir doktorun yorgunluğunun, bu taramaları değerlendirirken yapılabilecek hata riskini arttırdığını göstermektedir (Demirkazık, 2014). BT taramasında insan vücudunun tüm kesiti alındığı için birçok görüntü, doktorlar için incelenmesi bir anlam ifade etmemektedir. 200-300 görüntü için sadece üç BT taraması yapılması hastanın kanserin hangi evresinde olduğunu göstermeye yetecektir.

Yapılan çalışmada doktorların bir tümörü bulunan bir hastada, tedavi sürecinde ilk birkaç hafta içinde bir biyopsi yapması veya yeniden BT taramasına girip girmeyeceğine ilişkin karar alma sürecine yardımcı bir derin öğrenme modeli oluşturulmuştur. Yapılan çalışmada Nvidia 1050 Ti GTX ekran kartı, 8 GB RAM, intel i5 işlemcili bilgisayar kullanılmıştır. Önerilen CNN modeli için eğitim süresi akciğer BT verileri için 10 epoch adımıyla toplamda 1 saat 15 dakika sürmüştür. CNN mimarisinde öğrenilen toplam parametre sayısı 813,217'dir. Akciğer görüntülerinin CNN derin öğrenme mimarisi ile yapılan eğitim katmanların özeti Çizelge 4.1'de katmanların birbirine bağlanma durumu Şekil 4.1'de verilmiştir.



Şekil 4.1. Keras ile oluşturulan CNN modeli

Çizelge 4.1. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan CNN model özeti


Layer (type)	Output Shape	Param #	
conv2d_12 (Conv2D)	(None, 62, 62, 32)	896	} Konvolüsyon Katmanı
max_pooling2d_4 (MaxPooling2D)	(None, 31, 31, 32)	0	} Havuzlama Katmanı
conv2d_13 (Conv2D)	(None, 29, 29, 32)	9248	} Konvolüsyon Katmanı
max_pooling2d_5 (MaxPooling2D)	(None, 14, 14, 32)	0	} Havuzlama Katmanı
flatten_1 (Flatten)	(None, 6272)	0	} Düzleştirme Katmanı
dense_1 (Dense)	(None, 128)	802944	} Tam Bağlı Katman
dropout_2 (Dropout)	(None, 128)	0	} Bırakma Katmanı
dense_2 (Dense)	(None, 1)	129	} Tam Bağlı Katman

Total params: 813,217

Trainable params: 813,217

Non-trainable params: 0

DNN mimarisinde öğrenilen toplam parametre sayısı 3,723,385'dir. Akciğer görüntülerinin DNN derin öğrenme mimarisi ile yapılan eğitim katmanların bağlanma şekli Şekil 4.2'de ve katmanların özeti Çizelge 4.2'de verilmiştir. Önerilen DNN mimarisi birbirine benzer şekilde iç içe geçmiş konvolüsyonel ve havuzlama gibi toplamda 50 katmandan oluşmaktadır. Şekil 4.2 ve Çizelge 4.2'de önerilen DNN mimarisinin son 8 katmanı verilmiştir. Önerilen DNN modeli tüm katmanların özet ve bağlanma şekilleri Ek-A ve Ek-B'de verilmiştir.



Şekil 4.2. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan DNN modelinin katmanlarının bağlanma şekli

