

**T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MEDİKAL GÖRÜNTÜLER ÜZERİNDE ANALİZ VE SINIFLANDIRMA
YAPMAK İÇİN BİR UYGULAMA TASARIMI**

Şule Beste KAPÇI

**Danışman
Dr. Öğr. Üyesi Turgay AYDOĞAN**

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
ISPARTA- 2020**



© 2020 [Şule Beste KAPÇI]

TEZ ONAYI

Şule Beste KAPÇI tarafından hazırlanan "**Medikal Görüntüler Üzerinde Analiz ve Sınıflandırma Yapmak için Bir Uygulama Tasarımı**" adlı tez çalışması aşağıdaki jüri üyeleri önünde Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü **Bilgisayar Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ** olarak başarı ile savunulmuştur.

Danışman **Dr.Öğr.Üyesi Turgay AYDOĞAN**
Süleyman Demirel Üniversitesi

Jüri Üyesi **Prof.Dr.Ecir Uğur KÜÇÜKSİLLE**
Süleyman Demirel Üniversitesi

Jüri Üyesi **Dr.Öğr.Üyesi Tuna GÖKSU**
Isparta Uygulamalı Bilimler Üniversitesi

Enstitü Müdürü **Doç. Dr. Şule Sultan UĞUR**

TAAHHÜTNAME

Bu tezin akademik ve etik kurallara uygun olarak yazıldığını ve kullanılan tüm literatür bilgilerinin referans gösterilerek tezde yer aldığını beyan ederim.

Şule Beste KAPÇI

Ş.B. Kpç

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER.....	i
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR.....	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	viii
SİMGELER VE KISALTMALAR DİZİNİ	ix
1. GİRİŞ.....	1
2. KAYNAK ÖZETLERİ	5
3. MATERYAL VE YÖNTEM	10
3.1. Görüntü Sıkıştırma Teknikleri.....	10
3.1.1. Kayıpsız görüntü sıkıştırma formatları	11
3.1.1.1. BMP	11
3.1.1.2. PNG.....	11
3.1.1.3. RAW	11
3.1.1.4. GIF.....	12
3.1.2. Kayıplı görüntü sıkıştırma formatları	12
3.1.2.1. JPEG.....	12
3.2. Medikal Görüntü Sıkıştırma.....	13
3.2.1. NIFTI.....	14
3.2.2. ANALYZE.....	14
3.2.3. DICOM	14
3.3. Tıbbi Görüntüleme Teknikleri ve Görüntü Elde Etme Yöntemleri.....	17
3.3.1. Bilgisayarlı tomografi (BT)	17
3.3.2. Manyetik rezonans (MR)	18
3.3.3. Ultrasonografi.....	18
3.3.4. PET	19
3.4. Görüntü İşleme	20
3.4.1. Görüntü işleme filtreleri	21
3.4.1.1. Sobel filtresi.....	21
3.4.1.2. Gama dönüşümü	22
3.4.1.3. Medyan filtresi.....	23
3.4.1.4. Minimum ve Maksimum filtreleri	24
3.4.1.5. Gauss filtresi	24
3.4.1.6. Histogram eşitleme.....	25
3.4.1.7. Aşındırma (Erosion) ve Genişletme (Dilation) işlemleri	27
3.4.1.8. Açma (Opening) ve Kapama (Closing) işlemleri.....	27
3.4.2. Görüntü işleme araçları	28
3.5. Yapay Zekâ	29
3.5.1. Derin öğrenme ve derin öğrenme mimarileri	30
3.5.1.1. Derin sinir ağları	30
3.5.1.2. Derin inanç ağları	30
3.5.1.3. Derin oto-kodlayıcılar.....	31
3.5.1.4. Derin boltzmann makinesi.....	31
3.5.1.5. Evrişimli sinir ağları	31
3.5.2. Python kütüphaneleri	32

3.5.2.1. Tkinter	32
3.5.2.2. NumPy.....	32
3.5.2.3. Pandas.....	32
3.5.2.4. Matplotlib	33
3.5.2.5. Imageio	33
3.5.2.6. Scikit-image	33
3.5.2.7. SciPy.....	33
3.5.2.8. Pydicom.....	33
3.5.2.9. OpenCv.....	34
3.5.2.10. Glob.....	34
3.5.2.11. Keras	34
3.5.2.12. PIL	34
3.5.2.13. OS	35
3.5.2.14. TensorFlow	35
4. ARAŞTIRMA BULGULARI.....	36
5. TARTIŞMA VE SONUÇLAR.....	46
KAYNAKLAR.....	50
ÖZGEÇMİŞ.....	56

ÖZET

Yüksek Lisans Tezi

MEDİKAL GÖRÜNTÜLER ÜZERİNDE ANALİZ VE SINIFLANDIRMA YAPMAK İÇİN BİR UYGULAMA TASARIMI

Şule Beste KAPÇI

Süleyman Demirel Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Turgay AYDOĞAN

Yapay zekâ birçok alanda başarılı uygulamalarıyla hayatımıza girmiştir. Sağlık alanında yapay zekâ kullanımının önemi gün geçtikçe daha çok konuşulmaktadır. Özellikle hastalık tanı ve teşhisinde yapılan akademik çalışmalar incelendiğinde birçok hastalıkta uzmanların yapay zekâdan faydalandığı görülmüştür. Bu tanı ve teşhisler metinsel ve sayısal ifadelerin olduğu veri setlerinden de yapılabileceği gibi, doğrudan medikal görüntülerden de yapılabilmektedir. Medikal görüntüler elde edilirken en çok tercih edilen görüntü dosya biçimi DICOM'dur. Bu dosya biçimi içerisinde hem hastaya ait bilgiler hem de medikal görüntü yer almaktadır. DICOM görüntü formatı özel programlarla görüntülenebilmektedir. Bu özel programları kullanmadan DICOM görüntüleri açabilmek için dosya formatının değiştirilmesi gerekmektedir. Literatürde bulunan çalışmalar incelendiğinde üzerinde çalışılan görüntülerde istenilen görsel verilerin ön plana çıkarılması ve görüntüde bulunan görüntülerin yok edilmesi için bazı ön işlemlerin uygulandığı görülmüştür. Bu işlem sonucunda çalışmaya hazır hale gelen görüntülerde yapay zekâ algoritmalarının uygulanması ile sonucun başarısında artış olması amaçlanmıştır.

İnsan gözünden kaçan küçük noktalar tıpta hastalık tanı ve teşhisi için çok önemli olabilmektedir. Bilim insanlarının insan hatasını en aza indirmek için yaptığı çalışmalar olumlu sonuçlar vermiştir. Günümüzde medikal alanda yapılan yapay zekâ çalışmaları büyük ölçüde artmıştır ve buna bağlı olarak farklı disiplinlerin birlikte çalışması zorunlu hale gelmiştir. Görüntü elde etme, görüntü işleme ve görüntü veri setleri üzerinde işlem yapan birçok araç vardır. Yapay zekâ işlemleri için programlama bilgisi olan araştırmacılar kendi sistemlerini geliştirirler. Bu konuda bilgisi olmayan araştırmacılar ise farklı disiplinlerden yardım almak zorundadır. Fakat bu durum bazen zaman kaybının meydana gelmesine ve ekip çalışmalarında iletişim eksikliklerinin yaşanmasına sebep olmaktadır. Ayrıca disiplinler arası bilgi eksikliği çalışmalar sırasında sorunlar yaratabilmektedir.

Bu tez çalışmasında farklı disiplinlerde çalışan fakat medikal görüntülerde işlem yapmak isteyen ve yazılım bilgisi olmayan araştırmacılara yönelik bir uygulama

geliştirilmiştir. Bu yazılım ile kullanıcılar ister DICOM dosya biçiminde, isterse farklı görüntü dosya biçiminde sahip oldukları medikal görüntüleri açabilir, görüntüleyebilir, görüntüler üzerinde görüntü işleme filtrelerini uygulayabilir ve uygulamada sunulan yapay zekâ algoritmalarını çalıştırabilirler. Böylelikle kullanıcılar sadece bir program kullanarak medikal görüntülerde yapay zekâ algoritmalarının uygulanmasını gerçekleştirebilmektedirler.

Anahtar Kelimeler: Medikal Görüntü, Görüntü İşleme, Yapay Zekâ

2020, 56 sayfa



ABSTRACT

M.Sc. Thesis

AN APPLICATION DESIGN FOR ANALYSIS AND CLASSIFICATION ON MEDICAL IMAGES

Şule Beste KAPÇI

**Süleyman Demirel University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Asst. Prof. Dr. Turgay AYDOĞAN

Artificial intelligence has entered our lives with its successful applications in many fields. The importance of using the artificial intelligence in healthcare field is spoken day by day. Especially when the academic studies in the diagnosis and identification of the disease are examined, it is seen that the experts benefit from artificial intelligence in many diseases. These diagnoses and identifications can be done with data sets with textual statements, or directly from medical images. The most preferred image file format while obtaining medical images is DICOM. This file format includes both patient information and medical image. DICOM image file format can be displayed with specific applications. In order to open DICOM images without using these specific software, the file format must be changed. When the studies took part in the literature are examined, it is seen that some pre-treatments have been applied to highlight the intended visual data in current images and to erase the noises on the image. It has been aimed to increase the success of artificial intelligence algorithms in images ready to work.

Insignificant points fled from human eye can be very important for identification and diagnosis in medicine. Studies of scientists to minimize the human error have brought to positive outcomes. The artificial studies in medical field have increased significantly nowadays, therefore it has become compulsory for different disciplines to work together. There are many tools that operates on obtaining images, image processing and image data sets. Researchers with programming knowledge for artificial intelligence operations develop their own systems. Researchers who are not knowledgeable about this subject must seek help from different disciplines. However, this situation sometimes leads to time loss and lack of communication in teamwork. Additionally, lack of interdisciplinary information could create problems during studies.

In this thesis study, an application has been developed for researchers who study different disciplines but want to operate on medical images and lack software knowledge. With this software, users can open, view, apply image processing filters and apply the artificial intelligence algorithms that the

application offers to the medical images they own whether they are in DICOM file format or a different one. This way, users can perform their artificial intelligence studies on medical images by using a single application.

Keywords: Medical Image, Image Processing, Artificial Intelligence

2020, 56 pages



TEŞEKKÜR

Araştırma ve çalışma sürecimde beni yönlendiren, karşılaştığım sorunlarda bilgi ve tecrübesi yardımcı olan değerli Danışman Hocam Dr. Öğr. Üyesi Turgay AYDOĞAN'a teşekkürlerimi sunarım.

Tez çalışmalarım boyunca her zaman yanımda olan, desteklerini hiçbir zaman esirgemeyen aileme teşekkür ederim.

Bu süreçte motivasyon kaynağım olan, yanımda olamasalar bile bana her zaman destek olan çok değerli insanlara teşekkür etmeyi borç bilirim.

Şule Beste KAPÇI
ISPARTA, 2020



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Cari ABD doları cinsinden kişi başına düşen sağlık harcamaları ..	2
Şekil 1.2. Ülkelerin 2019 gayri safi yurt içi hasıla değerleri	3
Şekil 3.1. Sıkıştırma işlemi sonrası görüntü kalitesi değişimi	13
Şekil 3.2. DICOM dosya yapısı	15
Şekil 3.3. DICOM görüntüye ait meta verileri	15
Şekil 3.4. DICOM görüntüye ait PNG (solda) ve JPEG (sağda) görüntü	16
Şekil 3.5. Bilgisayarlı tomografi görüntüsü (BT)	17
Şekil 3.6. Manyetik rezonans görüntüsü (MR)	18
Şekil 3.7. Ultrasonografi görüntüsü	19
Şekil 3.8. Pozitron emisyon tomografisi görüntüsü	19
Şekil 3.9. Görüntü iyileştirme işlemleri uygulamış görüntü	20
Şekil 3.10. Sobel filtresi	21
Şekil 3.11. Sobel filtresi uygulanmış görüntü	21
Şekil 3.12. Farklı değerlere sahip gama dönüşüm eğrileri	22
Şekil 3.13. Gama dönüşümü uygulanmış görüntü	22
Şekil 3.14. 3x3 boyutundaki medyan filtresinin uygulanması	23
Şekil 3.15. Medyan filtesi uygulanmış görüntü	23
Şekil 3.16. Maksimum ve minimum filtreleri	24
Şekil 3.17. Gauss filtesi uygulanmış görüntü	25
Şekil 3.18. Griton görüntü (a) ve görüntüye ait histogram (b)	26
Şekil 3.19. Histogram eşitleme	26
Şekil 3.20. Aşındırma ve genişletme işlemleri	27
Şekil 3.21. Açma ve kapama işlemleri	28
Şekil 3.22. Derin sinir ağları	30
Şekil 3.23. ESA mimarisi	31
Şekil 4.1. Menü Çubuğu	37
Şekil 4.2. Ana pencere	38
Şekil 4.3. Görüntü ön işleme penceresi	39
Şekil 4.4. Veri arttırma işlemi	40
Şekil 4.5. Görüntü işleme penceresi	41
Şekil 4.6. Dosyada bulunan resimlere filtreleme işlemi	41
Şekil 4.7. Görüntü sınıflandırma penceresi-ESA	43
Şekil 4.8. Görüntü sınıflandırma penceresi-DSA	43
Şekil 4.9. Görüntü sınıflandırma penceresi-ESA	44
Şekil 4.10. Görüntü sınıflandırma penceresi-DSA	44

