



T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

AKCİĞER KANSERİNİN DERİN ÖĞRENME
YAKLAŞIMLARI KULLANILARAK TESPİT
EDİLMESİ

Ferhat AYAYNA

YÜKSEK LİSANS

Danışman: Dr. Öğr. Üyesi Abidin ÇALIŞKAN

Elektrik-Elektronik Mühendisliği Anabilim Dalını

Mart-2023
BATMAN
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Ferhat AYAYNA tarafından hazırlanan “**AKCİĞER KANSERİNİN DERİN ÖĞRENME YAKLAŞIMLARI KULLANILARAK TESPİT EDİLMESİ**” adlı tez çalışması 20/03/2023 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS** olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Yılmaz KAYA

.....

Danışman

Dr. Öğr. Üyesi Abidin ÇALIŞKAN

.....

Üye

Doç. Dr. Melih KUNCAN

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Osman PAKMA
Lisansüstü Eğitim Enstitüsü Müdür V.

TEZ BİLDİRİMİ

Yapmış olduğum tez çalışmasını Batman Üniversitesi Lisansüstü Eğitim Enstitüsü tarafından belirlenen tez yazım ve kurallarına uygun bir şekilde hazırladığımı ve tüm bilgi ve kaynakların etik akademik kurallar içerisinde elde ettiğimi hazırladığım bu çalışma süresince elde ettiğim her türlü ifade ve bilginin kaynağına eksiksiz atıf yaptığımı bildiririm.

DECLARATION PAGE

I have prepared this thesis in accordance with the thesis writing and rules determined by the Batman University Graduate Education Institute and I declare that all information and resources I have obtained within the framework of ethical academic rules have been fully cited to the source of all kinds of statements and information I have obtained during this study.

Ferhat AYAYNA

20/03/2023

ÖZET

YÜKSEK LİSANS

AKCİĞER KANSERİNİN DERİN ÖĞRENME YAKLAŞIMLARI KULLANILARAK TESPİT EDİLMESİ

Ferhat AYAYNA

**Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Abidin ÇALIŞKAN

2023, 64 Sayfa

Jüri

**Danışman: Dr. Öğr. Üyesi Abidin ÇALIŞKAN
Doç. Dr. Yılmaz KAYA
Doç. Dr. Melih KUNCAN**

Kanser, dünyadaki tüm ülkelerde ölüm sebebi ve kötü yaşam kalitesinin en büyük nedenlerinden olarak ilk sıralarda yer almaktadır. Dünya sağlık örgütü'nün 2019 yılındaki kayıtlarına göre yapmış olduğu tahminlerde kanser 183 ülkenin 112 'inde 70 yaş üzerindeki ölümlerin nedenleri arasında birinci veya ikinci sırada bulunurken 23 ülkede ise ölüm nedeni olarak üçüncü veya dördüncü sırada yer alır. Koroner kalp hastalığından ve inmeden dolayı ölenlerin oranlarındaki düşüş kanserin öneminin artmasına neden olmuştur. 2020 yılında 2,2 milyon yeni teşhis (tüm kanserler arasında yaklaşık %11,4) ve 1,8 milyon ölüm nedeni olarak akciğer kanseri en çok teşhis edilen kanserler arasında ikinci, ölüm sebebi olarak birinci sırada yer almıştır. Akciğer kanserinin teşhis edilmesinde ve tedavi sürecinde tıbbi görüntüleme tekniklerin önemi büyüktür. Bilgisayarlı tomografi, göğüs röntgeni, manyetik rezonans görüntüleme, moleküler görüntüleme teknikleri ve pozitron emisyon tomografisi akciğer kanserinin tespit edilmesinde önemli yer tutarlar. Kullanılan bu tekniklerin en büyük eksiklikleri arasında, başka patolojik rahatsızlığı olan hastalar için uygun olmayan ve kanser türünün sınıflandırılabilmesi gibi sorunlar yer alır. Bu kanser için erken teşhis ve sınıflandırma için yeni yaklaşımlarda bulunmak gerekmektedir. Tıpta görüntüleme alanında değeri artan konulardan biri olarak derin öğrenme yöntemi giderek daha fazla kullanılmaya başlanmıştır. Doktorların akciğer kanseri için daha net ve daha hızlı bir şekilde karar vermelerinde yapay zekâ ve derin öğrenmeyi kapsayan tıbbi cihazların geliştirilmesi son derece önemlidir. Bu çalışmada, akciğer kanserinin tespit ve sınıflandırılması için VGG16, VGG19 ve Xception yöntemleri kullanılmıştır. Derin öğrenme tabanlı yöntemler kullanılarak yapılan çalışmalarda, önerilen yaklaşım ile VGG16, VGG19 ve Xception yöntemleri ile %94,19, %95,24 ve %90,14 oranında başarı elde edilmiştir.

Anahtar Kelimeler: Akciğer kanseri, bilgisayarlı tomografi, derin öğrenme, evrimsel sinir ağları, transfer öğrenme.