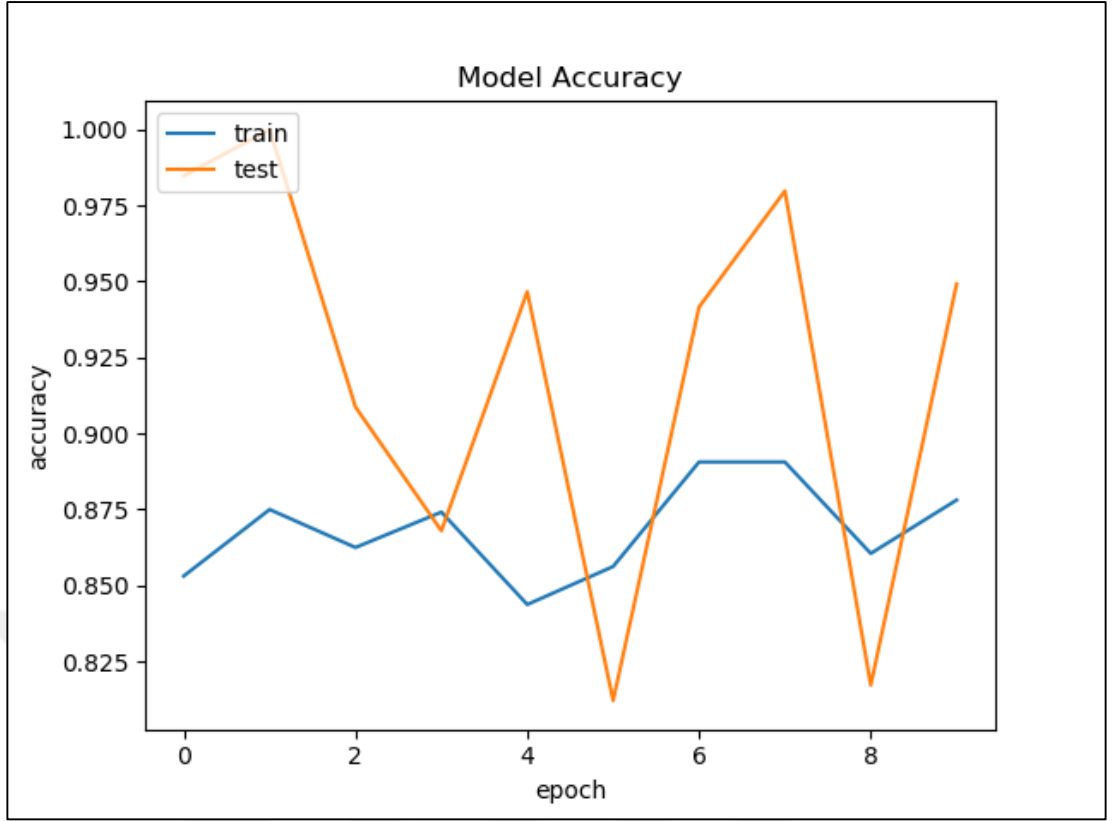
Çizelge 4.2. Akciğer kanseri BT görüntülerini sınıflandırma için oluşturulan DNN model özeti

Layer (type)	Output Shape	Param #	
↓			
activation_185 (Activation)	(None, 63, 63, 40)	0	} 64*64 aktivasyon katmanı
dense_195 (Dense)	(None, 63, 63, 40)	1640	} Tam bağlantılı katman
activation_186 (Activation)	(None, 63, 63, 40)	0	} 64*64 aktivasyon katmanı
conv2d_6 (Conv2D)	(None, 61, 61, 32)	11552	} konvolüsyonel katmanı
max_pooling2d_6 (MaxPooling2)	(None, 30, 30, 32)	0	} Havuzlama katmanı
flatten_3 (Flatten)	(None, 28800)	0	} Düzleştirme katmanı
dense_196 (Dense)	(None, 128)	3686528	} Tam bağlantılı katman
dense_197 (Dense)	(None, 1)	129	} Tam bağlantılı katman
Total params: 3,723,385			
Trainable params: 3,723,385			
Non-trainable params: 0			


Çizelge 4.3. Uygulanan derin öğrenme modelleri

Derin Öğrenme Modelleri	Parametre Sayısı	Eğitim Süresi	Doğruluk Oranları
CNN Modeli	813,217	1 saat 15 dakika	% 98.48
DNN Modeli	3,723,385	4 saat 13 dakika	% 93.65

Oluşturulan CNN modelin görüntü işleme yapılmış akciğer BT görüntüleri için doğruluk ve kayıp oranları Şekil 4.3 ve Şekil 4.4’de gösterilmiştir.