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 5.1. Öğrencilerin teknoloji konusundaki görüşleri	48
Çizelge 5.2. Öğrencilerin tıbbi yapay zekâ konusundaki görüşleri	48



SİMGELER VE KISALTMALAR DİZİNİ

AI	Artificial Intelligence
BMP	Bitmap
BT	Bilgisayarlı Tomografi
CNN	Convolutional Neural Networks
DİA	Derin İnanç Ağları
DBM	Derin Boltzmann Makinesi
DICOM	Digital Imaging and Communications in Medicine
DSA	Derin Sinir Ağları
EEG	Elektroensefalografi
FSL	FMRIB Software Library
GIF	Graphics Interchange Format
IDE	Integrated Development Environment
LZW	Lempel Zev Welch
MAE	Mean Absolute Error
MR	Manyetik Rezonans Tomografisi
OECD	Organisation for Economic Co-operation
PACS	Picture Archiving and Communication Systems
PNG	Portable Network Graphics
YSA	Yapay Sinir Ağları


1. GİRİŞ

Yapay zekâ, bir makinenin algılama, akıl yürütme, öğrenme ve etkileşim gibi bilişsel işlevleri yerine getirme yeteneğidir (Ergen, 2019). Birçok alanda olduğu gibi son yıllarda yapay zekâ üzerine yapılan çalışmalar içerisinde tıp alanı ile ilgili çalışmaların sayısının arttığı görülmektedir. Yapay zekâ sağlık alanında kullanıma başlandığı yer tıbbi tanı karar destek sistemleridir. Bu sistemler gelişmiş ülkelerde sağlık alanındaki hataların giderilmesi ve klinik uygulamaların etkili, verimli, doğru olması için sunulmuştur (Öcal vd., 2020). Yapay zekâ yöntemlerinin en çok bilinenlerinden biri Yapay Sinir Ağları (YSA) olmuştur. YSA çalışma mantığı olarak biyolojik sinir sistemini taklit eden, nöronlara benzer yapılardan oluşmaktadır (Demirhan vd., 2010). YSA, tıbbi görüntüler ve araştırma verileri içinden insan gözünden kaçan, fark edilmemiş desenleri saptama, sınıflandırma, tıbbi cihazların kontrolü, tıbbi görüntülerin karakteristik özelliklerinin tespiti gibi pek çok uygulamada aktif olarak kullanılmaktadır (Gönül vd., 2015).


Tıbbi yapay zekânın asıl ilgi alanıysa klinik teşhis işlemlerini yapabilecek ve tedavi önerilerinde bulunabilecek uygulamaların meydana getirilmesi olmuştur. Yapay zekâ karmaşık tıbbi verileri analiz edebilme yeteneğine sahiptir. Yapay zekâ yöntemleri, veri kümesi içindeki anlamlı verileri ortaya çıkarabilme yeteneğiyle birçok klinik senaryoda tanı, tedavi ve sonucu tahmin etmek için kullanılır. Tıbbi yapay zekâ sistemleri geliştirilirken tıbbi uzmanların görüşleri doğrultusunda çalışmalar yapılır (Demirhan vd., 2010).

Dünyada sağlık alanına verilen önem, bu alana ayrılan ödenek ve araştırmalara yapılan yatırımlar ülkeden ülkeye değişmektedir fakat insan sağlığının önemi, insanların tedavi ihtiyacı, hastalığın tespitinin önemi ve tedavi ihtiyacı bütün dünyada aynıdır. Küresel kalkınma verilerine açık erişim sağlayan The World Bank tarafından oluşturulan dünya genelinde sağlık alanında kişi başına düşen mevcut sağlık harcamasının yıllara göre ABD doları bazında değişimi Şekil 1.1'de ve ülkelerin OECD (Organisation for Economic Co-operation and Development, Ekonomik Kalkınma ve İşbirliği Örgütü) raporuna göre 2019

gayri safi yurt içi hâsıla değerleri Şekil 1.2’de gösterilmiştir. Dünya genelinde kişi başına düşen sağlık harcamaları artıyor görünse de ekonomik olarak gelişmemiş ülkelerde sağlık hizmetleri yeterli olmamakla birlikte tıbbi ekipmanların ve görüntüleme sistemlerinin yetersiz olması, sağlık çalışan sayısının az olması gibi faktörler insanların iyi bir sağlık hizmeti almasına engel olmaktadır. Yapay zekâ çalışmalarında ulaşılmak istenen amaçlardan biriside hızlı teşhis, hastalığın doğru tedavisi ve daha etkin kararlar alarak bu sebepleri önlemektir (Uzun, 2020).



Şekil 1.1. Cari ABD doları cinsinden kişi başına düşen sağlık harcamaları (Anonim, 2020)



Şekil 1.2. Ülkelerin 2019 gayri safi yurt içi hasıla değerleri (OECD, 2019)

Kanser tedavisi, radyoloji, psikiyatri, ilaç geliştirme, patoloji görüntülerinin analizi, doku mühendisliği, genetik mühendisliği, sağlık yönetimi gibi sağlık alanlarında yapay zekânın varlığı artmakta ve doktorlara yardımcı olacak sistemler geliştirilmektedir. Bunların dışında gerçeklik teknolojileri, mobil sağlık, robotik cerrahi gibi hayatımıza teknolojiyle birlikte giren alanlar insanlara daha iyi, güvenilir ve hızlı hizmet sunmayı amaçlamaktadır (Şahin vd., 2019).

Yapay zekâ çalışmalarının sağlık alanında getirmiş olduğu yenilikler ve faydalar yeni çalışmaların önünü açmış ve bu çalışmalara hız kazandırmıştır. Hızlı ve güvenilir hastalık teşhisleri, insan gözüyle ayırt edilemeyen hastalık belirtilerinin belirlenmesi ve doktorlara sağlayacağı zaman tasarrufuyla daha fazla hastaya ulaşma imkânı sağlayabilecek olmasıyla yapay zekânın sağlık alanında yapılan çalışmalarının önemi anlaşılmıştır. Bu alanda araştırma yapanların çoğalması ile yapılan çalışmalar artmış ve hız kazanmıştır. Bunun sonucu olarak disiplinler arası çalışmalarda artmıştır. Farkat disiplinler arası çalışmaların sahip olduğu bazı problemler vardır. Bunların başında karşılıklı bilgi alışverişi ve eksikliği gelmektedir.

Medikal görüntüleme sistemleri ile elde edilen görüntüler çoğunlukla DICOM (Digital Imaging and Communications in Medicine) görüntü formatında bulunmaktadır. Bu formata ait görüntüler özel programlar aracılığı ile görüntülenebilmektedirler. Özel bir program kullanılmadan DICOM formatında bulunan görüntülerde görüntüleme yapılmak istendiğinde dosya formatı değiştirilmelidir. Bu değişim sonucunda kayıplı formatlarda yaşanacak kalite kaybı istenmeyen bir durumdur (Ulaş, 2006).

Bu tez çalışmasının amacı yazılım bilgisine sahip olmadan da sağlık alanında yapay zekâ konusuyla çalışmak isteyen veya çalışan araştırmacıların kendi araştırma ve denemelerini DICOM formatını görüntüleyebilen bir sistemle yapma imkânı sunmaktır. Bu sayede disiplinler arası çalışmalarda yaşanabilecek olası aksaklıklar ve bu aksaklıklardan kaynaklanabilecek zaman kayıplarının önüne geçmek amaçlanmış ve yapay zekâ alanına ilgi duyan fakat kodlama bilgisi bulunmayan insanların kendi araştırmalarını yapma imkânı sunulmuştur. Farklı çalışma alanlarının farklı odak noktaları vardır. Bu çeşitlilik araştırmalara yeni, farklı ve yaratıcı bakış açısı sağlayarak tıbbi yapay zekâ çalışmalarının geliştirilmesi yönünde olumlu katkılar sağlayacaktır. Bu tez çalışmasında hedefimiz kullanıcı dostu, kolay kullanım sağlayan bir arayüz ile tasarlanan uygulamayla medikal alanda çalışacak kodlama bilgisi olmayan daha fazla araştırmacıya ulaşabilmektir.

2. KAYNAK ÖZETLERİ

Tıbbi alanda medikal görüntüler üzerinde yapay zekâ algoritmaları kullanan bazı araştırmalar aşağıda verilmiştir.

Karabulut (2016), yapmış olduğu çalışmasında biyomedikal alanda derin öğrenme yaklaşımlarının başarısını ölçmeyi amaçlamıştır. CNN (Convolutional Neural Networks - Konvolüsyonel/Evrişimsel Sinir Ağları) ve derin inanç ağları kullanılan çalışmada verideki dengesizliğin düzeltilmesi, özellik seçimi ve doku analizi gibi ön işlemler uygulanmıştır. Yapılan deneyler sonucunda medikal karar verme sürecinde derin öğrenme yaklaşımlarının gelecek vadettiğini ifade etmiştir.

Mehr (2017), akciğer tomografi görüntülerinde sınıflandırma yapmak için CNN için AlexNet ve GoogleNet mimarilerini kullanmış olup sınıflandırmada sırasıyla %95,919 ve %96,360 doğruluk oranlarına ulaşmıştır.

Esteva vd. (2017) Derin Sinir Ağları (DSA) ile cilt kanserinin dermatolog düzeyinde sınıflandırılması üzerine çalışma yapmışlardır. Çalışmalarında tek bir CNN kullanarak cilt lezyonlarının sınıflandırılmasını göstermişlerdir. Elde ettikleri sonuçlarda; ilk vaka, en sık görülen kanserlerin tanımını, ikincisi ise en ölümcül cilt kanserinin tanımlanmasını temsil eder. CNN, her iki görevde de test edilen tüm uzmanlarla aynı seviyede performans göstererek cilt kanserini dermatologlarla karşılaştırılabilir bir yeterlilik düzeyine sahip sunabilecek yapay bir sistem oluşturmuştur.

Sertkaya (2018), çalışmasında CNN yöntemi kullanılarak biyomedikal imgelerde hastalık tespiti ve medikal görüntülerde sınıflandırma çalışmaları yapmıştır. Bu çalışma sonucunda derin öğrenmenin sınıflandırma üzerine başarılı sonuçlar elde ettiği görülmüştür.

Oh vd. (2018) çalışmalarında, CNN kullanarak parkinson hastalığı için otomatik bir algılama sistemi önermiştir. Tüm EEG (Elektroensefalografi) sinyalleri

önerilen CNN'ye tabi tutulmuştur ve CNN ağı, Python dilinde Keras kullanılarak tasarlanmıştır. Yirmi parkinson hastalığına sahip ve yirmi normal kişinin EEG sinyallerini kullanılmış olup onüç katmanlı CNN mimarisi konvansiyonel özellik gösterme aşamasında kullanılmıştır. Geliştirilen model, %88,25 doğruluk, %84,71 hassasiyet ve %91,77 özgüllük sonucuna ulaşmıştır.

Gao vd. (2018) çalışmalarında meme kanseri teşhisi için medikal görüntüler kullanılarak CNN tabanlı bir sistem tasarlamışlardır. DICOM dosya biçimindeki görüntüleri OsiriX adındaki bir yazılımla ön işleme tabi tutulmuştur. Daha sonrasında bu görüntüler üzerinde CNN modelleri uygulamıştır.

Sajja vd. (2019) yaptıkları çalışmalarında akciğer kanseri teşhisi için derin öğrenme tabanlı bir sistem önermişlerdir. Önerdikleri sistemde ilk önce DICOM dosya biçimindeki görüntüleri JPG görüntü dosya biçimine dönüştürmüşler ve sonradan elde edilen görüntüleri oluşturdukları CNN modeli içerisinde kullanmışlardır.

Örnek (2019), yapmış olduğu çalışmada yeni doğan bebeklerin termal kamerayla görüntülenmesinde oluşabilecek görüntüleme problemlerinin ortadan kaldırılması için uygulanan klasik görüntü işleme yöntemleri yerine derin öğrenme algoritmalarından yararlanmayı amaçlamıştır. Derin öğrenme algoritmalarının eğitilebilmesi için veri arttırma yöntemi uygulanmıştır. Çalışma sonunda veri arttırma yöntemi ve CNN kullanarak %99,85 hassasiyet, %99,82 özgüllük ve %99,84 doğruluk ile en iyi sınıflandırma sonucu elde edilmiştir.

Cantemir (2019), yapmış olduğu çalışmada ham fonksiyonel MR (Manyetik Rezonans) görüntülerinden oluşan veri setine gürültü azaltma, beyin dokusu olmayan kısımların çıkarılması gibi ön işlemler için FSL (FMRIB Software Library) analiz aracı kullanılmıştır. Bu işlem sonrasında CNN eğitimiyle veriden özellik çıkarımı gerçekleşmiş ve bu özellikler doğrultusunda yapılan sınıflandırma sonucunda yüksek sınıflandırma doğruluk oranına ulaşılmıştır.