ABSTRACT

MS THESIS

USING DEEP LEARNING APPROACHES FOR DETECTION LUNG CANCER

Ferhat AYAYNA

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
BATMAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL ELECTRONICS ENGINEERING**

Advisor: Asst. Prof. Dr. Abidin ÇALIŞKAN

2023, 64 Pages

Jury

Asst. Prof. Dr. Abidin ÇALIŞKAN

Assoc. Prof. Dr. Yılmaz KAYA

Assoc. Prof. Dr. Melih KUNCAN

Cancer is one of the leading causes of death and poor quality of life in all countries in the world. According to the estimations made by the World health organization in 2019, cancer ranks first or second among the causes of death over the age of 70 in 112 of 183 countries, while it ranks third or fourth as the cause of death in 23 countries. The decline in the rates of deaths from coronary heart disease and stroke has led to an increase in the importance of cancer. With 2.2 million new diagnoses (about 11.4% among all cancers) and 1.8 million deaths in 2020, lung cancer was the second most diagnosed cancer and the first cause of death. Medical imaging techniques are of great importance in the diagnosis and treatment process of lung cancer. Computed tomography, chest X-ray, magnetic resonance imaging, molecular imaging techniques and positron emission tomography play an important role in detecting lung cancer. Among the biggest shortcomings of these techniques used are problems such as unsuitability for patients with other pathological conditions and inability to classify cancer type. New approaches are needed for early diagnosis and classification for this cancer. Deep learning method has started to be used more and more as one of the topics that has an increasing value in the field of imaging in medicine. The development of medical devices including artificial intelligence and deep learning is extremely important for doctors to make clearer and faster decisions for lung cancer. In this study, VGG16, VGG19 and Xception methods were used for detection and classification of lung cancer. In studies using deep learning-based methods, 94.19%, 95.24% and 90.14% success rates were obtained with the proposed approach and VGG16, VGG19 and Xception methods.

Keywords: Lung cancer, computed tomography, deep learning, convolutional neural networks, transfer learning.

ÖNSÖZ

Yüksek lisans eğitimim boyunca ve çalışmalarımda beni destekleyen, yönlendiren, fikirleri ile sürekli gelişimimi sağlayan danışmanım Sayın Dr. Öğr. Üyesi Abidin ÇALIŞKAN'a, deneyimlerini paylaşan Öğr. Gör. Ammar ASLAN'a ve çalışmam boyunca beni sürekli destekleyen, maddi ve manevi her türlü konularda bana yardımcı olan aileme teşekkürlerimi bir borç bilirim.

Ferhat AYAYNA
BATMAN- 2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER	ix
ÇİZELGELER	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
1.1. Kanser Nedir.....	6
1.2. Kanser Çeşitleri ve Oranları	7
1.2.1. Türkiye’de Kanser İstatistikleri	11
1.3. Akciğer Kanseri.....	12
1.3.1. İyi Huylu Akciğer Kanseri	13
1.3.2. Kötü Huylu Akciğer Kanseri	14
1.4. Akciğer Görüntüleme Teknikleri.....	15
1.4.1. Bilgisayarlı Tomografi	16
1.4.2. Akciğer Kanserinin BT ile Tespiti.....	21
1.4.3. Pozitron Emisyon Tomografi	25
1.4.4. PET ile Akciğer Kanseri Tespiti	26
1.5. Görüntü işleme	27
2. MATERYAL VE YÖNTEM	29
2.1. Akciğer Görüntü Veri Seti	29
2.1.1. DICOM Standartı.....	30
2.2. Çalışmada Kullanılan Programlama Dili	31
2.3. Bu Çalışmada Kullanılan Kütüphaneler.....	31
2.3.1. Pandas	31
2.3.2. Numpy	32
2.3.3. Matplotlib	32
2.3.4. Tensorflow.....	32
2.3.5. Keras	32
3. YAPAY ZEKÂ UYGULAMALARI.....	33
3.1. Tıpta Yapay Zekâ Uygulamaları	34
3.2. Yapay Sinir Ağları.....	34
3.3. Derin Öğrenme	35
3.4. ESA Derin Öğrenme Modeli.....	36
3.5. VGG16 Mimarisi.....	38
3.6. VGG19 Mimarisi.....	39

3.7. Xception Mimarisi	39
3.8. Evrişimsel Sinir Ağı Katmanları	40
3.8.1. Evrişimsel Katman.....	40
3.8.2. Havuzlama Katmanı.....	41
3.8.3. Düzleştirme Katmanı	42
3.8.4. Bırakma Katmanı	42
3.9. Sınıflandırma Modellerinin Değerlendirilmesi	43
3.9.1. Doğruluk Oranı	43
3.9.2. Kayıp Oranı	44
3.9.3. Performans Metriği	44
4. BULGULAR VE TARTIŞMA	46
4.1. VGG16	47
4.2. VGG19	48
4.3. Xception	50
5. SONUÇ VE ÖNERİLER.....	53
6. KAYNAKLAR.....	54
7. ÖZGEÇMİŞ.....	64