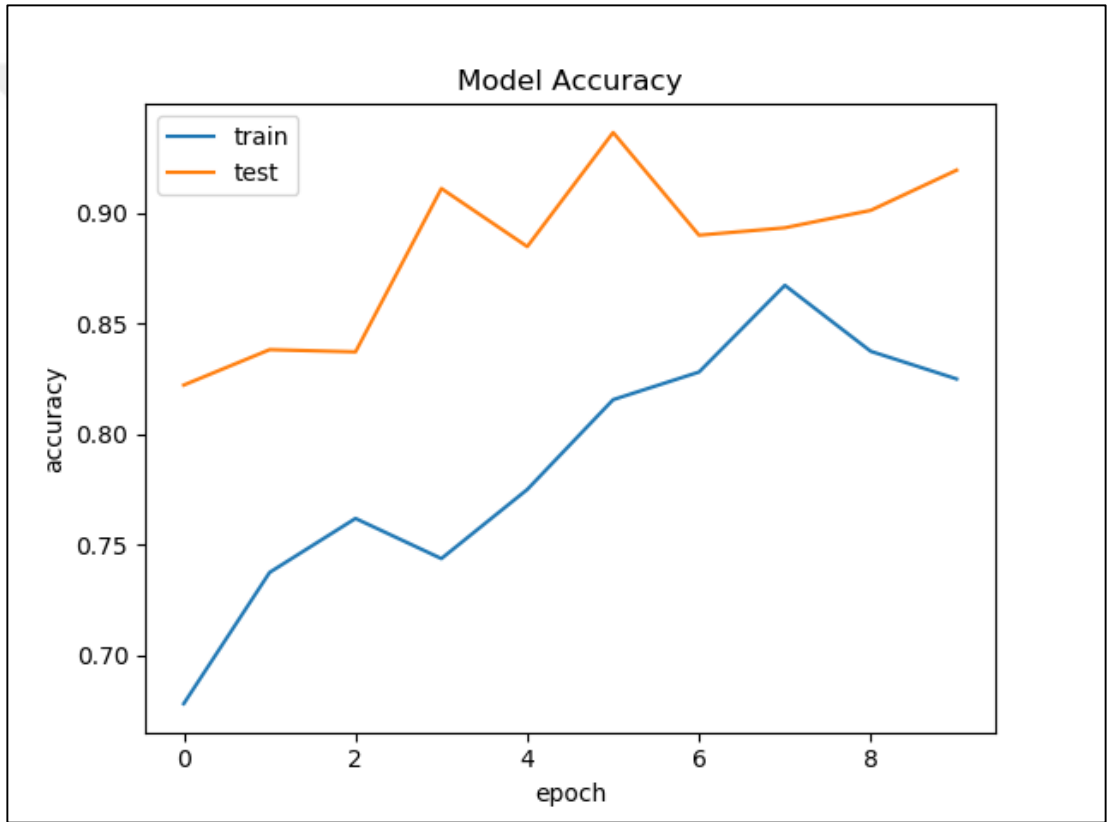
Şekil 4.3. CNN modeli doğruluk oranı




Şekil 4.4. CNN modeli kayıp oranı

Oluşturulan CNN modeli Şekil 4.3’de görüldüğü gibi eğitim ve test verileri için en yüksek doğruluk oranı % 98.48’dir. Bir modelin doğruluğunun 1’e yakın olması o modelin eğitimin doğru olduğunu göstermektedir. CNN modelin Şekil 4.4’de en düşük kayıp oranı % 0.1507 olarak bulunmuştur. Modelin kayıp oranının 0’a yakınsaması o model için eğitimin doğru olduğunu göstermektedir.

Önerilen DNN modeli için eğitim süresi akciğer BT verileri için, GTX 1050Ti ekran kartı, 8 GB ram bulunan bilgisayar için 10 epoch adımında toplamda 4 saat 13 dakika sürmüştür. Oluşturulan DNN modelin görüntü işleme yapılmış akciğer BT görüntüleri için doğruluk ve kayıp oranları Şekil 4.5 ve Şekil 4.6’da gösterilmiştir.



Şekil 4.5. Önerilen DNN model için doğruluk oranı



Şekil 4.6. Önerilen DNN model için kayıp oranı

Oluşturulan DNN modeli Şekil 4.5’de görüldüğü gibi eğitim ve test verileri için en yüksek doğruluk oranı % 93.65’dir. DNN modelin Şekil 4.6’da en düşük kayıp oranı % 0.2022 olarak bulunmuştur.

Akciğer BT tarama görüntülerinin sınıflandırılması için CNN’deki eğitim fazının iyi huylu ve kötü huylu tümörler için kayıp oranı olduğu gibi DNN mimarisindeki eğitim aşamasında da kayıp gerçekleşmiştir. Her iki algoritmadaki eğitim kaybının değerleri, eğitim sonunda en düşük değeri elde etmek için sık sık değiştirilmesi gerekir. CNN mimarisindeki kayıp oranı, sürekli değişim göstermektedir. CNN’in eğitim sonunda, değer kaybı 0.1555’e düşmüştür. DNN’deki eğitim kaybı sürekli değişiklik göstermiş ve eğitim aşaması sonunda 0.2207’e düşmüştür. Hem CNN hem de DNN, eğitim ile kayıp oranlarını en aza indirerek örnekleri eğitebilir hale gelmiş ve her iki mimaride kayıp oranı sifıra yakın olarak elde edilmeye çalışılmıştır.

Literatürdeki diğer yöntemlerin çoğunun farklı akciğer BT tarama veri setlerinde kullanılmasına rağmen, bu yüksek lisans tez çalışmasında, kullanılan derin öğrenme mimarileri, akciğer BT tarama görüntülerinin sınıflandırılması için literatürde

kullanılan diğer yöntemlerden daha yüksek doğruluk oranına sahip olmuştur. Diğer yöntemlerle yapılan çalışma arasındaki karşılaştırma Çizelge 4.4’de verilmiştir.