Karakurt (2019), çalışmasında derin öğrenme mimarilerinden olan CNN kullanarak meme kanseri patoloji görüntüleri üzerinde sınıflandırma işlemi gerçekleştirilmiştir. 3 adet evrişim katmanı, 3 adet ReLU katmanı, 3 adet havuzlama katmanı ve tam bağlantılı katmanda 200 sinir hücresi kullanılmasıyla eğitilmiş olan modelin doğruluk değeri 0,8775, F1 skoru 0.8238, hassasiyet değeri 0,8381, hatırlama değeri 0,8762, MSE (Mean Squared Error - Ortalama Karesel Hata) değeri 0,1195, MAE (Mean Absolute Error - Ortalama Mutlak Hata) değeri 0,2497 olarak elde edilmiştir.

Avcı (2019), çalışmasında karaciğer dokuları üzerinde CNN ile farklı girdi boyutları ve farklı aktivasyon fonksiyonlarıyla oluşturulan modellerin aynı veri seti ile elde edilen başarımlarının karşılaştırılması yapılmıştır. Yapılan deneyler sonucunda U-NET yapısıyla 256x256 ve 512x512 boyutundaki görüntülerde %97,58 ve %94,97 F-measure değerleri elde edilmiştir. Basit CNN yapısıyla Sigmoid ve Linear aktivasyon fonksiyonundan oluşan U-NET modellerinin (ortak eşik değer için) başarımlarını gösteremediği görülmüştür.

İnik (2019), çalışmasında histolojik analiz yapan uzmanlara yardımcı olacak akıllı bir sistem geliştirmeyi amaçlamıştır. Makine öğrenmesi ile yapılan analizler öncesinde, uzmanlar tarafından yapılan ham verinin işlenmesini ortadan kaldırmak ve özellik çıkarma işleminin otomatik olarak gerçekleşmesi istenmiştir. Bu amaçla önermiş olduğu derin öğrenme yöntemini Faster R-CNN modelinin farklı katman yapıları ile karşılaştırmış ve yapılan deneysel çalışmalarda önerilen yöntemin Faster R-CNN katman yapılarından daha başarılı olduğu görülmüştür.

Akpolat (2019), çalışmasında zatürre hastalığının teşhisi için röntgen görüntüleri kullanarak daha önce bu konuda yapılan çalışmaların üstünde ek çalışmalar yapmıştır. Bunun sonucunda başarımları artan modellerin performans ve hızlarında yaşanan sorunlar için yeni çözüm önerisinde bulunmuştur. The NIH (National Institutes of Health - Ulusal Sağlık Enstitüleri) Clinical Center tarafından oluşturulan etiketli verilerde bulunan dengesiz dağılımı giderebilmek için veri arttırma yöntemi uygulanmış ve çalışmaya

uygun olmayan veriler veri setinden çıkarılmayarak veri setine uygun hale getirilmiştir.

Yancı (2019) çalışmasında derin öğrenme yöntemleriyle medikal görüntülerde kanserli doku tespitinde YOLO mimarisinden yararlanmıştır. YOLO, yapılan çalışmalar sonucunda kanser hücrelerinin tespitinde %70-75 arası başarı sağlamıştır.

Erdoğan (2019), çalışmasında retina görüntülerinde optik disk bölütlemesi için tam CNN mimarisi olan U-Net mimarisinin iyileştirilmesini incelemiştir. Görüntülerin elde edildiği ekipmanların farklılığından dolayı bir ön işlem uygulaması yapılmıştır.

Arı (2019) beyin MR görüntülerinde bulunan tümörlü bölgelerin otomatik tespitini yapan, tümörleri derecelerine ve türlerine göre sınıflandıran Bölgesel Evrişimsel Sinir Ağları, CNN, AlexNet, VGG16 gibi derin öğrenme tabanlı sistemler tasarlamıştır. Çalışmasında 6 farklı veri tabanı kullanarak tasarladığı sistemlerin performansını değerlendirmiştir. Tasarlanan sistemlerden iki tanesinde kenar tespiti, morfolojik işlemler ve beyin tümörlerinin dokusal, morfolojik, istatistiksel öznitelik çıkarma ve sınıflandırma gibi ön işlemler uygulanmıştır.

Ali vd. (2019) beyin tümörü sınıflandırması için önerdikleri yaklaşımlarında DICOM dosya biçimini kullanmışlardır. İlk olarak (X)MedCon adındaki yazılım ile DICOM görüntü dosyası biçimindeki görüntüleri JPG ve PNG dosya biçimine dönüştürmek için kullanmışlardır. Daha sonrasında CNN modelinde bu görüntüleri kullanmışlardır.

Öcal vd. (2020), yapmış oldukları çalışmada tıp fakültesi öğrencilerinin yapay zekâ hakkında ne düşündüklerini araştırmışlardır. Yapılan araştırmada elde edilen sonuçlardan bazıları şu şekildedir; Öğrencilerin %59,4'ü robotların hayatımıza girmesinin onları endişelendirmediğini, %93,6'sı yapay zekâyı duyduğunu %59,2'si tıpta yapay zekâ uygulamaları hakkında bilgi sahibi

olmadığını, %79,2'si ileride hekimlik hayatında yapay zekâyı kullanmak istediğini belirtmiştir.

Safdar vd. (2020) beyin tümörlerinin analiz edilmesine yönelik yaptıkları çalışmalarında MR (Manyetik Rezonans) görüntüle tekniği ile elde edilen görüntülerini kullanmışlardır. DICOM dosya biçimindeki görüntüleri ilk önce MicroDicom adındaki yazılım ile JPG görüntü dosya biçimine dönüştürmüşler. Sonrasında bu görüntüleri yapay zekâ algoritmalarında kullanmışlardır.

Literatür çalışmalarından da anlaşılabacağı üzere son yıllarda medikal görüntüler üzerinde yapay zekâ algoritmaları kullanılarak birçok çalışma gerçekleştirilmiştir.

Literatüre bakıldığında görüntülerin elde edilmesinde DICOM dosya biçiminin kullanıldığı görülmektedir. Bu dosya biçimini yapay zekâ algoritmalarında kullanmak için uygun olan görüntü dosya biçimine (X)MedCon, MicroDicom, OsiriX vb. farklı yazılım araçları kullanarak dönüşüm yapıldığı anlaşılmaktadır.

Bu tez çalışması ile literatürden farklı olarak, araştırmacıların medikal görüntüler üzerinde daha kolay işlem yapmalarına olanak sağlayan yapay zekâ algortimalarının kullanabilindiği uygulanabilmesi adına bir uygulama geliştirilmiştir. Bir sonraki bölümde tez çalışmasında kullanılan materyal ve yöntem ile ilgili bilgiler sunulmuştur.

3. MATERYAL VE YÖNTEM

Bu tez çalışmasında görüntü işleme algoritmaları, arayüz tasarımı, veri çoğaltma işlemleri ve görüntü sınıflandırma algoritmalarının uygulanabilmesi için bir kullanıcı arayüzü meydana getirilmiş ve bu arayüz tasarımı ve kodlamasında tamamiyle python programlama dili kullanılmıştır. Programın kod geliştirilmesinde Anaconda IDE (Integrated Development Environment – Tümüleşik Geliştirme Ortamı) içerisinde yer alan Spyder geliştirme ortamı kullanarak gerçekleştirilmiştir. Yapılan işlemlerin test edilmesi için <https://www.kaggle.com/> adresinde bulunan veri setleri kullanılmıştır. Birinci veri seti herkese açık paylaşımı olan <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection> adresinde bulunan Brain MRI Images for Brain Tumor Detection isimli veri setidir ve JPEG görüntülerinden oluşmaktadır. İkinci veri seti herkese açık paylaşımı olan Brain-Tumor-Progression (Clark vd., 2013) adlı, <https://www.kaggle.com/andrewmvd/brain-tumor-progression> adresinde bulunan DICOM görüntülerin bulunduğu veri setidir.

3.1. Görüntü sıkıştırma teknikleri

Görüntü sıkıştırma teknikleri depolama veya görüntü maliyetinde azaltma sağlayabilmek için dijital görüntüler üzerinde uygulanan bir veri sıkıştırma türüdür (Saha, 2000). Başka bir tanımla görüntü sıkıştırma, orijinal görüntünün birkaç bite kodlandığı veri sıkıştırma uygulamasıdır (Wei, 2008). Diğer dijital veriler için kullanılan veri sıkıştırma yöntemlerinden farklı olarak daha iyi sonuçlar elde edebilmek için görüntü verilerinin istatistiksel özelliklerinden yararlanılabilir. Görüntü dosyasının boyutunu küçültebilmek için dosyanın belli bölümlerinin kaldırılması veya gruplandırılmasıyla gerçekleştirilir. Görüntü sıkıştırma işlemi kayıpsız ve kayıplı sıkıştırma olmak üzere ikiye ayrılmaktadır (Kalkan ve Demirci, 2019).

3.1.1. Kayıpsız görüntü sıkıştırma formatları

Kayıpsız sıkıştırma işlemi görüntünün sıkıştırılma işlemi uygulanmadan önceki kalitesinin korunarak dosya boyutunu azaltmak için kullanılan yöntemdir. Arşivleme amacıyla veya tıbbi görüntüleme, teknik çizimler, çizgi romanlar gibi görüntü dosyalarında tercih edilirler. Kayıpsız veri sıkıştırma, depolama ve iletim gibi süreçlerde etkililiği arttırabilmek için sıkıştırılmış olan veriden daha sonra orijinal verinin aynısını elde etme imkânı tanıyan tekniklerin kullanımına dayanmaktadır (Artuğer ve Özkaynak, 2018).

3.1.1.1. BMP

Windows ve Microsoft'un PCX formatını değiştirerek oluşturdukları bir formattır. BMP (Bitmap) formatı 1-24 bit derinliği arasında değişen piksel derinliğine sahiptir. Başlangıçta sıkıştırma seçeneği bulunmamakta olup daha sonra Run-Lenght-Encoding sıkıştırma yöntemi BMP dosyaları için kullanılmaya başlanmıştır. Bu sıkıştırma görüntü üzerinde detay kaybına yol açmamaktadır (Bourke, 1998).

3.1.1.2. PNG

Portable Network Graphics (PNG) patentsiz bir görüntü formatıdır. GIF dosya formatına alternatif olarak oluşturulmuştur. PNG 48 bit renk derinliğine kadar destekleyebilmektedir (Aydoğan, 2008). PNG resimlerde sıkıştırma işlemi tersine çevrilebilmektedir ve bu sayede PNG dosyası açtığımız zaman görüntü tam olarak kurtarılabilmektedir. ZLIB ve DEFLATE veri sıkıştırma tekniklerini kullanmaktadır (Mesut ve Carus, 2005).

3.1.1.3. RAW

Dijital fotoğraf makinesinden elde edilen, genellikle sensör pikselini içeren, herhangi bir işlemten geçmemiş veya en az düzeyde işleme tabi tutulan verileri içeren dosyadır. RAW dosyası yüksek kaliteli görüntüler içermektedir.

Sensörlerden alınan ham verilerin yanında RAW dosyaları pozlama hakkında bilgilerin bulunduğu meta veriler içermektedir (Sumner, 2014).

3.1.1.4. GIF

Graphics Interchange Format (GIF) az sayıda renk içeren (1 veya en fazla 8 bit boyutunda bulunan) dosyalarda yüksek sıkıştırma sağlamaktadır. Gerçek renk desteği bulunmayan GIF resimleri griskala, Bitmap ve indexlenmiş renk sisteminde olabilir. GIF patentli LZW (Lempel Zev Welch) sıkıştırma ve açma algoritması kullanmaktadır (Aydoğan, 2008).

3.1.2. Kayıplı görüntü sıkıştırma formatları

Dosya boyutunun daha da küçülmesi için bazı verilerin kaybolduğu sıkıştırma işlemidir. Bu sıkıştırma algoritmalarının temel mantığı veri içeriğinde bozulmaya sebep olmayacak şekilde kayıplara izin vererek yüksek sıkıştırma oranlarına ulaşmaktır (Artuğer ve Özkaynak, 2018). Sıkıştırma işlemi tersine çevrilememektedir. Resim dosya boyutunu ne kadar küçültürsek bozulmada o kadar artmaktadır ve resim dosyasının kalitesinde düşüş yaşanmaktadır.

3.1.2.1. JPEG

Dosya boyutunu küçültmek için görüntünün algılanmasında zorunlu olmayan verileri bulup bunları atarak dosyayı sıkıştırdığı için kayıplı sıkıştırma formatıdır. Kaybedilen veriler geri alınamaz ve sıkıştırma işlemi ne kadar çok olursa görüntüde kalite kaybı o kadar çok olmaktadır. Şekil 3.1’de görüldüğü gibi sıkıştırma işlemleri görüntülerde kalitenin düşmesine neden olmaktadır. JPEG 10:1 oranına kadar fark edilebilir bir bozulma olmadan sıkıştırma işlemlerini gerçekleştirebilmektedir. JPEG formatının özelliği gerçek renk değerlerini içermesidir ve 24 bit rengi desteklemektedir. Bu nedenle çizgisel veya grafiksel olmayan görüntüleme için kullanılır (Pennebaker vd., 1992).