ŞEKİLLER

Şekil 1.1. BT akciğer görüntüsü.....	2
Şekil 1.2. 2019'da <70 yaşında ölüm nedeni olarak ulusal kanser sıralaması.....	8
Şekil 1.3. Katmanlı İnsani Gelişme Endeksi.....	9
Şekil 1.4. 2020 yılına ait Türkiye’de kanser istatistikleri.....	11
Şekil 1.5. İyi huylu (Benign) akciğer kanseri görüntüsü (IQ-OTH/NCCD).....	14
Şekil 1.6. Kötü huylu (Malign) akciğer kanseri görüntüsü (IQ-OTH/NCCD).....	15
Şekil 1.7. Bilgisayarlı Tomografi.....	17
Şekil 1.8. BT Bölümleri.....	17
Şekil 1.9. BT çalışma şekli.....	18
Şekil 1.10. BT bilgisayar ünitesi.....	19
Şekil 1.11. BT görüntüleme ünitesi.....	19
Şekil 1.12. Akciğer BT görüntüsü.....	23
Şekil 1.13. Nodül tespitli akciğer BT görüntüsü.....	23
Şekil 1.14. Görünür Nodül tespitli akciğer BT görüntüsü.....	24
Şekil 1.15. İşaretli Nodül tespitli akciğer BT.....	25
Şekil 1.16. PET Cihazı.....	26
Şekil 1.17. PET ile Akciğer Tümör görüntüsü.....	27
Şekil 1.18. Görüntü işleme adımları.....	28
Şekil 1.19. PET ile Akciğer Tümör görüntüsü	29
Şekil 2.1. Akciğer görüntü veri seti.....	30
Şekil 2.2. Python logo	31
Şekil 3.1. YSA mimarisi.....	35
Şekil 3.2. Derin öğrenme mimarisi.....	36
Şekil 3.3. ESA model örneği görselleştirmesi	37
Şekil 3.4. VGG16 mimarisi	38
Şekil 3.5. VGG19 mimarisi.....	39
Şekil 3.6. Xception mimarisi.....	40
Şekil 3.7. Görüntüleri ölçekleme.....	40
Şekil 3.8. Evrişim işleminin gösterimi.....	41
Şekil 3.9. Maksimum havuzlama.....	42
Şekil 3.10. Düzleştirme (Flatten).....	42
Şekil 3.11. Standart sinir ağı ve bırakma sonrası sinir ağı.....	43
Şekil 3.12. AİK eğrisi.....	45

Şekil 4.1. Önerilen Derin Öğrenme Modeli.....	46
Şekil 4.2. VGG16 ile Önerilen model için doğruluk grafiği.....	48
Şekil 4.3. VGG16 ile Önerilen model için kayıp grafiği.....	48
Şekil 4.4. VGG19 ile Önerilen model için doğruluk grafiği.....	49
Şekil 4.5. VGG19 ile Önerilen model için kayıp grafiği.....	49
Şekil 4.6. VGG19 ile Önerilen model ile sınıflandırma.....	50
Şekil 4.7. Xception ile Önerilen model için doğruluk grafiği.....	51
Şekil 4.8. Xception ile Önerilen model için kayıp grafiği.....	51

ÇİZELGELER

Çizelge 1.1. 2020 Yılında 36 Kanser ve Tüm Kanserlerde Kombine Yeni Vakalar ve Ölümmler.....	9
Çizelge 1.3.1. X-ışını yöntemlerinin ayırabildiği dokular.....	21
Çizelge 4.1. VGG16 için Eğitim tur (Epoch) tablosu.....	47
Çizelge 4.2. VGG19 için Eğitim tur (Epoch) tablosu.....	48
Çizelge 4.3. Xception için tur (Epoch) tablosu.....	50
Çizelge 4.4. Modellerimizden elde ettiğimiz sonuçların karşılaştırılması.	51
Çizelge 4.5. Benzer veri setleri ile gerçekleştirilmiş çalışmaların karşılaştırılması.....	52

SİMGELER VE KISALTMALAR

AİK	: Alıcı İşlem Karakteristiği
BDT	: Bilgisayar Destekli Tespit
BT	: Bilgisayarlı Tomografi
DÖ	: Derin Öğrenme
DVM	: Destek Vektör Makineleri
ESA	: Evrişimsel Sinir Ağı
k-NN	: k-En Yakın Komşu
MR	: Manyetik Rezonans
MÖ	: Makine Öğrenmesi
PET	: Pozitron Emisyon Tomografi
US	: Ultrason
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ


1. GİRİŞ

Akciğerdeki nodüller, erkeklerdeki kanser morbidite ve mortalitesinin ilk sırada gelen sebebi iken, insidans açısından meme kanseri ve kolorektal kanserinin ardından üçüncü ve can kaybı oranında meme kanserinin ardında ikinci sırada bulunur (Sung ve ark., 2021). Akciğer kanseri şüphesi olan hasta tanı değerlendirmeleri, dokuların tanımlarını içerir; metastazlar dahil değerlendirmeler de olmak üzere tam bir evreleme çalışması yapılmalıdır (Dwivedi ve ark., 2014). Histolojik tanı erişilebilir lenf nodu biyopsisi, transtorasik iğne aspirasyonu, balgam sitolojisi, bronkoskopi, torasentez, video yardımcı torakoskopi veya torakotomi. Metastatik hastalık için ilk değerlendirme hasta öyküsüne ve fizik muayeneye, laboratuvar testlerine, bilgisayarlı göğüs tomografisine, pozitron emisyon tomografisi (PET) ve mediastinal tutulumun doku teyidinde dayanır (Collins ve ark., 2007). Metastazlar için ileri değerlendirme klinik tabloya bağlıdır. Tedavi ve prognoz, tanımlanan tümörün tipine ve evresine yakından bağlıdır. İlerlemiş küçük hücreli olmayan karsinom, radyoterapi, kemoterapi ve palyatif bakımı içerebilen multimodalite bir yaklaşımla tedavi edilir. Kemoterapi (sınırlı hastalık için radyoterapi ile birlikte), küçük hücreli karsinom tedavisinin temel dayanağıdır (Collins ve ark., 2007).