Çizelge 4.4. Literatürdeki diğer çalışmalar ile karşılaştırma tablosu

Veri seti	Derin Öğrenme Modeli	Metot	Doğruluk oranı	Kaynak
LIDC & IDRI	CNN	DNN	82.10	Gruetzemacher(2016)
LIDC & IDRI	CNN	DNN, SAE	84.15	Song (2017)
ILD	CNN	LeNet, AlexNet, VGG	85.61	Anthimopoulos (2016)
Data Science ve Kaggle	CNN	U-net	86.60	Alakwaa(2017)
Oluşturulan Veri seti	CNN	CNN	98.48	Önerilen modelde elde edilen sonuç
Oluşturulan Veri seti	CNN	DNN	93.65	Önerilen modelde elde edilen sonuç

SONUÇ VE ÖNERİLER

Yapılan yüksek lisans çalışmasında, akciğer kanseri hastalığının yüksek doğruluk oranları ile sınıflandırılması, kanserin teşhisi ve tedavi açısından önemli bir etmendir. Bu çalışma Süleyman Demirel Üniversitesi Nükleer Tıp Anabilim Dalı'dan 38 farklı hastadan alınan iyi ve kötü tümör bulunan BT görüntüleri veri seti olarak kullanılmıştır. Veri seti olarak kullanılan BT görüntülerinin sınıflandırılması için CNN ve DNN derin öğrenme modelleri önerilmiştir.

Görüntü işlemeye tabii tutulan BT görüntülerine histogram eşikleme uygulanmış görüntüdeki tümörlü bölgelerin görünürlüğü artırılmıştır. Histogram eşikleme yapılmış görüntüler %80'i eğitim, %20'si test olacak şekilde ayrılmıştır. Görüntü işleme uygulanan BT görüntülerine CNN derin öğrenme modeli uygulandığında % 98.48 doğruluk oranı bulunmuştur. Kullanılan diğer yöntem olan DNN derin öğrenme modelinde ise % 93.65 doğruluk oranı bulunmuştur.

Sonuç olarak, yapılan yüksek lisans tez çalışmasında, akciğer BT tarama görüntülerinin CNN derin öğrenme modeli kullanılarak sınıflandırılmasıyla, akciğer kanserinin erken teşhisi aşamasında doktorlara yardımcı bir karar destek sisteminin ilk aşaması olan derin öğrenme modelinin için örnek bir sistem geliştirilmiştir.

Önerilen sistem ileri ki çalışmalarda kanserli dokuların bulunduğu yerin tespiti için ön adım niteliğindedir. Oluşturulacak olan bir CAD sistemiyle doktorlara yardımcı bir arayüz programı yapılması planlanmaktadır. Arayüz programında kanserli dokuların tespitinin yanısıra dokunun boyutu, hacmi gibi tümöre özgü niteliksel özelliklerin sonucunun sunulması düşünülmektedir.

İleriye yönelik yapılacak çalışmalarda, akciğer BT görüntüleri için, uygulanacak derin öğrenme modellerinde veri seti hazır bulunmuyorsa, öncesinde görüntü işleme adımı yapılarak problemin çözümünü kolaylaştırması ve yeni sınıflandırma yöntemlerinin problemin çözümünde kullanılması uygun olacağı düşünülmektedir.

KAYNAKLAR

- Açık, S., (2017) Python: glob Modülü, Erişim Adresi: <https://medium.com/@sddkal/python-glob-mod%C3%BCI%C3%BC-c422e14cbafe> Erişim Tarihi: 25.02.2019
- Agarwal, P., (2018) Smoothing in Digital Image Processing, Erişim Adresi: <https://www.slideshare.net/hiiampallavi15/smoothing-in-digital-image-processing> Erişim Tarihi: 20.05.2019
- Akciğer kanserinde tanı ve evreleme, (2008) Erişim Adresi: <https://www.msxlab.org/forum/tip-bilimleri/185053-akciğer-kanseri.html> Erişim Tarihi:19.12.2017
- Alakwaa, W., Nassef, M., & Badr, A. (2017). Lung cancer detection and classification with 3D convolutional neural network (3D-CNN). *Lung Cancer*, 8(8).
- Ali, A.,A., Knowledge Discovery In Health Domain Using Deep Neural Network Algorithms, Yüksek Lisans Tezi, Gaziantep Üniversitesi, Elektrik ve Bilgisayar Mühendisliği, 2018.
- Allibhai, E., (2018) Building a Convolutional Neural Network (CNN) in Keras, Erişim Adresi:<https://towardsdatascience.com/building-a-convolutional-neural-network-cnn-in-keras-329fbbadc5f5> Erişim Tarihi: 12.05.2019
- Ambrosini, R. D., Wang, P., & O'dell, W. G. (2010). Computer- aided detection of metastatic brain tumors using automated three- dimensional template matching. *Journal of Magnetic Resonance Imaging*, 31(1), 85-93.
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. *IEEE transactions on medical imaging*, 35(5), 1207-1216.
- Bektaş, B., & Babur, S. (2016, October). Machine learning based performance development for diagnosis of breast cancer. In *Medical Technologies National Congress (TIPTEKNO)*, 2016 (pp. 1-4). IEEE.
- Budhiraja, A., (2016) Dropout in (Deep) Machine Learning, Erişim Adresi: <https://medium.com/@amarbudhiraja/https-medium-com-amarbudhiraja-learning-less-to-learn-better-dropout-in-deep-machine-learning-74334da4bfc5> Erişim Tarihi:03.05.2019
- Chen, K., (2017) How to interpret “loss” and “accuracy” for a machine learning model, ErişimAdresi:<https://stackoverflow.com/questions/34518656/how-tointerpret-loss-and-accuracy-for-a-machine-learning-model> Erişim tarihi: 20.05.2019
- Cichy, R. M., Khosla, A., Pantazis, D., Torralba, A., & Oliva, A. (2016). Comparison of deep neural networks to spatio-temporal cortical dynamics of human visual object recognition reveals hierarchical correspondence. *Scientific reports*, 6, 27755.