Şekil 3.1. Sıkıştırma işlemi sonrası görüntü kalitesi değişimi

3.2. Medikal Görüntü Sıkıştırma

Sağlık hizmetlerinde zamanın önemi daha fazla hastaya ulaşabilme, maliyetin düşmesi ve daha fazla hayata ulaşabilmek demektir. Medikal görüntüler üzerinde sıkıştırma işlemi görüntünün boyutunu azaltma, aktarım süresi ve depolamak için gereken zamanın da azalmasını sağlamaktadır. Dosya sıkıştırma işlemlerinde tercih edilen formata bağlı olarak görüntülerde kalite kaybı yaşanabilmektedir. Medikal görüntüler, bilinen formatlarla kaydedilen resimlerin boyutlarından çok daha yüksek boyutlara sahiplerdir. Bunun sebebi medikal görüntülerin doğru teşhise yardımcı olabilmeleri için yüksek detay içermelidir. Bu da yüksek çözünürlük ve kayıpsız sıkıştırma işlemlerini beraberinde getirmektedir (Boyacı ve Ulaş, 2007).

Kayıpsız sıkıştırma yöntemleri medikal görüntüler için önemlidir. Kayıplı sıkıştırmada gerçekleşecek veri kayıpları görüntü üzerinde önemli bilgi kayıplarına sebep olabilir ve bu da hastalık teşhislerinde büyük hatalara sebebiyet verebilmektedir.

PACS (Picture Archiving and Communication Systems) görüntülerin saklanması, görüntülere erişim ve dağıtımının sağlanması ve sunumu için kullanılan

yönetim sistemlerinin genel adıdır. PACS röntgen, ultrason, manyetik rezonans, bilgisayarlı tomografi, mamografi gibi tıbbi görüntüleme cihazlarından alınan görüntülerin tek bir kaynakta toplanmasını sağlar. Tıbbi görüntülerin saklanması DICOM en yaygın kullanılan formattır.

3.2.1. NIFTI

NIFTI (Neuroimaging Informatics Technology Initiative), Data Format Working Group tarafından hazırlanmış olan bir medikal görüntü dosyasıdır. Medikal görüntülerde bulunan analiz paketlerinin veri alışverişini kolaylaştırır. NIFTI 348 byte uzunluğunda başlık bilgisi içerir. Görüntü ve başlık bilgisi birleşir ve *.nii uzantılı dosya oluşturur (Doğan vd., 2013).


3.2.2. ANALYZE

Analyze, görüntü verilerinde düzenleme ve erişim sağlayan dosya formatıdır. Çok büyük boyutlu veriler için tasarlanmıştır (Larobina ve Murino, 2014). Analyze görüntü veritabanı görüntü ve başlık dosyası bulundurur. Görüntü dosyası için .img uzantısı ile, başlık dosyası için .hdr uzantısı ile aynı isimde kaydedilir (Doğan vd., 2013).

3.2.3. DICOM

DICOM standardı, National Electrical Manufacturers Association (NEMA) tarafından bilgisayarlı tomografi, manyetik rezonans ve ultrason gibi görüntülemelerden elde edilen görüntüler için oluşturulmuş dosya formatıdır. Medikal görüntülerde standartlaşmanın amacı farklı cihazlardan elde edilen görüntülerin ortak bir şekilde kullanılabilmesini sağlamaktır ve farklı üreticilerin ekipmanları arasında iletişimi sağlar. Ayrıca hasta başka bir hastaneye gittiği zaman bilgilerine ulaşılabilmesi açısından tıbbi görüntülerde standartlaşma çok önemlidir (Mildenberger vd., 2001).

DICOM dosyaları ham görüntüler yanında meta bilgilerini de tutmaktadır (Ulaş ve Boyacı, 2007). DICOM dosyasında bulunan başlık bilgisi 794 bayt'tır. Başlık boyutu başlık bilgisinin ne kadar olduğuna göre değişmektedir. 128 bayt dosya girişinden sonra 4 baytlık DICOM ön eki ve arkasından meta verileri gelmektedir. Şekil 3.2'de DICOM dosyasının yapısı verilmiştir ve burada hastaya ait bilgiler, görüntü alan cihaz hakkında bilgiler, hastaneye ait bilgiler, görüntü dosyasına ait bilgiler gibi veriler bulunmaktadır (Doğan vd., 2013). Şekil 3.3'de bir hastaya ait DICOM görüntüsünün meta verileri örnek olarak gösterilmiştir.




Şekil 3.2. DICOM dosya yapısı (Obrul vd., 2012)

(0008, 0005) Specific Character Set	CS: 'ISO_IR 100'
(0008, 0008) Image Type	CS: ['ORIGINAL', 'PRIMARY', 'OTHER']
(0008, 0016) SOP Class UID	UI: MR Image Storage
(0008, 0018) SOP Instance UID	UI: 1.3.6.1.4.1.14519.5.2.1.2857.3707.127824704157528849251019519345
(0008, 0020) Study Date	DA: '19991115'
(0008, 0021) Series Date	DA: '19991115'
(0008, 0022) Acquisition Date	DA: '19991115'
(0008, 0023) Content Date	DA: '19991115'
(0008, 0030) Study Time	TM: '042736'
(0008, 0031) Series Time	TM: '043443'
(0008, 0032) Acquisition Time	TM: '043443'
(0008, 0033) Content Time	TM: '043443'
(0008, 0050) Accession Number	SH: '2370730844192095'
(0008, 0060) Modality	CS: 'MR'
(0008, 0070) Manufacturer	LO: 'GE MEDICAL SYSTEMS'
(0008, 0090) Referring Physician's Name	PN: ''
(0008, 1030) Study Description	LO: 'MR BRAIN WO+W CONTRAST'
(0008, 103e) Series Description	LO: 'Ax Flair irFSE H'
(0008, 1090) Manufacturer's Model Name	LO: 'Signa HDxt'
(0008, 1111) Referenced Performed Procedure Step Sequence	1 item(s) ----
(0008, 1150) Referenced SOP Class UID	UI: Modality Performed Procedure Step SOP Class
(0008, 1155) Referenced SOP Instance UID	UI: 1.3.6.1.4.1.14519.5.2.1.2857.3707.678184114810878104957539097771

Şekil 3.3. DICOM görüntüye ait meta verileri

DICOM görüntüler çok büyük boyutlara sahiplerdir ve kişisel bilgisayarlarda görüntülenmeleri için özel yazılımlar kullanmak gerekir. DICOM görüntülerin yazılım olmadan görüntülenebilmesi için farklı formatlara dönüştürülebilir. Kayıplı ve kayıpsız sıkıştırma formlarına dönüştürülen görüntü meta verileri içermez ve boyutu daha küçüktür. Görüntülerde boyut küçülmesi daha az depolama alanı sağlar fakat kayıplı sıkıştırmalarda küçültme miktarına bağlı olarak görüntü kalitesinde düşme meydana gelir ve bu durum medikal görüntülerde istenmeyen bir durumdur. Şekil 3.4'te DICOM formatı ile JPEG görüntü formatında olan görüntüler birlikte verilmiştir. DICOM görüntülemesi tez çalışmasında oluşturulan sistem aracılığıyla elde edilmiştir ve kayıpsız görüntü formatlarından PNG ile ekran görüntüsü alınmıştır.



Şekil 3.4. DICOM görüntüye ait PNG (solda) ve JPEG (sağda) görüntü


DICOM görüntüler için özel görüntüleyici sistemler vardır. Bunlardan bazıları; RadiAnt, MicroDicom, IrfanView, JiveX DICOM Viewer, Horos, Sante, Athena, ClearCanvas, Yakami DICOM tools, MatrixUser, NextCloud'tur. Daha birçok farklı seçeneği olan bu uygulamalar DICOM medikal görüntüleri görüntülemekte ve bu görüntüler üzerinde görüntü işlemenin uygulanmasına izin vermektedirler. Her programın kendisine özgü farklı özellikleri de mevcuttur. Görüntüye ait meta verileri görüntüleme, görüntüyü kaydetme, görüntüler üzerine işlemler yapmak genel olarak ortak özelliklerindendir.

3.3. Tıbbi Görüntüleme Teknikleri ve Görüntü Elde Etme Yöntemleri

Wilhelm Conrad Röntgen'in 1895 yılında X-ışınlarının keşfetmesiyle başlayan tıbbi görüntüleme, klinik analiz ve tıbbi müdahale için insan vücudunun iç yapısının farklı yöntemlerle görüntülenmesidir. Hastalık tanı ve tedavisinde kullanılan tıbbi görüntüleme tekniklerinin uygulanması hastanın durumuna ve hastanın şikayetlerine göre farklılık göstermektedir. Bilgisayarlı tomografi (BT), manyetik rezonans (MR), ultrasonografi, pozitron emisyon tomografisi (PET) görüntüleme yöntemlerinden bazılarıdır.

3.3.1. Bilgisayarlı tomografi (BT)


Bilgisayarlı tomografi temeli röntgen cihazına dayanan ve vücudun incelenen bölgesinin kesitsel görüntüsünü oluşturan görüntüleme yöntemidir. Cormak tarafından 1963 yılında teorize edilmiştir. Bir cismin farklı açılardan çok sayıda iki boyutlu X ışını görüntülerinin alınmasıyla o cismin iç yapısının üç boyutlu görüntüsünün elde edilmesiyle oluşur. Konvansiyonel radyografide film üzerinde yaklaşık 20 farklı kontrast varken, BT de bu sayı 2000'i geçmektedir. Bu kontrast sayısı farkı BT de dokuların birbirinden ayrılmasını sağlar ve bu sayede su, ödem, hematoma gibi yapılar daha iyi şekilde görüntülenir. Bilgisayarlı tomografi işlemlerinin büyük kısmında kontrast madde kullanılmaktadır (Aydoğdu vd., 2017). Şekil 3.5'te örnek bir BT görüntüsü verilmektedir.



Şekil 3.5. Bilgisayarlı tomografi görüntüsü (BT)

3.3.2. Manyetik rezonans (MR)

Manyetik rezonans görüntüleme vücutta bulunan organ ve dokuların ayrıntılı bir şekilde görüntülerini oluşturmak için manyetik alan ve radyo dalgalarını kullanan bir tekniktir. MR cihazlarının oluşturduğu manyetik alan geçici olarak vücutta bulunan hidrojen atomlarını yeniden düzenler ve radyo dalgaları, bu hizalanan atomların çok zayıf sinyaller üretmesine sebep olur ve daha sonra bu sinyaller ilgili organın kesit görüntülerini oluşturmak için kullanılır. MR cihazlarının sahip olduğu manyetik alan gücü 0,2 Tesla ile 3 Tesla arasındadır (Aydoğdu vd., 2017). Şekil 3.6'de örnek bir MR görüntüsü verilmektedir.



Şekil 3.6. Manyetik rezonans görüntüsü (MR)

3.3.3. Ultrasonografi


Yüksek frekanslı ses dalgaları yardımıyla vücudun görüntülenmesidir. Ultrasonografide X ışınları kullanılmamaktadır. Promp tarafından üretilen ses dalgalarının vücutta organlardan yansıdıktan sonra aynı cihaz tarafından algılanmasında oluşan yansıma farklılıklarıyla oluşturulan görüntülerdir. Ses dalgalarının farklı doku ve organların farklı yansımalar oluşturmasına dayanır (Aydoğdu vd., 2017). Şekil 3.7'de örnek bir ultrasonografi görüntüsü verilmektedir.



Şekil 3.7. Ultrasonografi görüntüsü

3.3.4. PET

Pozitron emisyon tomografisi (PET), damar yoluyla enjekte edilen metabolik radyoaktif ajanların (radyoaktif işaretli şeker bileşimi) birikmiş olduğu normal veya patolojik dokuların görüntülenmesidir. Tümörler sağlıklı dokulara göre daha yüksek oranda madde değişim özelliğine sahiptir. Bundan dolayı radyoaktif işaretli şeker bileşimi tümör hücreleri tarafından daha yoğun bir şekilde emilir ve depo edilir. Depolanan bu bileşim PET-Scanner kameraları tarafından tespit edilirler. Şekil 3.8’de örnek bir Pozitron emisyon tomografisi görüntüsü verilmektedir.



Şekil 3.8. Pozitron emisyon tomografisi görüntüsü

3.4. Görüntü İşleme

Görüntü işleme, dış ortamdan çeşitli teknik ve yöntemlerle elde edilen görüntülerin bilgisayarın anlayacağı biçime dönüştürülmesiyle meydana gelen görüntülerin, çeşitli yöntem ve tekniklerle üzerinde istenilen değişikliklerin yapılmasıdır (Aydoğan, 2008). Bir başka tanımlama, dijital ortama aktarılmış olan görseller üzerinde istenilen bilgileri elde etmek için farklı teknikler kullanılan bir yöntemdir. Görüntü işleme yöntemi, dijital ortamda bulunan görüntünün işlenip mevcut olan resim ve grafiklerin değiştirilerek iyileştirilmesi veya farklılaştırılması için kullanılmaktadır. Başlıca görüntü işleme teknikleri; görüntü ön işleme, özellik çıkarımı, görüntü geliştirme, görüntü ayırma ve sınıflandırmadır (Solak ve Altınışik, 2017).