Konvansiyonel göğüs radyografisi, bilgisayarlı tomografi (BT), manyetik rezonans (MR) ve PET, akciğer kanserinin ölçümü, karakterizasyonu, evrenlemesi ve takibi için kullanılan görüntülemelerdir (Schalekamp ve ark., 2022). BT'nin başarısı, tümörün lokalizasyonu ve yaygınlığı, genişlemiş lenf nodlarının varlığı ve metastatik hastalık varlığı gibi çok detaylı görüntüleme bilgilerinin sağlanabilmesine bağlıdır. Entegre PET/BT'nin, BT'den alınan anatomik bilgileri PET'den gelen metabolik yapılarla birleştirir. PET/BT'nin günümüzde kanserin evrenlenmesi için en iyi görüntüleme tekniğidir (De Wever ve ark., 2009).

Sağlık alanında uzun yıllardır derin öğrenme (DÖ) ve yapay zekâ (YZ) çalışmaları, çeşitli tanımlama ve inceleme için kullanılmaktadır (Çalışkan, 2023a; Çalışkan, 2023b). DÖ verileri, orijinal görüntülerde olmayan belirgin görüntü özelliklerini çıkarmaktadır. Spesifik olarak, evrişimli sinir ağı'nın (ESA) özelliği çıkarma ve öğrenmede son derece faydalı olduğu savunulmuştur ve bu nedenle araştırma topluluğu tarafından geniş çapta benimsenmiştir (Krizhevsky ve ark., 2012).

Son zamanlarda, akciğer kanserini tespit etmek için BT görüntülerini kullanan DÖ yöntemleri ile ilgili önemli çalışmalar yapılmıştır (Nasrullah ve ark., 2019; Gumma ve ark., 2022; Reddy ve Khanaa, 2023; Shimazaki ve ark., 2022).



Şekil 1.1. BT akciğer görüntüsü (Erbaş, 2011).

Bhatia ve ark. (2019), DÖ kullanarak BT taramalarından akciğer kanserini tespit etmek için bir yaklaşım sunmuşlardır. UNet ve ResNet modellerini kullanarak kansere karşı sonuçları tarama bölgelerini kullanır ve özelliklerini çıkarmak için bir dizi ön işlemeyi ölçerek tanımlamışlardır. Özellik seti birden çok sınıflandırıcıya besliyor, yani. XGBoost ve Random Forest ve bireysel tahminler, bir BT performansının kanserli olma tahminini bir araya getirmek için bir araya getirdi. LIDC-IRDI'de elde edilen doğruluk, önceki denemelerden daha iyi performans gösteren %84 olarak geliştirmişlerdir.

Ayrıca Asuntha ve ark. (2020), kanserli tarama nodüllerinin yerini tespit etmek için yeni DÖ yöntemlerini kullanmışlardır. Bu çalışmalarda, yönlendirilmiş Gradyanların Histogramı, dalgacık yangını kalıntıları özellikleri, yerel ikili model, ölçek değişmeyen özellik dönüşümü ve zernike momenti gibi en iyi özellik çıkarma tekniklerini kullanmışlardır. Doku, geometrik, hacim ve yapı özellikleri çıkarıldıktan sonra, en iyi özelliğin açıklamaları için bulanık parçacık sürü optimizasyonu (BPSO) dışlamasını uygulamış, son olarak da bu özellikleri DÖ kullanarak sınıflandırmışlardır. Gerçek zamanlı bir veri seti olan Arthi Scan Hospital'dan gelen başka bir veri seti üzerinde ek bir değerlendirme görmüş sonuçlardan, yeni BPSO ESA'nın diğer tekniklerden daha iyi performans göstermişlerdir.

Cengil ve ark. (2018) ise, SPIE-AAPM-LungX verilerinin BT görüntüsünü kullanarak tarama nodüllerinin elde edilmesi oluşturulmuşlardır. DÖ, son yıllarda

kavrama işlemi için popüler bir seçim olmuştur. Özellikle DÖ, kitaplıklarından tensorflow ve üç boyutlu ESA mimarisinin kullanımında kullanılır.

Niki ve ark. (2001), projelerinde; akciğer nodüllerinin tespiti ve toplanmasında k-en yakın komşu (k-NN) algoritması yardımıyla, kötü veya iyi huylu olarak ayrıştırılmasında lineer karmaşıklık algoritmasından yararlanmışlardır. %80 gibi bir doğruluk dercesinde elde ettikleri sonuçtan destek vektör makineleri (DVM) algoritması kullanılmıştır.