- Ciampi, F., Chung, K., Van Riel, S. J., Setio, A. A. A., Gerke, P. K., Jacobs, C.,... & Pastorino, U. (2017). Towards automatic pulmonary nodule management in lung cancer screening with deep learning. *Scientific reports*, 7, 46479.
- Cournapeau, D. vd., (2007) Scikit-Learn, Erişim Adresi: <https://scikit-learn.org/stable/about.html#> Erişim Tarihi: 26.02.2019
- Çağırıcı, E., (2019) Pet- Bt nedir? Erişim Adresi: <https://www.turkiye-rehberi.net/pet-ct-nedir> Erişim tarihi: 20.05.2019
- Çevik, A., Eyüpoğlu B.M., 2011. Doku Anomalisi İçeren Beyin MR İmgeleri Üzerinde Mumford -Shah Tabanlı Bölütleme. EMO Bilimsel Dergi, Cilt 1, Sayı 2, Syf 103-107.
- Dandıl, E., 2017. Implementation and comparison of image segmentation methods for detection of brain tumors on MR images. Computer Science and Engineering (UBMK), 2017 International Conference on.
- Dastjerdi- Moghadas, H., Ahmadzadeh, M., Karami, E., Karami, M., Samani, A.,2017. Lung BT image based automatic technique for COPD GOLD stage assessment. Expert Systems With Applications 85, 194–203.
- Demirkazık B., F., 2014. Akciğer Kanseri Bilgisayarlı Tomografi ile Tarama: Güncel Bilgiler. Hacettepe Üniversitesi Tıp Fakültesi, Radyoloji Anabilim Dalı, Ankara, Türkiye
- Deperlioğlu, Ö., & Köse, U. (2018, October). Diagnosis of Diabetic Retinopathy by Using Image Processing and Convolutional Neural Network. In 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) (pp. 1-5). IEEE.
- Dirican, A. (2001). Tanı testi performanslarının değerlendirilmesi ve kıyaslanması. *Cerrahpaşa Tıp Dergisi*, 32(1), 25-30.
- Doğan Buket, Zeki Öğretici Sistemlerde Veri Madenciliği Kullanılması, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul,2006
- Doğan, B., Demir, Ö., Çalık Kazdal, S., 2016. Computer-Aided Detect. of Brain Tumors Using Morph. Reconstruction. Uludağ University Journal of The Faculty of Engineering, Vol. 21, No. 2.
- Doxygen, 2015, OpenCv Open Source Computer Vision, Erişim Adresi: <https://docs.opencv.org/3.1.0/> Erişim Tarihi: 26.02.2019
- Dunet, A., Beigelman-Aubrya, C., Brun, A.L., 2016. BT imaging in pre-therapeutic assessment of lung cancer. *Diagnostic and Interventional Imaging*. 97, 973—989
- Ekşi, Z., Dandıl, E., & Çakıroğlu, M. (2012, April). Computer aided bone fracture detection. In 2012 20th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