Görüntü elde edilmesi sırasında yaşanan çevresel veya cihazlardan kaynaklı kontrast ve parlaklık hataları, resimler üzerinde gürültü sorunları olabilir. Görüntü ön işleme çalışması piksellerin geometrisi ve parlaklık değerleriyle ilgili hataların ortadan kaldırılmasını sağlar. Şekil 3.9'da görüntü iyileştirme işlemleri uygulanmış görüntüye örnek verilmiştir.




Şekil 3.9. Görüntü iyileştirme işlemleri uygulanmış görüntü (Anonim, 2019)

Yapılan bu tez çalışmada sınıflandırma işlemi uygulanmadan önce kullanıcının isteğine bağlı olarak veriler üzerinde uygulayabilecekleri filtreler seçenekler halinde program arayüzüne eklenmiştir.

3.4.1. Görüntü işleme filtreleri


3.4.1.1. Sobel filtresi

Kenar algılama, görüntüde bulunan nesnelerin sınırlarını algılamak için kullanılır. Sobel filtresi Şekil 3.10'da verilen iki kernelden oluşmaktadır.



Şekil 3.10. Sobel filtresi


Gx kernel yatay kenarları algılarken Gy kernel dikey kenarları algılamaktadır. Şekil 3.11'de sobel filtresine örnek verilmiştir.




Şekil 3.11. Sobel filtresi uygulanmış görüntü

3.4.1.2. Gama dönüşümü

Görüntülerde piksellerin sahip olduğu parlaklık seviyeleri bulunur. Bu değer 0 ile 1 arasındadır. 0 tam karanlığa, 1 ise en parlak (beyaz) anlamındadır. Gama dönüşümü görüntünün parlaklık değerini düzenlemek için kullanılır (Gonzalez ve Woods, 2014). Şekil 3.12’de farklı değerlere sahip gama dönüşüm eğrileri verilmiştir. Şekil 3.13’de 0,5 değeri uygulanmış gama dönüşümü örneği verilmiştir.




Şekil 3.12. Farklı değerlere sahip gama dönüşüm eğrileri (Wang vd., 2018)




Şekil 3.13. Gama dönüşümü uygulanmış görüntü

3.4.1.3. Medyan filtresi

Medyan filtresi, görüntüden gelen tuz ve biber gürültülerini ortadan kaldırmak için kullanılan doğrusal olmayan filtreleme yöntemidir. Medyan filtresi komşu pikselleri sıralayarak sıranın ortasında bulunan değeri alır. Şekil 3.14'te 3x3 piksel boyutundaki medyan filtresinin uygulama örneği verilmiştir. Şekil 3.15'de 6 değeri uygulanmış medyan filtresi uygulanan görüntü örneği verilmiştir (Kızrak ve Özen).




Şekil 3.14. 3x3 boyutundaki medyan filtresinin uygulanması



Şekil 3.15. Medyan filtesi uygulanmış görüntü

3.4.1.4. Minimum ve Maksimum filtreleri


Minimum filtresi merkezi piksel değerini, belirtilen pencere boyutundaki en koyu piksel değeri ile değiştirir. Bu görüntüde bulunan koyu renkli bölgelerin kalınlaşmasını sağlar. Maksimum filtresi minimum filtresine ters bir şekilde çalışır ve merkezi piksel değerini belirtilen pencere boyutundaki en açık piksel değeri ile değiştirir. Şekil 3.16'da solda orijinal resim, ortada 5 değeri uygulanmış minimum filtresi ve sağda 5 değeri uygulanmış maksimum filtresi örnek olarak verilmiştir.



Şekil 3.16. Maksimum ve minimum filtreleri

3.4.1.5. Gauss filtresi

Gauss yumuşatma filtresi görüntüler üzerinde bulanıklaştırma işlemi yaparak ayrıntı ve gürültüleri ortadan kaldırmak için kullanılan 2 boyutlu operatördür. Gauss filtresi görüntüde bulunan her bir piksel için ağırlıklı ortalama değerleri üretmektedir. Bunu yaparken merkezi piksel etrafında bulunan $k \times k$ komşuluk değerlerine bakılmaktadır (Aydoğan, 2008). Şekil 3.17'de 1 değeri uygulanmış gauss filtresine örnek verilmiştir.




Şekil 3.17. Gauss filtesi uygulanmış görüntü

3.4.1.6. Histogram eşitleme

Histogram, istatistikde veri dağılımının grafiksel gösterimidir. Bu gösterim, kesikli bir değişkende olasılıksal dağılımın eksiksiz tanımlanmasını sağlamaktadır. Görüntü işlemede ise histogram, belirli piksel değerlerinin ilgili görüntüde bulunma oranı hakkında bilgi vermektedir (Çatalbaş vd., 2015). Gri seviyeli bir görüntünün her pikseli 0 – 255 arasında parlaklık değeriyle temsil edilmektedir. 0 değeri siyah, 255 değeri ise beyaz rengi göstermektedir. Histogram sola yaklaştıkça karanlık, sağa yaklaştıkça aydınlık bir görüntü elde edilir (Arısoy ve Dikmen, 2014). Şekil 3.18’de bir histogram örneği verilmiştir. Bu grafik 0-255 arasında ifade edileceği gibi 0-1 arasında da temsil edilebilmektedir.




(a)




Şekil 3.18. Griton görüntü (a) ve görüntüye ait histogram (b) (Çatalbaş vd., 2015)


Histogram eşitleme, görüntüye ait belli bir yerde kümelenmiş olan renk değerlerinin genliğinin değiştirilerek kontrastının geliştirilmesi işlemidir. Şekil 3.19’da histogram eşitleme uygulanmış görüntüye örnek verilmiştir. Üstte orijinal görüntümüz altta ise histogram eşitleme uygunması sonucu oluşan görüntü verilmiştir.



(a)




(b)



Şekil 3.19. Histogram eşitleme (Senthilkumaran ve Thimmiaraja, 2014)

3.4.1.7. Aşındırma (Erosion) ve Genişletme (Dilation) işlemleri


Morfolojik görüntü işlemlerden olan aşındırma iki inputa ihtiyaç duymaktadır. Bunlar orijinal görüntümüz ve işlem yapısına karar veren kernel'dır. Aşındırma filtresi ön plandaki nesnenin sınırlarını aşındırır. Bu işlem birbirine ince bir gürültü ile bağlı olan iki veya daha fazla nesneyi birbirinden ayırmak için kullanılır. Genişletme filtresi görüntüde bulunan nesnelerin ince bir sınırla birbirlerinden ayrılıp iki farklı nesne olmasını engeller (Acar ve Bayram, 2009). Şekil 3.20'de aşındırma ve genişletme işlemlerine örnek verilmiştir. Solda orijinal görüntü, ortada 7 değerinde aşındırma ve sağda 7 değerinde genişletme işlemi uygulanmış görüntü vardır.



Şekil 3.20. Aşındırma ve genişletme işlemleri

3.4.1.8. Açma (Opening) ve Kapama (Closing) işlemleri

Görüntü genelinde bulunan birinci seviye küçük parçaları ortadan kaldırmak için açma işlemi uygulanır. Bunun için görüntüye önce aşındırma uygulanır. Bu sayede çok küçük alanlar yok olur fakat görüntüde küçülme de meydana gelir. Bunu ortadan kaldırmak için de daha sonra genişletme uygulanır. Kapama işlemi iç açma işleminin tersi olarak düşünülebilir. Görüntü üzerinde küçük parçaların birleşmesi için önce genişletme işlemi daha sonra aşındırma işlemi uygulanır (Acar ve Bayram, 2009). Şekil 3.21'de açma ve kapama işlemlerine örnek verilmiştir. Solda orijinal görüntü, ortada 7 değerinde açma ve sağda 7 değerinde kapama işlemi uygulanmış görüntü vardır.



Şekil 3.21. Açma ve kapama işlemleri

3.4.2. Görüntü işleme araçları

Görüntülerden elde edilecek bilgi için etkili bir şekilde yapılan görüntü işleme önemlidir. Görüntü işleme sırasında yaygın olarak kullanılan işlemlerden bazıları çevirme, kırpma, döndürme gibi temel işlemler, bölümleme, öznelilik çıkarma gibi işlemlerden bahsedebiliriz. Farklı programlama dillerinin farklı görüntü işleme araçları bulunmaktadır. Araştırmacılar görüntüleri makine öğrenimine hazır hale getirmek için öncelikle ön işlemden geçirirler. Bunun amacı görüntü kalitesini artırma ve önemli olan bazı bilgileri ön plana çıkarabilmektir.

Çalışmalarda kullanılan programlama diline bağlı olarak görüntü işleme araçları da farklılık göstermektedir. Scikit-image, openCV, Mahotas, SimpleITK, SciPy, PIL, Matplotlib, Pycairo, Numpy Python programlama dilinde en çok kullanılan kütüphanelerdir (Pandey, 2019). BoofCV açık kaynak kodlu bir Java kütüphanesidir. CVIPtools C++, C ve C# kullanılarak yazılan görüntü işleme yazılımıdır. VXL birçok çekirdek kütüphaneden oluşan C++ kütüphaneleri koleksiyonudur. AForge.NET C# ile yazılan ve .NET Framework için geliştirilen açık kaynaklı kütüphanedir. Scilab üst düzey, sayısal olarak yönlendirilmiş programlama dilidir ve C, C++, Java, Fortran'da yazılmıştır. GNU Octave, 1998 yılında C++ standart kütüphanesi olarak GNU projesinin bir parçası olarak MATLAB'ın ücretsiz alternatifi olarak tasarlanmıştır. MATLAB, MathWorks tarafından geliştirilmiştir. 1984 yılında kurulan MATLAB C, C++ ve Java ile

yazılmıştır (Pattnaik, 2018). Bu tez çalışmasında görüntü işleme için Python programlama diline ait görüntü işleme kütüphaneleri kullanılmıştır.

3.5. Yapay Zekâ

Günümüzde bilgisayar olarak kabul edilen bir cihazın veya bu cihazın kontrolündeki robot olarak tanımlanabilir nesnenin sahip olduğu yeteneklerin zeki olarak kabul edilen canlılarla kıyaslanabilir şekilde yapabilme becerisine denir. Yapay zekâ (YZ), bir bilgisayarın veya bilgisayar kontrolündeki bir robotun çeşitli faaliyetleri zeki canlılara benzer şekilde yerine getirme kabiliyeti. İngilizce artificial intelligence (AI) kavramının akronimi olan AI sözcüğü de bilişimde sıklıkla kullanılır (Wikipedia, 2020).

Sağlık alanında yapay zekâdan beklenen hastanede rutinleşen işleri devralması, insan gözünün fark edemediği durumlarda teşhiste yardımcı olması, büyük miktardaki verilerden en kısa sürede en uygun sonuçları çıkararak zaman ve maliyetten tasarruf sağlamasıdır. Bu yönde çeşitli yapay zekâ çalışmaları yapılmış ve uygulamalar geliştirilmiştir.

1970 yılında geliştirilen MYCIN enfeksiyon hastalıkları, menenjit gibi hastalıkların tanı ve tedavisi için geliştirilmiştir. JOSEPH 1986 yılında Tıp fakültesi öğrencilerine EKG okumayı öğretmek için geliştirilmiştir. PHARM-2 ilaç tedavisinde karar destek amacıyla geliştirilmiştir. QUAWDS, yürüme analizi yaparak felç, kas kusuru gibi durumlara açıklık getirir. LEDI-2 yoğun bakım hastalarıyla ilgili kararlara yardımcı olması için geliştirilmiştir. PIP böbrek hastalıkları, PUFF ise akciğer hastalıkları tanısında yardımcı olması için geliştirilmiştir. Digitalis Therapy Advisor diyaliz uygulamaları için kullanılmıştır (Bilge, 2007).


Günümüzde kanser teşhisi en çok yapılan derin öğreneme çalışmaları arasındadır. Elde edilen görüntülerin sınıflandırılması için yapılan çalışmalar halka açık erişim sağlayan kanser veri tabanlarının olması ve disiplinler arası çalışmaların artmasıyla hız kazanmıştır.

3.5.1. Derin öğrenme ve derin öğrenme mimarileri

Derin öğrenme en basit tanımıyla bir ya da daha fazla gizli katman içeren yapay zekâ yöntemidir ve makine öğreniminin alt kümesidir. Derin öğrenmeyi makine öğrenmesinden ayıran özellik kodlanmış kurallardan öğrenmek yerine üzerinde çalışılan verilerden otomatik olarak öğrenebilmesidir (Kaya vd., 2019). Bu bölümde sağlık alanında kullanılan derin öğrenme mimarileri anlatılmıştır.

3.5.1.1. Derin sinir ağları (DSA)

Derin sinir ağları (DSA) ikiden fazla gizli katmana sahip, sınıflandırma ve regresyon için kullanılan yapıdır. Şekil 3.22’de derin sinir ağlarının yapısına örnek verilmiştir.



Şekil 3.22. Derin sinir ağları

3.5.1.2. Derin inanç ağları

Derin inanç ağları her bir alt ağda bulunan gizli katmanın bir sonraki için görünür katman olduğu, Kısıtlı Boltzman Makinesinin yığını olarak oluşturulmuştur. Genellikle görüntü tanıma ve üretmede kullanılmaktadır (Sertkaya, 2018).