Ciampi ve ark. (2017) yapmış oldukları çalışmada çok ölçekli ESA modeli kullanıp akciğer kanseri nodüllerinin sınıflandırılmasını sağlamışlardır. Yapmış oldukları bu çalışma için Danimarka akciğer kanseri taraması ve çok merkezli İtalyan akciğer saptama veri setlerini kullanılmıştır. Elde edilen tahminler ile radyologların tahminleri birbirine yakın sonuç vermiş ve bu ESA modeli %79.5 doğruluk bulmuştur.

Teramoto ve Fujita (2013) yaptıkları çalışmada, akciğer nodülünün hızlı tespit şemasını önermişlerdir. Silindirik nodül iyileştirme filtresi kullanarak göğüs BT görüntülerini “Lung Image Database Consortium (LIDC)” halka açık görüntü veri tabanını kullanmışlardır. Sonuç olarak %80'nin doğru bir şekilde tespit ettiklerini göstermişlerdir.

Song ve ark. (2017), çalışmalarında verilerini LIDC-IDRI almışlardır ve akciğer kanserinin sınıflandırılması için çeşitli algoritmaları karşılaştırmışlardır. Sonuç olarak derin sinir ağları (DSA), ESA ve SAE algoritmalarının başarı yüzdeleri sırasıyla %82,37, %84,15 ve %82,59 olarak bulmuşlardır.

Elnakib ve ark. (2020), düşük doz BT görüntülerinden akciğer nodüllerinin erken tespiti için bir bilgisayar destekli tespit sistemi önermişlerdir. Önerilen sistem başlangıçta düşük doz görüntülerin kontrastını iyileştirmek için ham verileri önceden işler. Kompakt DÖ özellikleri daha sonra Alex, VGG16 ve VGG19 ağları dâhil olmak üzere farklı DÖ mimarileri araştırılarak çıkarılır. Çıkarılan özellik setini optimize etmek için, erken tespit için en alakalı özellikleri seçmek üzere bir genetik algoritma eğitilir. Son olarak, akciğer nodüllerini doğru bir şekilde saptamak için farklı türde sınıflandırıcılar test edilir. Sistem, çevrimiçi bir kamu akciğer veri tabanı, yani uluslararası erken akciğer kanseri eylem projesi, I-ELCAP kullanılarak, 50 farklı denekten alınan 320 LDCT görüntüsü üzerinde test edilmiştir. VGG19 mimarisini ve DVM sınıflandırıcısını kullanan önerilen sistem, %96,25 ile en iyi tespit doğruluğunu, %97,5 ile hassasiyeti ve %95 ile özgüllüğü elde etmiştir. Diğer modern yöntemlerle karşılaştırıldığında, önerilen sistem umut verici sonuçlar vermiştir.

Sun ve ark. (2016), çalışmalarında, Lung Image Database Consortium (LIDC) veri tabanındaki vakalarla akciğer kanseri teşhisi için DÖ algoritmalarının kullanılmasının uygulanabilirliğini test etmişlerdir. Her BT dilimindeki nodüller, radyologlar tarafından sağlanan işaretlere göre bölümlere ayırmışlardır. Aşağı örnekleme ve döndürmeden sonra, her biri 52x52 piksel olan 174412 örnek ve karşılık gelen doğruluk dosyaları elde etmişlerdir. Deep belief networks (DBNs), ESA, stacked denoising autoencoder (SDAE) gibi üç DÖ algoritması tasarlayıp uygulamışlardır. DÖ algoritmalarının performanslarını bilgisayar destekli tespit (CADx) uygulamaları ile karşılaştırmak için 28 görüntü özelliği ve DVM içeren bir şema tasarlamışlardır. ESA, DBN'ler ve SDAE'nin doğrulukları sırasıyla 0,7976 0,8119 ve 0,7929 bulmuşlardır. Tasarladıkları geleneksel CADx'in doğruluğu, ESA ve DBN'lerden biraz daha düşük olan 0,7940 olarak tespit etmişlerdir. Ayrıca, DBN'leri kullanan yanlış etiketlenmiş nodüllerin, geleneksel CADx'i kullananlardan %4 daha büyük olduğunu fark etmiş, bunun nedeni nodüllerin bazı boyut bilgilerini kaybeden aşağı örnekleme sürecinden kaynaklanıyor olabileceğini belirtmişlerdir.

Yu ve ark. (2020), yapmış oldukları retrospektif çalışmada, model değerlendirmesi için 300 hasta taramasından oluşan bir veri seti kullandı; 150 hasta taraması yarışma setinden ve 150 hasta taraması bağımsız bir veri setindendi. Her iki test veri seti de 50 kanser pozitif tarama ve 100 kanser negatif tarama içeriyordu. Referans standardı, kanser pozitif taramalar için histopatolojik inceleme ve kanser negatif taramalar için en az 2 yıllık görüntüleme takibi ile belirlendi. Test veri kümeleri, Kaggle Data Science Bowl 2017 halka açık yarışmasında en iyi performans gösteren üç algoritmaya uygulamışlardır: Daniel Hammack (JWDH), grt123, Julian de Wit ve Yardım. Model çıktıları, aynı test veri setlerini değerlendiren 11 radyologun gözlem çalışmasıyla karşılaştırmışlar. Her tarama hem DÖ algoritmaları hem de radyologlar tarafından sürekli bir ölçekte puanlamışlar. Performans, çok okuyuculu, çok durumlu alıcı işletim karakteristik analizi kullanılarak ölçmüşler. Alıcı çalışma karakteristik eğrisinin altındaki alan (AUC) JWDH için 0,902 (%95 CI: 0,871, 0,932) ve 0,900 (%95 CI: 0,870, 0,928), grt123 için 0,877 (%95 CI: 0,842, 0,910) tespit. Yardım. Radyologların ortalama EAA'sı 0,917 (%95 GA: 0,889, 0,945) idi, bu grt123'ten önemli ölçüde yüksek olduğunu bulmuşlar. ($P = ,02$); ancak, radyologlar ile JWDH ($P = .29$) veya Aidence ($P = .26$) arasında anlamlı bir fark bulunmadığını belirtmişlerdir.