- Erbaş, G. Adım Adım Akciğer Bilgisayarlı Tomografisi, Gazi Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı, 2011
- Escontrela, A., (2018) Convolutional Neural Networks from the ground up, Erişim Adresi:<https://towardsdatascience.com/convolutional-neural-networks-from-the-ground-up-c67bb41454e1> Erişim Tarihi: 20.05.2019
- Felzenszwalb, P. F., & Huttenlocher, D. P. (2004). Efficient graph-based image segmentation. *International journal of computer vision*, 59(2), 167-181.
- Fıçıcı Ö., C., 2016. MR Görüntülerinde Bulunan Anormal Belirlenmesi Ve Hacimlerinin Hesaplanması. Ankara Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.74 s. Ankara
- Firelord Phoenix, (2018) Max-pooling / Pooling, Erişim Adresi: https://computersciencewiki.org/index.php/Max-pooling/_/Pooling Erişim Tarihi: 20.05.2019
- Genç, Ö., (2016) Keras İle Derin Öğrenmeye Giriş, Erişim Adresi: <https://medium.com/turkce/keras-ile-derin-%C3%B6%C4%9Frenmeye-giri%C5%9F-40e13c249ea8> Erişim Tarihi: 12.05.2019
- Gezer M., Python ile Görüntü İşlemede Örnek Bir Uygulama, 1. Baskı, 65-80s., SAKARYA, Aralık 2017.
- Gruetzemacher, R., & Gupta, A. (2016). Using deep learning for pulmonary nodule detection & diagnosis.
- Gulli, A., & Pal, S. (2017). *Deep Learning with Keras*. Packt Publishing Ltd.
- Hamdi, E., (2015) Medikal Görüntü İşlemenin Amacı, Erişim Adresi: <https://slideplayer.biz.tr/slide/3785909/> Erişim Tarihi: 10.02.2019
- Hastie, T., Tibshirani, R., Friedman, J., Hastie, T., Friedman, J. and Tibshirani, R.: 2009, *The elements of statistical learning*, Vol. 2, Springer.
- Hunter, J., Dale, D., Firing, E., & Droettboom, M. *Matplotlib-development-team*. matplotlib., Chicago, 2017
- Jacobs, C., van Rikxoort, E. M., Scholten, E. T., de Jong, P. A., Prokop, M., Schaefer-Prokop, C., & van Ginneken, B. (2015). Solid, part-solid, or non-solid?: classification of pulmonary nodules in low-dose chest computed tomography by a computer-aided diagnosis system. *Investigative radiology*, 50(3), 168-173.
- Jordan, J., (2018) Common architectures in convolutional neural networks. Erişim Adresi: <https://www.jeremyjordan.me/convnet-architectures/> Erişim Tarihi: 22.05.2019
- Kahraman, M., 2017. Akciğer BT Görüntülerinin Bölütlenmesi ve Matlab ile Nodül Tespiti. Yenyüzyıl Üniversitesi Mühendislik Mimarlık Fakültesi, Elektrik Elektronik Mühendisliği. Bitirme Tezi. 61s. İstanbul

- Karaçavuş, S., Kayaaltı, Ö., Yılmaz, B., İçer, S., Kaya, E., Ayyıldız, O., 2014. PET/BT Görüntülerinden Doku Analizi Yöntemiyle Elde Edilen Parametrelerin Küçük Hücreli Dışı Akciğer Kanseri Evrelemesinde Kullanılması. Biyomedikal Görüntü İşleme ve Yapay Zekâ Uygulamaları. Tıp Teknolojileri Ulusal Kongresi. Kapadokya.
- Karakeçi E., 2011. Open Computer Vision (OpenCv), Erişim Adresi: <https://erkankarakeci.wordpress.com/?s=opencv> Erişim Tarihi: 20.01.2019
- Kızrak, A., (2018) DERİNE DAHA DERİNE: Evrişimli Sinir Ağları, Erişim adresi: <https://medium.com/deep-learning-turkiye/deri%CC%87ne-daha-deri%CC%87ne-evri%5%9Fimli-sinir-a%C4%9Flar%C4%B1-2813a2c8b2a9> Erişim tarihi: 26.02.2019
- Kutukız, M., 2014. Bir Uzman Sistem Yardımıyla Kanser Hücrelerinin Belirlenmesi. Fırat Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi. 70 s. Elazığ.
- Lane, J. E., & Gantley, M. J. (2017). Utilizing Complex Systems Statistics for Historical and Archaeological Data. *Journal of Cognitive Historiography*, 3(1-2), 68-92.
- Lasko, T. A., Bhagwat, J. G., Zou, K. H., & Ohno-Machado, L. (2005). The use of receiver operating characteristic curves in biomedical informatics. *Journal of biomedical informatics*, 38(5), 404-415.
- Matsuki, Y., Nakamura, K., Watanabe, H., Aoki, T., Nakata, H., Katsuragawa, S., & Doi, K. (2002). Usefulness of an artificial neural network for differentiating benign from malignant pulmonary nodules on high-resolution BT: evaluation with receiver operating characteristic analysis. *American Journal of Roentgenology*, 178(3), 657-663.
- Metz, C. E. (2006). Receiver operating characteristic analysis: a tool for the quantitative evaluation of observer performance and imaging systems. *Journal of the American College of Radiology*, 3(6), 413-422.
- Mwiti, D., (2018) Convolutional Neural Networks: An Intro Tutorial, Erişim Adresi: <https://heartbeat.fritz.ai/a-beginners-guide-to-convolutional-neural-networks-cnn-cf26c5ee17ed> Erişim Tarihi: 12.05.2019
- Nielsen, M. A. (2015). *Neural networks and deep learning* (Vol. 25). San Francisco, CA, USA:: Determination press.
- Niki, N., Kawata, Y., & Kubo, M. (2001, June). A CAD system for lung cancer based on BT image. In International Congress Series (Vol. 1230, pp. 631-638). Elsevier.
- Okyay, S., 2016. Beyin Görüntüleme Tekniklerinde Alzheimer Hastalığı Erken Tanı Tahmininde Kullanılması. Anadolu Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi. Eskişehir.