3.5.1.3. Derin oto-kodlayıcılar


Derin Oto-Kodlayıcılarda giriş ve çıkış düğüm sayıları aynıdır ve denetimsiz öğrenme yöntemlerindendir. Eğitim için etiketli veriye ihtiyaç duymazlar. Girdi katmanında bulunan değerleri çıktı katmanına kopyalar bunnun sonucunda girdi olarak verilen veri çıktı katmanında tekrar oluşur (Uçar ve Uçar, 2019).

3.5.1.4. Derin boltzmann makinesi

Derin Boltzman makinesi, farklı katmanlar arasında yönlendirilmemiş bağlantılara sahiptir. Katmanlar içinde bulunan birimler birbirinden bağımsız olmasına karşın komşu katmanlara bağlıdır (Küçük ve Arıcı, 2018).

3.5.1.5. Evrişimli sinir ağları

Evrişimli sinir ağları, görüntü sınıflandırma, benzerlik kümeleme, nesne tanımak için kullanılan derin sinir ağıdır. Çok katmanlı algılayıcıların bir türü olan ESA görsel nitelikler arassında bulunan tüm hiyerarşik yapıyı bulmak için birden fazla katmana ihtiyaç duyar (Kaya vd., 2019). Şekil 3.22’de Evrişimli sinir ağı mimarisine örnek verilmiştir.



Şekil 3.23. ESA mimarisi

3.5.2. Python kütüphaneleri

Yapılan çalışmada öncelikle kullanıcının yapmak istediği işlemleri seçeceği ve kullanıcı ile program arasında iletişimi sağlayacak arayüz oluşturulmuştur. Kullanılan veri setinde bulunan görsellerin görüntülendiği, filtreleme işlemlerinin yapıldığı ve istenildiği durumlarda veri çoğaltma işleminin gerçekleştirilmesi ve son olarakta sınıflandırma algoritmalarının uygulandığı sistemde python programlama dili kütüphaneleri kullanılmıştır.

3.5.2.1. Tkinter

Python programlama diliyle gelen grafiksel kullanıcı arayüzü (GUI) aracıdır. Tkinter terimi Tk interface'in kısaltmasıdır. Görsel arayüz oluşturmak için gereken modülleri, sınıfları, sabitleri içerir. Tkinter ile görsel öğeler çalışılan işletim sistemi öğeleri tarafından oluşturulur ve bu sayede oluşturulan arayüzler o işletim sisteminin gibi görünürler (Lundh, 1999).

3.5.2.2. NumPy

NumPy bilimsel hesaplamalar için kullanılan nümerik dizi nesnesini temel alan python paketidir. Çok boyutlu dizi nesnesi, dizilerde matematiksel, mantıksal, şekil değiştirme gibi hızlı işlemler için rutin çeşitleri sağlar. Aynı zamanda ayrık Fourier dönüşümleri, temel istatistiksel işlemler, temel doğrusal cebir gibi işlemlerde de NumPy kullanılır (Oliphant, 2006).

3.5.2.3. Pandas

Pandas kütüphanesi, yüksek performanslı, veri yapıları ve veri analiz araçları sağlayan python kütüphanesidir. Pandas, NumPy'nin yüksek performanslı dizi hesaplama özelliklerini elektronik tablo ve ilişkisel veri tabanının esnek veri işleme yeteneği ile birleştirmiştir (McKinney, 2012). Özellikle sayısal tablolar ve zaman serilerinde değişiklikler yapmak için veri yapılarına ve işlemlere sahiptir (Wikipedia, 2020).

3.5.2.4. Matplotlib

Matplotlib 2D ve 3D grafik çizim kütüphanesidir (Ari ve Ustazhanov, 2014). Statik, animasyonlu veya etkileşimli görseller oluşturmada kullanılır. Matplotlib NumPy dizileri üzerine kurulan ve daha geniş SciPy yığını ile çalışmak üzere tasarlanan çok platformlu veri görselleştirme kütühanesidir.

3.5.2.5. Imageio

Imageio, animasyonlu görüntüler, bilimsel formatlar ve hacimsel veriler gibi çok çeşitli görüntü verilerini okumak ve yazmak için kullanılan python kütüphanesidir. Çapraz platformdur ve farklı görüntü formatlarında çalışma yapma imkânı sağlar (Dube, 2019).

3.5.2.6. Scikit-image

Scikit-image, görüntü işlemede kullanılan güçlü ve çeşitli araçların yüksek kalitede kullanıcıya sunan python kütüphanesidir (Van der Walt vd, 2014). Segmentasyon, analiz, filtreleme, morfoloji, özellik algılama, geometrik dönüşümler ve daha fazlasının yapıldığı python kütüphanesidir.

3.5.2.7. SciPy

Bilimsel hesaplamalar ve teknik işlemler için kullanılan python kütüphanesidir. SciPy tarafından kullanılan temel veri yapısı Numpy tarafından sağlanmış olan çok boyutlu dizilerdir. Kullanıcıların verileri manipüle etmesinde ve görselleştirmesinde kullanılır.

3.5.2.8. Pydicom

Pydicom DICOM dosyalarını okumak ve yazmak için kullanılan açık kaynaklı python kütüphanesidir (Mason, 2011).

3.5.2.9. OpenCv

Open Source Computer Vision Library, kısaca OpenCV yüz tanıma, hareket algılama, nesneleri 3 boyutlu modellerine ayıklama, hareketli nesneleri izleme gibi geniş uygulama alanı olan görüntü işleme kütüphanesidir. OpenCv, C ++, Python, Matlab/Octave ve Java arayüzlerine sahiptir.

3.5.2.10. Glob

Glob, Unix kabuğuyla ilgili kurallara göre belirlenmiş eşleştirme tekniklerini tanımlamak için kullanılan genel bir terimdir. Glob modülü belirtilmiş olan kalıpla eşleşen dosyaları veya yol adlarını almak için kullanılır. Glob, yerleşik olarak python ile gelmektedir (Van Rossum vd., 2017).

3.5.2.11. Keras

Pythonda yazılan açık kaynaklı sinir ağı kütüphanesidir. Keras düşük seviyeli hesaplamayı işlemek yerine bunun için başka bir kütüphane kullanır ve Google TensorFlow ve Theano üzerinde çalışabilen üst düzey bir API'dir (Arnold, 2017).

3.5.2.12. PIL

PIL (Python Image Library), python görüntü işleme kütüphanelerindendir. Birçok dosya biçimini destekleyen PIL güçlü görüntü işleme ve grafik özelliğine sahiptir. Görüntüyü piksel matrisi olarak kabul eder ve piksel düzeyinde değişiklik ve piksel değerlerinin ayarlanması gibi işlemlere izin verir (Olimid, 2011).

3.5.2.13. OS

Python OS modülü sayesinde yazmış olduğumuz program içerisinde işletim sistemi içerisinde bulunan izin ve dosyalar üzerinde işlemler yapabilmemizi sağlar.

3.5.2.14. TensorFlow


TensorFlow genelde karmaşık hesapları grafik olarak gösterir ve grafiklerin parçalarını bir kümede bulunan makinelere ya da tek bir makinenin işlemcilerine verimli bir şekilde eşleyerek basitleştirir (Shukla, 2018). Theano gibi derin öğrenmede kullanılmak üzere oluşturulan diğer sayısal kütüphanelerin aksine araştırma, geliştirme ve üretim sistemlerinde kullanılmak üzere tasarlanmıştır (Brownlee, 2016).

4. ARAŞTIRMA BULGULARI


Gelecekte yapılacak yapay zekâ çalışmalarında farklı disiplinlerde bulunan araştırmacılara kendi araştırmalarını özgürce yapmalarına imkân sağlamasına ve işlem aşamaları için farklı farklı programlar kullanmak yerine tek bir program üzerinde çalışmalarına yardımcı olmasını amaçladığımız bu tez çalışmasında kullanıcı arayüzü olan bir sistem tasarlanmıştır. Oluşturulan sistem için python programlama dili kullanılmıştır.

Programımıza ait arayüz tasarımı python programlama diline ait tkinter kütüphanesi kullanılmıştır. Sistemimiz bir ana pencere ve bu ana pencere üzerinden eriştiğimiz 3 alt pencereden oluşmaktadır ve en üstte menü bulunmaktadır.


Menü çubuğu üzerinde yer alan menü seçenekleri Şekil 4.1'de gösterilmiştir. Dosya menüsü üzerinde çalışmak istediğimiz görüntüleri ilgili dosyadan seçebildiğimiz aç seçeneğine sahiptir. Aç seçeneği altında bulunan kaydetme seçeneği üzerinde filtreleme işlemi uygulanmış görseli istediğimiz konuma kaydetmemizi sağlar. En altta yer alan Çık seçeneği uygulamanın kapatılması içindir Görüntü üzerinde yer alan görüntü seçeneği filtre uygulanmış olan görüntünün orijinal haline gelmesini sağlayan sıfırla seçeneğine sahiptir. Menü üzerinde yer alan görüntü işlemleri seçeneği alt pencerelere geçiş yapma seçeneklerinin ve DICOM verilerinde bulunan meta verilerini görüntüleme seçeneğinin bulunduğu bölümdür. Şekil 4.1'de menü çubuğu gösterilmiştir.



(a)



(b)




(c)

Şekil 4.1. Menü Çubuğu ve Alt Menüleri

Ana pencere Şekil 4.2’de gösterilmiş olduğu gibi 3 bölümden oluşmaktadır. Bu bölümler ana pencerenin tkinter framelere bölünmesiyle oluşturulmuştur ve daha sonra bu framer üzerine bölümlerin adlarının bulunduğu label framer eklenmiştir. Buton, listbox ve diğer araçlar label frame üzerinde oluşturulmuştur. Bunlardan birincisi filtreleme bölümüdür. Filtreleme işlemleri için SciPy ve PIL kütüphaneleri kullanılmıştır. 12 adet filtre seçeneğinin yer aldığı bu bölümde görüntülerimiz üzerinde uygulayacağımız filtrelerin parametre değerlerinin kullanıcı tarafından girilebileceği entry kutucuğu bulunmaktadır. Ayrıca görüntünün yönünü 45 derecelik açılarla değiştirebileceğimiz sol ve sağ olmak üzere iki buton yer almaktadır. İki numaralı bölüm menüde yer alan dosya seçeneğinde bulunan aç seçeneği ile

seçtiğimiz görüntünün görselleştirildiği yerdir. Imageio kütüphanesi kullanılarak okunan görüntüler DICOM, PNG, JPEG gibi formatlarda bulunabilir ve matplotlib kütüphanesiyle görselleştirilerek tkinter canvas ile arayüzümüzde görüntülenir. Üç numaralı bölümde seçilen görüntülerin DICOM formatında olduğu durumlarda görüntüye ait başlık bilgisinde yer alan ve görüntünün elde edilmesi, hastanın cinsiyeti, yaşı ve buna benzer bilgilerin yer aldığı metadatanın listelendiği listbox bulunmaktadır.



Şekil 4.2. Ana pencere

Ana pencereye ait alt pencereler 3 tanedir. Bunlardan birincisi sınıflandırma işlemleri sırasında elde yeterli veri bulunmadığı zaman veya veri setinde dengesiz bir dağılım olduğunda kullanılan veri artırma işleminin yapıldığı Şekil 4.3'te gösterilen Görüntü Ön İşleme penceresidir. 3 bölümden oluşan bu pencerede en üstte yer alan bölüm, görüntü seç butonu üzerinde veri artırma işlemini uygulayacağımız görüntümüzün uygulamaya kullanılmak üzere seçildiği bölümdür. İkinci bölümde resim üzerine uygulanabilecek değişikliklerin listelendiği bölümdür.

Burada 1 numara ile belirtilen bölümde bulunan fill mode dışında kalan seçenekler true veya false değeri yer almaktadır. Yalnızca fill mode seçeneği ise constant, nearest, reflect ve wrap parametrelerini almaktadır. 2 numara ile

belirtilen bölümde bulunan seçenekler sayısal parametreler alabilmektedir. En alta bulunan bölümde klasör seç ve oluştur butonları yer almaktadır. Klasör seç butonu veri arttırma işlemi sonrası görüntülerin kaydedileceği klasörü seçtiğimiz yerdir. Oluştur butonu ise veri arttırma işlemini başlattığımız butondur. Veri arttırma işlemleri için Keras kütüphanesinden ImageDataGenerator kullanılmıştır. Bir görüntüye uygulanan veri çoğaltma işlemi örneği Şekil 4.4'te gösterilmiştir. Solda yer alan parametre değerine sahip görüntülerin klasör içerisinde oluşturulmuş hali sağda bulunan resimde gösterilmiştir.

Görüntü Ön İşleme Penceresi

Görüntü Seç

8 no

1 Featurewise Center: False

Samplewise Center: False

Featurewise Std Normalization: False

Samplewise Std Normalization: False

Vertical Flip: True

Horizontal Flip: True

Fill Mode: nearest

2 Height Shift Range: 0.2

Width Shift Range: 0.2

Shear Range: 0.2

Zoom Range: 0.2

Channel Shift Range: 0.2


cval: 0.2

Rotation Range: 32

Number of Image : 30

Klasör Seç Oluştur

Şekil 4.3. Görüntü ön işleme penceresi




Şekil 4.4. Veri arttırma işlemi


Ana pencereye ait ikinci alt pencere Şekil 4.5'te gösterilen görüntü işleme penceresidir. Görüntülerin yer aldığı klasör üzerinde bütün resimlere aynı filtreleme işlemlerinin uygulandığı yerdir.