Kalaivani ve ark. (2020), Yapmış oldukları çalışmada, BT görüntülerinden akciğer kanserini saptamak için derin bir sinir ağı geliştirip ve değerlendirmişler. Akciğer görüntüsünün nodülü tür bakımından iyi, kötü veya normal olarak ayırt edilmesi için yoğun bağlantılı evrişimli sinir ağı (DenseNet) ve uyarlamalı boosting algoritması kullanmışlar. Görüntülerin %85'inin eğitim için ve görüntülerin %15'inin test ve sınıflandırma için kullanıldığı 201 akciğer görüntüsünden oluşan bir veri seti kullandığını belirten grup deneysel sonuçlar, önerilen yöntemin %90,85 doğruluk elde ettiğini göstermişlerdir.

Shimazaki ve ark. (2022), segmentasyon yöntemini kullanarak DÖ tabanlı bir model geliştirip onayladılar ve akciğer kanserini göğüs radyografilerinde tespit etme yeteneğini değerlendirdiler. Eğitim ve test veri seti olarak kullanılmak üzere akciğer grafileri hastanede Ocak 2006'dan Haziran 2018'e kadar ayrı ayrı toplamış ve eğitim veri seti, DL tabanlı modeli beş katlı çapraz doğrulama ile eğitmek ve doğrulamak için kullanmışlardır. Görüntü başına model duyarlılığı ve ortalama yanlış pozitif göstergeler (mFPI), bağımsız test veri seti ile değerlendirmişler. Eğitim veri seti, 652 nodül/kitle içeren 629 radyografi ve test veri seti, 159 nodül/kitle içeren 151 radyografi içermektedir. DL tabanlı model, test veri setinde 0,13 mFPI ile 0,73 hassasiyete sahip olduğunu tespit ettiklerini belirtmişler. Pulmoner apeks gibi kör noktalarla örtüşen akciğer kanserlerinde duyarlılık daha düşük çıkmıştır, pulmoner hila, göğüs duvarı, kalp ve diyafram altı boşluk (0,50-0,64) ile örtüşmeyen yerlerdeki (0,87) karşılaştırma. 159 habis lezyon için zar katsayısı ortalama olarak 0.52 olduğunu tespit eden bu grup DL tabanlı model, akciğer kanserlerini düşük mFPI ile göğüs radyografilerinde tespit edebilmişler.

Nageswaran ve ark. (2022), yapmış oldukları araştırmada, MÖ ve görüntü işleme ile sağlanan teknolojiyi kullanarak akciğer kanserinin doğru bir şekilde sınıflandırılmasını ve tahmin edilmesi üzerine yapmış oldukları bu çalışmada deneysel araştırma için, veri seti olarak 70 farklı hastadan alınan 83 CT taraması kullanmışlar. Geometrik ortalama filtresi, resim ön işleme sırasında kullanmış sonuç olarak, görüntü kalitesinin arttığını belirtmişlerdir bu tekniğin daha sonra görüntüleri bölümlere ayırmak için kullanıldığı anlamına gelir. Görüntünün parçası bu segmentasyon kullanılarak bulunabilir olduğunu belirtmişlerdir. Daha sonra, MÖ'yü kullanan sınıflandırma yöntemleri kullanılır, sınıflandırma için YSA, k-NN ve RF kullanmış oldukları MÖ tekniklerinden bazıları olduğunu yazan grup YSA modelinin

akciğer kanserini tahmin etmede daha doğru sonuçlar ürettiğini bulduklarını beyan etmişlerdir.

Bu tez çalışmasında, Python programlama dili yardımıyla Tensorflow kütüphanesi kullanarak transfer öğrenme yöntemi ile ESA yardımıyla ağ eğitimi VGG16, VGG19 ve Xception mimari kullanılarak gerçekleştirilmiştir. ESA modeli oluşturularak, bu modelin akciğer kanseri veri setleri üzerindeki başarısı ve performansı değerlendirilmiştir.