- Özcan Habil, Çok Düşük Çözünürlüklü Yüz İmgelerinde Derin Öğrenme Uygulamaları, Deniz Harp Okullu, Deniz Bilimleri Ve Mühendisliği Enstitüsü, İstanbul, 2014.
- Özkan, İ. N. İ. K., & Ülker, E. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Paul S., (2018) Learn How to Train U-Net On Your Dataset, Erişim adresi: <https://medium.com/coinmonks/learn-how-to-train-u-net-on-your-dataset-8e3f89fbd623>, Erişim tarihi: 21.04.2019
- Polat, H., Mehr, H. D., & Cetin, A. (2017). Diagnosis of chronic kidney disease based on support vector machine by feature selection methods. *Journal of medical systems*, 41(4), 55.
- Polat, H., Mehr, H. D., & Cetin, A. (2017). Diagnosis of chronic kidney disease based on support vector machine by feature selection methods. *Journal of medical systems*, 41(4), 55.
- Radsite, “Consumer Guide to Imaging Modalities Benefits and Risks of Common Medical Imaging Procedures, 2011” Erişim Adresi: <https://radsitequality.com>, Erişim Tarihi: 20.01.2019.
- Rao, P., Pereira, N. A., & Srinivasan, R. (2016, December). Convolutional neural networks for lung cancer screening in computed tomography (BT) scans. In 2016 2nd International Conference on Contemporary Computing and Informatics (IC3I)(pp. 489-493). IEEE.
- Raza, M., Cinquegrana, P., (2018) Artificial Intelligence And Machine Learning, Erişim Adresi: <https://www.qubole.com/blog/deep-learning-the-latest-trend-in-ai-and-ml/> Erişim Tarihi: 09.07.2019
- Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.
- Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.
- Salomon, J., Lung Cancer Detection using Deep Learning, Dublin Institute of Technology, 2018
- Savaş, R., 2015. Akciğer Kanserinde PET/BT. Ege Üniversitesi Tıp Fakültesi, Türk Radyoloji Semineri. S: 326-339. İzmir.
- Song, Q., Zhao, L., Luo, X., & Dou, X. (2017). Using deep learning for classification of lung nodules on computed tomography images. *Journal of healthcare engineering*, 2017.

- Sorokina, K. (2017) Image Classification with Convolutional Neural Networks, Erişim Adresi:<https://medium.com/@ksusorokina/image-classification-with-convolutional-neural-networks-496815db12a8> Erişim Tarihi: 12.05.2019
- STM, (2018) Derin Farklar: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme, ErişimAdresi:https://thinktech.stm.com.tr/uploads/raporlar/pdf/141120181498483_stm_blog_yapay_zeka_makine_ogrenmesi_derin_ogrenme.pdf Erişim Tarihi:24.05.2019
- Sun, W., Zheng, B., & Qian, W. (2016, March). Computer aided lung cancer diagnosis with deep learning algorithms. In *Medical imaging 2016: computer-aided diagnosis* (Vol. 9785, p. 97850Z). International Society for Optics and Photonics.
- Şeker Abdulkadir, Amasyalı Mehmet Fatih, Topluluk Algoritması destekli Yarı Eğitici Öğrenme, 2016
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3), 47-64.
- Teramoto, A., & Fujita, H. (2013). Fast lung nodule detection in chest BT images using cylindrical nodule-enhancement filter. *International journal of computer assisted radiology and surgery*, 8(2), 193-205.
- Tu, F., Yin, S., Ouyang, P., Tang, S., Liu, L., & Wei, S. (2017). Deep convolutional neural network architecture with reconfigurable computation patterns. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 25(8), 2220-2233.
- TÜİK. “Ölüm Nedeni İstatistikleri, 2014”. Erişim Adresi: <http://www.tuik.gov.tr/PreHaberBultenleri.do?id=18855> Erişim Tarihi: 19.12.2017.
- TÜİK. “Yıllara, Yaş Grubu ve Cinsiyete Göre Nüfus Tablosu”. Erişim Adresi: <http://www.tuik.gov.tr/UstMenu.do?metod=temelist> Erişim Tarihi:19.12.2017
- Ural, A.B., 2016. Görüntü İşleme Metotları İle Girişimsel Olmayan Mide Kanserinin Tespit Edilmesi. Gazi Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Wikipedia, Erişim Adresi: <https://en.wikipedia.org/wiki/Scikit-image> Erişim Tarihi: 26.02.2019
- Wikipedia, Erişim Adresi: <https://en.wikipedia.org/wiki/SciPy> Erişim Tarihi: 26.02.2019
- Wikipedia, Erişim Adresi: https://tr.wikipedia.org/wiki/Görüntü_işleme Erişim Tarihi: 10.02.2019
- Wu, J. (2017). Introduction to convolutional neural networks. National Key Lab for Novel Software Technology. Nanjing University. China, 5-23.