1 numaralı bölüm klasörde bulunan görüntülerin isimlerinin listelendiği yerdir. En üstte klasör adı yer alır ve daha sonra o klasör içinde yer alan görüntü dosyalarının isimleri listelenir. Bu işlem Os ve Glob kütüphaneleri kullanılarak listbox üzerinde gerçekleştirilir. 2 numaralı bölüm filtreleme seçeneklerinin görüntüler üzerinde hangi sıra ile uygulanacağını belirttiğimiz bölümdür. Filtreler uygulama üzerinde görünen sıra ile değil kullanıcının belirlemiş olduğu sıraya göre uygulanmaktadır. 3 numaralı bölüm uygulanabilecek filtrelerin ve işlemlerin isimlerinin yer aldığı bölümdür. Bu filtreler görüntü ön işleme olarak en çok tercih edilen filtrelerden oluşmaktadır. Bu pencereye ait son kısım olan 4. Pencerede filtreleme işlemlerine ait kullanıcı tarafından belirlenen parametre değerlerinin alındığı entry kutuları yer almaktadır. Adaptive histogram ve negative işlemleri dışında kalan işlemler sayısal değerler alırken bu iki işlem uygula seçeneğinin seçilmesi ile görünümler üzerine uygulanmaktadır. En altta yer alan butonlar sırasıyla görüntülerin bulunduğu klasörü açtığımız dosya aç butonu, belirlemiş olduğumuz filtrelerin uygulandığı görüntülerin kaydedileceği klasörü seçtiğimiz klasör seç butonu ve seçilen filtrelerin görüntüler üzerinde uygulama işlemini başlattığımız oluştur butonlarından oluşmaktadır. Şekil 4.6'de değerleri Şekil 4.5'te gösterildiği gibi belirlenmiş program ve bu

değerlere sonucunda oluşan filtreleme işlemlerinin uygulandığı görüntülerin yer aldığı klasörün resimleri verilmiştir. Solda orijinal resim dosyası sağda ise filtreleme sonrası verilmiştir.




Şekil 4.5. Görüntü işleme penceresi




Şekil 4.6. Klasörde bulunan resimlere filtreleme işlemi

Üçüncü ve son alt pencere görüntü sınıflandırma penceresidir. 3 bölümden oluşur.


1 numara ile gösterilen bölüm sınıflandırma algoritmalarının seçildiği, istenilen sayıda katmanların oluşturulduğu ve parametrelerin belirlendiği, araştırmacıların kendi modellerini oluşturdukları yerdir. 1. Klasör, 2. klasör butonları üzerinde sınıflandırma işlemi yapılacak klasörlerimizi seçtiğimiz butonlardır. Seçilen bu klasörler iki farklı özelliğin ayrı ayrı klasörlenmiş halleri olmalıdır. Örneğin kanserli veriler bir klasörde, sağlıklı veriler başka bir klasörde bulunmalıdır. Train-test size, train-valid test size bölümleri sınıflandırma sırasında verilerimizin train ve test işlemleri için hangi oranda bölünmesini istediğimizi belirttiğimiz yerdir. Ayrıca bu bölümde oluşturmak istediğimiz derin öğrenme ağının katmanlarını ve onların parametre değerlerini belirlediğimiz seçenekler bulunmaktadır. İlgili parametre değerleri girildikten sonra ekle butonu ile her katman uygulamamızda oluşmaktadır ve son olarak batch ve epoch size değerleri girilerek başla butonu ile sınıflandırma işlemi başlatılmaktadır. 2 numara ile gösterilen bölüm kullanıcı tarafından eklenmiş olan katmanların isimlerinin ve parametre değerlerinin ekleme işlemi gerçekleştikçe listelendiği ve sınıflandırma işlemi sonuç bilgilerinin yazdığı listboxtır. Son olarak 3 numara ile gösterilen bölüm hazırlanan modelin performansının matplotlib kütüphanesi kullanılarak grafiksel olarak gösterildiği yerdir. Model loss grafiği verilerimizin gerçek değerleri ile modelin öngördüğü değerler arasında bulunan mesafedir. Loss değeri ne kadar büyükse hata da o oranda artar. Model Accuracy ise veriler üzerinde yapılan hata sayısıdır. Şekil 4.7’de örnek olarak hazırlanmış ESA modeli gösterilmiştir. Şekil 4.8’de örnek olarak hazırlanmış DNN modeli gösterilmiştir.




Şekil 4.7. Görüntü sınıflandırma penceresi-ESA



Şekil 4.8. Görüntü sınıflandırma penceresi-DSA



Şekil 4.9. Görüntü sınıflandırma penceresi-ESA



Şekil 4.10. Görüntü sınıflandırma penceresi-DSA

Şekil 4.7 ve Şekil 4.8’de bulunan örneklerde kullanılmış olan veri seti herkese açık paylaşımı olan Brain MRI Images for Brain Tumor Detection <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection> adresinde bulunan Brain MRI Images for Brain Tumor Detection isimli veri setidir. Şekil 4.9 ve Şekil 4.10’da bulunan uygulama örneğinde kullanılmış olan veri seti herkese açık paylaşımı olan Brain-Tumor-Progression (Clark vd., 2013) adlı, <https://www.kaggle.com/andrewmvd/brain-tumor-progression> adresinde bulunan Brain Tumor Progression adlı veri setidir.



5. TARTIŞMA VE SONUÇLAR

Yogi Berra “Gelecek artık eskisi gibi değil” der. Yapay zekâ teknolojisinin hayatımıza girmesi eski alışkanlıklarımızı, davranışlarımızı ve çalışma şeklimizi değiştirmiştir. Teknolojik gelişmelerin üssel olarak arttığı bu zamanlarda buna ayak uydurmayan ülkeler başka ülkelerin teknolojisini kullanmak zorunda kalmaktadır. Bunun olumsuz sonuçlarından birisi alınan teknolojinin o ülkenin ekonomisine, yapısına uymaması ve yeniliklerin halka ulaşmadan sadece belli kesimlerce kullanılmasıdır.

Sağlık hizmetleri her insanın eşit olarak ulaşma hakkı olduğu kritik alanlardan birisidir. Bu alanda yapılacak araştırma ve geliştirmelere herkes kolaylıkla ulaşabilmeli veya insanlar kendi araştırmalarını bağımsız olarak yapabilmelidirler.

Bu tez çalışmasının çıkış noktası günümüzde artan, sağlık alanındaki yapay zekâ çalışmalarında araştırmacıların kendi araştırmalarını özgürce, farklı disiplinlerde çalışan araştırmacılara bağlı kalmadan hızlıca gerçekleştirebilmeleridir. Yazılım bilgisinin eksikliği medikal alanında yapılan çalışmalarda bireysel çalışmaları engellemektedir. Disiplinler arası çalışma, farklı bilgi ve düşüncelerin ortak çalışması ve ortaya yeni, taze fikirler konulması bakımından güzel, fakat çalışma hızını ise düşüren bir faktördür.

Türkçetin (2019) çalışmasında akciğer kanserine ait BT görüntülerini derin öğrenme modellerinde eğitmeden önce histogram eşitleme uygulamıştır ve daha sonra CNN ve DNN derin öğrenme modellerinde eğitmiştir. Arı vd. (2019) DICOM ve Jpeg görüntü formatında bulunan MR görüntülerine görüntü ön işleme işlemleri uygulanmış ve daha sonra veri sınıflandırma işlemleri uygulanmıştır. Bu çalışmalarda programlama bilgisi olmayan araştırmacılar görüntü işleme ve sınıflandırma için ayrı ayrı programlar kullanmakta ya da bu işlemleri yapan sistemi yazacak çalışma arkadaşları bulmaya çalışmaktadır. Bu tez çalışması, oluşacak zaman kayıplarını en aza indirmek için görüntü ön

işleme işlemlerini ve veri sınıflandırmak için kullanılan derin öğrenme modellerini içinde barındırmaktadır.

Bu tez çalışmasında gerçekleştirilen uygulamada yer alan CNN modelinin doğruluğunu test etmek için Github platformunda bulunan <https://github.com/girishkuniyal/Cat-Dog-CNN-Classifier> örneği ile kıyaslama yapılmıştır. Yapılan karşılaştırmada, aynı parametrelerde örnekten %97,56 doğruluk oranı elde edilirken, tez çalışmasındaki uygulama ile %96,27 doğruluk oranı elde edilmiştir. Buradaki sonuçların birbirine yakın fakat farklı çıkmasının sebebi eğitim ve test veri setinin rastgele seçilmesinden dolayı kaynaklanmıştır.

Öcal vd. (2020) yapmış oldukları çalışmada Eskişehir Osmangazi Üniversitesi Tıp Fakültesi öğrencilerinin yapay zekâ ile ilgili düşüncelerini araştırmışlardır. Araştırmaları sonucunda tıp öğrencilerinin büyük çoğunluğu yapay zekâyı duymuş olmalarına rağmen yarısına yakını tıpta kullanılan yapay zekâ uygulamaları hakkında bilgi sahibidir. Yapay zekânın hasta tanı ve tedavisinde faydalı olduğunu düşünen öğrenciler bu konuya ilgi duyuyor ve meslek hayatlarında kullanmak istiyorlar. Öcal vd. gelecekte bu konunun tıp fakültesi eğitim müfredatına da girebileceğini ve meslek hayatlarında kullanım arttıkça toplumunda tıpta yapay zekâ çağına hazır olacağını düşünmektedirler. Çizelge 5.1.'de yapılan çalışma sonunda grubunda bulunan öğrencilerin teknolojik gelişmelerile ilgili görüşleri verilmiştir. Çizelge 5.2.'de ise tıpta kullanılan yapay zekâ uygulamaları hakkında öğrencilerin görüşleri verilmiştir.

Çizelge 5.1. Öğrencilerin teknoloji konusundaki görüşleri (Öcal vd., 2020)

Sorular		n	%
Bilgisayar bilgi düzeyinizi nasıl değerlendirirsiniz?	Kötü	127	31.1
	Orta	175	42.7
	İyi	107	26.2
Bilgisayar ile ilgili herhangi bir eğitim aldınız mı?	Hayır	269	65.8
	Evet	140	34.2
Robotların hayatımıza girip insanlarla iletişim kurması sizi endişelendiriyor mu?	Hayır	243	59.4
	Evet	166	40.6
Yapay zekayı daha önce duydunuz mu?	Duymadım	26	6.4
	Duydum	383	93.6
Yapay zekanın günümüzde pek çok işi yapıyor olması sizi endişelendiriyor mu?	Hayır	252	61.6
	Evet	157	38.4
	Heyecanlandırıyor	111	27.1
Yapay zekanın hayatımıza giderek dahil olması, gelecek bakımından sizde nasıl bir duygu uyandırıyor?	İyimser bakmama neden oluyor	69	16.9
	Korkutuyor	48	11.7
	Merak uyandırıyor	170	41.6
Toplam		409	100.0

Çizelge 5.2. Öğrencilerin tıbbi yapay zekâ konusundaki görüşleri (Öcal vd., 2020)

Tıpta kullanılan yapay zeka uygulamaları ile ilgili düşünceleri		n	%
Tıpta kullanılan yapay zeka uygulamaları hakkında bilgi sahibisiniz?	Hayır	242	59.
	Evet	167	40.
İleride hekimlik hayatınızda yapay zekayı kullanmayı ister misiniz?	Hayır	85	20.
	Evet	324	79.
Yapay zeka kullanan hastaneler tanıda daha avantajlı mıdır?	Hayır	63	15.
	Evet	346	84.
Yapay zeka kullanan hastaneler tedavide daha avantajlı mıdır?	Hayır	65	15.
	Evet	344	84.
Tıp eğitiminde yapay zeka ile ilgili eğitim verilmeli mi?	Hayır	53	13.
	Evet	356	87.
Tıp fakültesinde yapay zeka uygulamaları olmasını ister misiniz?	Hayır	59	14.
	Evet	350	85.
Tıpta kullanılan yapay zeka uygulamaları daha yoğun kullanılmalı mıdır?	Hayır	93	22.
	Evet	316	77.
Tıpta kullanılan yapay zeka uygulamalarını güvenilir buluyor musunuz?	Hayır	90	22.
	Evet	319	78.

Bu çalışmada görüldüğü gibi gelecekte tıbbi yapay zekâ çalışmaları artacak ve mesleki yaşantıda büyük ölçüde yerini alacaktır. Bu tez çalışmasında ortaya koyulan program kullanım kolaylığı ve yapmış olduğu işlemlerin kapsamıyla ilerleyen zamanlarda geliştirilecek hastane ve araştırma sistemlerine örnek teşkil etmektedir. Açık kaynak kodlu programlama dili kullanılarak oluşturulan

program, geliştiricilerin katkılarıyla daha kapsamlı ve optimize hale gelerek herkesin yararlanabileceği ve kolay ulaşılabilen kapsamlı ve güçlü bir sisteme dönüşmesi açısından başlangıç olması amacıyla yapılmıştır.