1.1. Kanser Nedir

Yapılan birçok çalışma göstermiştir ki insan kanserlerinin tümör baskılayıcı genlerin mutasyona uğramasından veya onkogenik mutasyonların birikmesinden meydana geldiğini göstermiştir (İbrahim ve ark., 2021; Forte ve ark., 2022; Navaneethakrishnan ve ark., 2023). Kanserli dokular, vücudumuzdaki bazı hücrelerin kontrol dışı olarak büyümeleri ve vücuttaki başka dokulara yayılan bir hastalık türüdür. Bu tür bir hastalık, trilyon adet hücre yapısından meydana gelen insan vücudundaki neredeyse herhangi bir bölgesinde meydana gelebilir. Normal olarak insandaki hücreler, vücudumuzun ihtiyacı dâhilinde gerekli hücreleri meydana getirmek için büyürler ve çoğalırlar (bu olaya hücre bölünmesi adı verilmektedir). Hücrelerin yaşlanması veya hasar görmeleri sonucu hücre ölümü olur ve ölen hücrelerin yerini yenileri alır. Bazı zamanlar olması gereken bu sürecin düzenliliği bozulur ve normal olmayan veya sakat hücreler büyüüp çoğalmamaları gerektiği halde çoğalırlar. Hasarlı olan bu hücreler, dokularda kansere sebep olabilmektedir. Oluşan tümörler kanser hücreli iseler kötü huylu değil iseler iyi huylu tümör olabilirler (Siah ve ark., 2019; Liu ve ark., 2021).

Kanser barındıran tümör çeşitleri yakınındaki doku ve bölgelere yayılabilir ve dokuları sarabilirler. Sonrasında yeni tümörlü dokuları oluşturmak için vücudumuzdaki yakın olmayan bölgelere de gidebilirler (bu duruma metastaz adı verilir) (Fu'adah ve ark., 2020). Kanser barındıran tümör ayrıca kötü huylu tümör olarak adlandırılmaktadır. Birden fazla kanser çeşidi katı-sert tümör oluştururlar, fakat lösemi gibi kan kanseri çeşitleri çoğu zaman katı-sert tümör oluşturmamaktadır (Talaman, 1994). Kanserli olmayan tümörler, başka bölgelere sıçrama yapmazlar. İyi huylu tümörler çıkarıldığında genellikle sonradan büyümezken, kötü huylu tümörler sonradan tekrardan büyüyebilirler. Bunun yanı sıra, kansersiz tümörler bazen olduğundan büyük

olabilirler. Beyinde bulunabilecek olan kanserli olmayan tümörler gibi bazı tümörler ciddi etkilerde bulunabilir ve hayatı olumsuz etkileyebilirler (Zhao ve ark., 2018).

1.2. Kanser Çeşitleri ve Oranları


2020 yılının aralık ayında Dünya sağlık örgütü'nün (DSÖ) bir alt kuruluşu olan uluslararası kanser araştırma ajansı (IARC) Dünyadaki kanser istatistikleri hakkındaki son güncel tahminlerini yayınlamıştır (Carter, 2014). 2020 yılı için bütün kanser türleri dahil olmak üzere 185 ülkede ve 36 kanser türü için kanser vaka sayısı ve ölüm oranları IARC tarafından internet üzerinden globocan 2020 veri tabanında paylaşılmıştır (Cao ve ark., 2021). Yapılan çalışmalarda kanser oranının dünya genelinde yükseldiği tahmin ediliyor. 2020 yılında 19,3 milyon yeni tespit ve 10,0 milyon yeni ölüm kayıt edilmiştir. 2018 senesinde ise 18,1 milyon tespit ve 9,6 milyon yeni hayat kaybı bildirilmişti. 2012 yılında yeni kanser tespit sayısı 14,1 milyon gösterilirken, yıllık kanser nedeniyle ölüm oranı 8,2 milyon belirtilmiştir. Dünyadaki her 5 kişiden biri hayatı süresince kansere yakalanmaktadır ve 8 erkekten biri ve 11 kadından biri kanser sebebiyle hayatının kaybeder (Bray ve ark., 2018). Dünya genelinde, kanser tespiti konulduktan sonra 5 sene içerisinde yaşayan toplam insan sayısının 50,6 milyon olarak tahmin ediliyor. Uluslararası kanser araştırmaları ajansı tarafından üretilen globocan 2020 kanser insidansı ve mortalite tahminlerini kullanarak küresel kanser ağırlığı hakkında bir güncelleme sunulmuştur (Sung ve ark., 2021).

2020'de yapılan çalışma dünya genelinde tahmin olarak 19,3 milyon yeni kanser tespiti (melanom dışı cilt kanseri hariç 18,1 milyon) ve yaklaşık 10,0 milyon kanser nedeni ölüm (melanom dışı cilt kanserleri dahil olmadan 9,9 milyon) olduğu belirtilmiştir (Ali ve ark., 2022). Göğüs kanseri sayısı, en fazla tespit edilen kanser vakaları olarak akciğer kanser sayısını geçmiştir (Ha ve Vahedi, 2021). Tahmini olarak 2,3 milyon yeni tespit (%11,7), akciğer (%11,4), kolorektal (%10,0), prostat (%7,3) ve mide (%5,6) kanserleri gelmektedir. Akciğer kanseri, 1,8 milyon tahmin olarak ölümle (%18) kanser ölümlerinin birincil sebebi olarak tespit edilirken, ikinci sırada kolorektal (%9,4), karaciğer (%8,3), mide (%7,7) ve kadın meme (%6,9) kanserleri gelmektedir.