EKLER

EK-A Önerilen Dnn modeli katman özeti

EK-B Önerilen DNN modeli katmanlarının özet tablosu



EK-A Önerilen Dnn modeli katman özeti



Şekil A.1. Önerilen DNN modeli katmanlarının bağlanma şekli

EK-B Önerilen DNN modeli katmanlarının özet tablosu

Çizelge B.1. Önerilen DNN modeli katman özeti

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 126, 126, 32)	896
max_pooling2d_1 (MaxPooling2)	(None, 63, 63, 32)	0
activation_1 (Activation)	(None, 63, 63, 32)	0
dense_1 (Dense)	(None, 63, 63, 40)	1320
activation_2 (Activation)	(None, 63, 63, 40)	0
dense_2 (Dense)	(None, 63, 63, 40)	1640
activation_3 (Activation)	(None, 63, 63, 40)	0
dense_3 (Dense)	(None, 63, 63, 40)	1640
activation_4 (Activation)	(None, 63, 63, 40)	0
dense_4 (Dense)	(None, 63, 63, 40)	1640
activation_5 (Activation)	(None, 63, 63, 40)	0
dense_5 (Dense)	(None, 63, 63, 40)	1640
activation_6 (Activation)	(None, 63, 63, 40)	0
dense_6 (Dense)	(None, 63, 63, 40)	1640
activation_7 (Activation)	(None, 63, 63, 40)	0
dense_7 (Dense)	(None, 63, 63, 40)	1640
activation_8 (Activation)	(None, 63, 63, 40)	0
dense_8 (Dense)	(None, 63, 63, 40)	1640
activation_9 (Activation)	(None, 63, 63, 40)	0
dense_9 (Dense)	(None, 63, 63, 40)	1640
activation_10 (Activation)	(None, 63, 63, 40)	0
dense_10 (Dense)	(None, 63, 63, 40)	1640
activation_11 (Activation)	(None, 63, 63, 40)	0
dense_11 (Dense)	(None, 63, 63, 40)	1640
activation_12 (Activation)	(None, 63, 63, 40)	0
dense_12 (Dense)	(None, 63, 63, 40)	1640
activation_13 (Activation)	(None, 63, 63, 40)	0
dense_13 (Dense)	(None, 63, 63, 40)	1640
activation_14 (Activation)	(None, 63, 63, 40)	0
dense_14 (Dense)	(None, 63, 63, 40)	1640
activation_15 (Activation)	(None, 63, 63, 40)	0
dense_15 (Dense)	(None, 63, 63, 40)	1640
activation_16 (Activation)	(None, 63, 63, 40)	0
conv2d_2 (Conv2D)	(None, 61, 61, 32)	11552

max_pooling2d_2 (MaxPooling2 (None, 30, 30, 32))	0
flatten_1 (Flatten)	(None, 28800) 0
dense_16 (Dense)	(None, 128) 3686528
dense_17 (Dense)	(None, 1) 129

Total params: 3,723,385
Trainable params: 3,723,385
Non-trainable params: 0



ÖZGEÇMİŞ

Adı Soyadı : Ayşen Özün Türkçetin

Doğum Yeri ve Yılı : Karaman, 1993

Medeni Hali : Bekar

Yabancı Dili : İngilizce

E-posta : aysenozun@gmail.com

Eğitim Durumu

Lise : Karaman, Karaman Lisesi, 2010

Lisans : SDÜ, Mühendislik Fakültesi, Bilgisayar Mühendisliği

Mesleki Deneyim

SDÜ Keçiborlu MYO 2017-2017

SDÜ Bilgi İşlem Daire Başkanlığı 2018-2019