KAYNAKLAR

- Acar, U., & Bayram, B. Morfolojik Görüntü Filtreleri ile İkonos Görüntülerinden Otomatik Bina Çıkarımı.
- Akpolat, G., 2019. Derin Öğrenme ile Pnömoni Hastalığını Tespit Etme. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 87s, İstanbul.
- Ali, N. A., Syafeeza, A. R., Geok, L. J., Wong, Y. C., Hamid, N. A., & Jaafar, A. S. (2019). Design of Automated Computer-Aided Classification of Brain Tumor Using Deep Learning. In Intelligent and Interactive Computing (pp. 285-291). Springer, Singapore.
- Arı, A., 2019. Derin Öğrenme Tabanlı Beyin MR Görüntülerinden Beyin Tümörlerinin Tespit Edilmesi ve Sınıflandırılması. İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 108s, Malatya.
- Arı, A., Hanbay, D. (2019). Tumor detection in MR images of regional convolutional neural networks. Journal of the Faculty of Engineering and Architecture of Gazi University, 34(3), 1395-1408.
- Arısoy, M. Ö., & Dikmen, Ü. Manyetik Belirti Haritalarının Histogram Eşitleme Yöntemi Kullanılarak İyileştirilmesi. Yerbilimleri, 35(2), 141-168.
- Ari, N., & Ustazhanov, M. (2014, September). Matplotlib in python. In 2014 11th International Conference on Electronics, Computer and Computation (ICECCO) (pp. 1-6). IEEE.
- Arnold, T. B. (2017). kerasR: R interface to the keras deep learning library. Journal of Open Source Software, 2(14), 296.
- Artuğer, F., & Özkaynak, F. (2018). JPEG Sıkıştırma Algoritmasının Dünyü Bugünü ve Geleceği. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 30(3), 161-167.
- Avcı, F., 2019. Derin Öğrenme Teknikleriyle Tomografi Görüntülerinde Karaciğer Bölütlemesi. Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 45s, Eskişehir.
- Aydoğan, T., 2008. Sinir Sistemi Görüntülenmesinde Farklı Görüntü Kayıtlarının Çıkarılması. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 73s, İstanbul.
- Aydoğdu, A., Aydoğdu, Y., & Yakıncı, Z. D. Temel Radyolojik İnceleme Yöntemlerini Tanıma. İnönü Üniversitesi Sağlık Hizmetleri Meslek Yüksek Okulu Dergisi, 5(2), 44-53.

- Cantemir, Z., 2019. Derin Öğrenme Yöntemleriyle Medikal Görüntü Sınıflandırma. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 80s, Ankara.
- Bilge, U. (2007). Tıpta Yapay Zeka ve Uzman Sistemler. Türkiye Bilişim Derneği Kongresi, 113-118.
- Bourke, P. (1998). BMP image format. BMP Files. July.
- Boyacı, A., & Ulaş, M. (2007). PACS ve Medikal Görüntülerin Sayısal Olarak Arşivlenmesi. Akademik Bilişim.
- Brownlee, J. (2016). Deep learning with Python: develop deep learning models on Theano and TensorFlow using Keras. Machine Learning Mastery.
- Catalbas, M. C., Issever, D., & Gulten, A. (2015, May). Morphological feature extraction with local histogram equalization. In 2015 23rd Signal Processing and Communications Applications Conference (SIU) (pp. 435-438). IEEE.
- Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., ... & Tarbox, L. (2013). The Cancer Imaging Archive (TCIA): maintaining and operating a public information repository. Journal of digital imaging, 26(6), 1045-1057.
- Demirhan, A., Kılıç, Y. A., & İnan, G. (2010). Tıpta yapay zeka uygulamaları.
- Dube, B. (2019). prysm: A Python optics module. Journal of Open Source Software, 4(37), 1352.
- Edizer, E. (2006). Sayısal görüntü işleme yöntemi ile tane boyut dağılımı analizi. Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans, 235s, Adana.
- Erdoğan, Z., 2019. U-NET Architecture Optimization for Optic Disc Segmentation in Retinal Images. Istanbul Technical University, M.Sc. Thesis, 43p, Istanbul.
- Ergen, M. (2019). What is Artificial Intelligence? Technical Considerations and Future Perception. Anatolian journal of cardiology, 22(Suppl 2), 5-7.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. Nature, 542(7639), 115.
- Gao, F., Wu, T., Li, J., Zheng, B., Ruan, L., Shang, D., & Patel, B. (2018). SD-CNN: A shallow-deep CNN for improved breast cancer diagnosis. Computerized Medical Imaging and Graphics, 70, 53-62.
- Gonzalez, R. C., & Woods, R. E. (2014). Sayısal görüntü işleme: üçüncü baskıdan çeviri. Palme Yayıncılık.

- Gönül, Y., Ulu, Ş., Bucak, A., & Bilir, A. (2015). Yapay sinir ağları ve klinik araştırmalarda kullanımı. Genel Tıp Dergisi, 25(3).
- Güzeldereli, E. A., Doğan, F., & Çetin, Ö. (2013). Medikal görüntü içerisine tıbbi bilgilerin gömülmesi için yeni bir yaklaşım. Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 17(2), 277-286.
- İnik, Ö., 2019. Derin Öğrenme Kullanarak Ovaryum Foliküllerinin Sınıflandırılması. Konya Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 88s, Konya.
- Kalkan, M. B., & Demirci, R. (2019). Görüntülerin Renk Uzayı Yardımıyla Ayırıştırılması ve Tekrarlı Uzunluk Kodlaması Tabanlı Görüntü Sıkıştırma. In 3rd International Symposium on Innovative Approach in Scientific Studies, Ankara (pp. 667-671).
- Karabulut, E.M., 2016. Investigation of Deep Learning Approaches for Biomedical Data Classification. Çukurova University, PhD. Thesis, 95p, Adana.
- Karakurt, M., 2019. Patoloji Görüntülerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması. Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 71s, Samsun.
- Kaya, U., Yılmaz, A., & Dikmen, Y. (2019). Sağlık Alanında Kullanılan Derin Öğrenme Yöntemleri. Avrupa Bilim ve Teknoloji Dergisi, (16), 792-808.
- Kızrak, M. A., & Özen, Y. D. D. F. Parmak İzi İyileştirme Yöntemlerine Yeni Bir Bakış: Histogram Bölütlemeli, Medyan Filtrelenmiş Parmak İzi İyileştirme Algoritması (HMPA).
- Küçük, D., & ARICI, N. (2018). Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine Bir Literatür Çalışması. Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi, 2(2), 76-86.
- Larobina, M., & Murino, L. (2014). Medical image file formats. Journal of digital imaging, 27(2), 200-206.
- Mason, D. (2011). SU-E-T-33: pydicom: an open source DICOM library. Medical Physics, 38(6Part10), 3493-3493.
- Murat, Uçar., & Emine, Uçar. Derin Otomatik Kodlayıcı Tabanlı Özellik Çıkarımı İle Android Kötücül Yazılım Uygulamalarının Tespiti. Yönetim Bilişim Sistemleri Dergisi, 5(2), 21-28.
- Lundh, F. (1999). An introduction to tkinter. URL: [www. pythonware. com/library/tkinter/introduction/index. htm](http://www.pythonware.com/library/tkinter/introduction/index.htm).

- McKinney, W. (2012). Python for data analysis: Data wrangling with Pandas, NumPy, and IPython. " O'Reilly Media, Inc."
- Mehr, H.D., 2017. Classification Of Lung CT Images Using Deep Convolutional Neural Network. Gazi University, M.Sc. Thesis, 92p, Ankara.
- Mesut, A., & Carus, A. (2005). Kayıpsız Görüntü Sıkıştırma Yöntemlerinin Karşılaştırılması. II. Mühendislik Bilimleri Genç Araştırmacılar Kongresi, MBGAK İstanbul, 93-100.
- Mildenberger, P., Eichelberg, M., & Martin, E. (2002). Introduction to the DICOM standard. European radiology, 12(4), 920-927.
- Oh, S. L., Hagiwara, Y., Raghavendra, U., Yuvaraj, R., Arunkumar, N., Murugappan, M., Acharya, U. R. (2018). A Deep Learning Approach For Parkinson's Disease Diagnosis From EEG Signals. Neural Computing and Applications, 1-7.
- Olimid, R. (2011). Python implementation of visual secret sharing schemes. Journal of Information Systems & Operations Management, 5(2.1), 538-550.
- Oliphant, T. E. (2006). A guide to NumPy (Vol. 1, p. 85). USA: Trelgol Publishing.
- Öcal, E. E., Emrah, Atay., Önsüz, M. F., Algin, F., Çokyiğit, F. K., Kılınç, S., ... & Yiğit, F. N. Tıp Fakültesi Öğrencilerinin Tıpta Yapay Zeka ile İlgili Düşünceleri. Türk Tıp Öğrencileri Araştırma Dergisi, 2(1), 9-16.
- Örnek, A.H., 2019. Yeni Doğan Bebeklerin Termal Görüntülerinin Derin Öğrenme Yöntemleri ile Sınıflandırılması. Konya Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 101s, Konya.
- Pandey, P., 2019. 10 Python image manipulation tools. Erişim Tarihi: 15.07.2020. <https://towardsdatascience.com/image-manipulation-tools-for-python-6eb0908ed61f>
- Pattnaik, R., 2018. Tools For Image Processing. Erişim Tarihi: 15.07.2020. <https://medium.com/image-vision/tools-for-image-processing-5ef294d5704a>
- Pennebaker, W. B., & Mitchell, J. L. (1992). JPEG: Still image data compression standard. Springer Science & Business Media.
- Safdar, M. F., Alkobaisi, S. S., & Zahra, F. T. (2020). A Comparative Analysis of Data Augmentation Approaches for Magnetic Resonance Imaging (MRI) Scan Images of Brain Tumor. Acta Informatica Medica, 28(1), 29.
- Saha, S. (2000). Image compression—from DCT to wavelets: a review. XRDS: Crossroads, The ACM Magazine for Students, 6(3), 12-21.

- Sajja, T., Devarapalli, R., & Kalluri, H. (2019). Lung Cancer Detection Based on CT Scan Images by Using Deep Transfer Learning. *Traitement du Signal*, 36(4), 339-344.
- Sertkaya, M.E., 2018. Derin Öğrenme Tekniklerinin Biyomedikal İmgeler Üzerine Uygulamaları. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 60s, Elazığ.
- Shukla, N. (2018). Machine learning with TensorFlow. Manning Publications Co..
- Solak, S., & Altınışik, U. (2018). Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. *Sakarya University Journal of Science*, 22(1), 56-65.
- Sumner, R. (2014). Processing RAW images in MATLAB. Department of Electrical Engineering, University of California Santa Cruz.
- Sertkaya, M.E., 2018. Akciğer Kanserinin Tespit Edilmesinde Derin Öğrenme Algoritmalarının. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 60s, Elazığ.
- Şahin, A. R., Ateş, S., & Günay, M. (2019). Klinik Mikrobiyoloji Laboratuvarlarında Yapay Zekanın Temel İşleyiş Modelleri. *Journal of Biotechnology and Strategic Health Research*, 3(2), 66-71.
- Tuççe, Uzun Yapay Zeka Ve Sağlık Uygulamaları. İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 3(1), 80-92.
- Ulaş, M. (2006). Radyolojik görüntülerin sayısal olarak arşivlenmesi ve ağ üzerinden paylaşılması/Digital archiving radiological images and share at network.
- Ulaş, O. M., & Boyacı, O. A. DICOM Görüntü Standardı. *Akademik Bilişim*, 7, 69-74.
- Van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., ... & Yu, T. (2014). scikit-image: image processing in Python. *PeerJ*, 2, e453.
- Van Rossum, G., & Drake, F. L. (1995). Python library reference.
- Wang, P., Liu, F., Yang, C., & Luo, X. (2018). Blind forensics of image gamma transformation and its application in splicing detection. *Journal of Visual Communication and Image Representation*, 55, 80-90.
- Wei, W. Y. (2008). An introduction to image compression. National Taiwan University, Taipei, Taiwan, ROC.

Wikipedia. (2020). pandas (software). Eriřim Tarihi: 15.07.2020.
[https://en.wikipedia.org/wiki/Pandas_\(software\)#cite_note-5](https://en.wikipedia.org/wiki/Pandas_(software)#cite_note-5)

Wikipedia. (2020). Yapay zekâ. Eriřim Tarihi: 15.07.2020.
https://tr.wikipedia.org/wiki/Yapay_zek%C3%A2

Yancı, M., 2019. Derin Öğrenme Yöntemleri ile Medikal Görüntülerde Kanserli Doku Tespiti. Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 75s, İstanbul.



ÖZGEÇMİŞ

Adı Soyadı : Şule Beste KAPÇI
Doğum Yeri ve Yılı : İstanbul, 1993
Medeni Hali : Bekar
Yabancı Dili : İngilizce
E-posta : yl1830138018@ogr.sdu.edu.tr

Eğitim Durumu

Lise : Acıpayam Anadolu Lisesi, 2010
Lisans : Süleyman Demirel Üniversitesi, Mühendislik Fakültesi,
Bilgisayar Mühendisliği, 2018
Yüksek Lisans : Süleyman Demirel Üniversitesi, Mühendislik Fakültesi,
Bilgisayar Mühendisliği, 2020