Genel insidans, geçiş yapan ülkeler ile karşılık olarak geçiş ülkelerinde iki cins için 2 kat oranından 3 kata kadar, daha yüksek bulunurken, ölümlü oran erkekler için <2 kat ve kadınlar için pek az değişim göstermiştir. Bunun yanı sıra, kadın meme ve

serviks kanserleri için ölüm sayıları, geçiş yapan ülkelere karşı olarak önemli ölçüde daha yüksek bulunmuştur (Sung ve ark., 2021).


Dünya geneli kanser sayısının 2040 yılında 28,4 milyon olması, 2020 yılına göre %47 oranında artış olması ve demografik değişiklikler sebebiyle geçiş yapan ülkelere (%32 ila %56) kıyasla geçiş yapan ülkelerde (%32'den %56'ya) daha fazla bir yükseliş olması beklenmektedir (Sung ve ark., 2021). Kanser, dünyadaki her bir ülkede ilk sıralarda olan ölüm sebebi ve yaşam kalitesinin önünde büyük bir engeli temsil etmektedir (De Wever ve ark., 2009). DSÖ, 2019'da elde ettiği verilere dayanarak kanserin, 183 ülke arasından 112 ülkede 70 yaşın öncesindeki ölümler arasında ilk veya ikinci nedeni olarak önde geldiğini tespit edip ve 23 ülkede ise üçüncü veya dördüncü sırada yer aldığını belirtmişlerdir (Sung ve ark., 2021).



Şekil 1.2. 2019'da <70 yaşında ölüm nedeni olarak ulusal kanser sıralaması (Sung ve ark., 2021).

Genel olarak, kanser insidansı ve mortalite yükü dünya genelinde hızla yükselmektedir. Bu yükseliş hem nüfusun yaşlanmasını hem de büyümesini ve ayrıca birçoğu sosyoekonomik gelişme ile bağlantılı olarak kanserin ana risk faktörlerinin yaygınlığı ve dağılımındaki değişiklikleri yansıtmaktadır (Lei ve ark., 2021). Erken ölüm nedeni olarak kanserin konumunun sosyal ve ekonomik kalkınmanın ulusal düzeylerini ne ölçüde yansıttığı, Şekil 1.3 (A) ve Şekil 1.3 (B)'deki haritalar

karşılaştırılarak görülebilir, ikincisi dört kademeli insani gelişme endeksi'ni gösterir. Birleşmiş Milletler'in 2019 insani gelişme raporu'na dayanmaktadır.



Şekil 1.3. Katmanlı İnsani Gelişme Endeksi İlgili popülasyonların boyutları dâhil edilmiştir (Sung ve ark., 2021).

Çizelge 1.1. 2020 Yılında 36 Kanser ve Tüm Kanserlerde Kombine Yeni Vakalar ve Ölümler (Sung ve ark., 2021)

Kanser bölgesi	Numara. Yeni vaka sayısı (tüm sitelerin %'si)		Numara. Yeni ölümlerin (tüm sitelerin %'si)	
Kadın meme	2.261.419	(11.7)	684.996	(6.9)
Akciğer	2.206.771	(11.4)	1.796.144	(18.0)
Prostat	1.414.259	(7.3)	375.304	(3.8)
Derinin melanomu olmayan	1.198.073	(6.2)	63.731	(0.6)

Kanser bölgesi	Numara. Yeni vaka sayısı (tüm sitelerin %'si)		Numara. Yeni ölümlerin (tüm sitelerin %'si)	
Kolon	1.148.515	(6.0)	576.858	(5.8)
Karın	1.089.103	(5.6)	768.793	(7.7)
Karaciğer	905.677	(4.7)	830,180	(8.3)
Rektum	732,210	(3.8)	339.022	(3.4)
Rahim ağzı	604,127	(3.1)	341.831	(3.4)
Yemek borusu	604,100	(3.1)	544.076	(5.5)
Tiroid	586.202	(3.0)	43.646	(0.4)
Mesane	573.278	(3.0)	212,536	(2.1)
Hodgkin olmayan lenfoma	544.352	(2.8)	259.793	(2.6)
Pankreas	495.773	(2.6)	466.003	(4.7)
Lösemi	474.519	(2.5)	311.594	(3.1)
Böbrek	431.288	(2.2)	179.368	(1.8)
Korpus uteri	417.367	(2.2)	97.370	(1.0)
Dudak, ağız boşluğu	377.713	(2.0)	177.757	(1.8)
Deri melanomu	324.635	(1.7)	57.043	(0.6)
Yumurtalık	313.959	(1.6)	207.252	(2.1)
Beyin, sinir sistemi	308,102	(1.6)	251.329	(2.5)
Gırtlak	184.615	(1.0)	99.840	(1.0)
Multipil myeloma	176.404	(0.9)	117.077	(1.2)
Nazofarenks	133.354	(0.7)	80,008	(0.8)
Safra kesesi	115.949	(0.6)	84.695	(0.9)
Orofarenks	98.412	(0.5)	48,143	(0.5)
Hipofarenks	84.254	(0.4)	38.599	(0.4)
Hodgkin lenfoma	83.087	(0.4)	23.376	(0.2)
Testis	74.458	(0.4)	9334	(0,1)
Tükürük bezleri	53.583	(0.3)	22.778	(0.2)
Anüs	50.865	(0.3)	19.293	(0.2)
Vulva	45.240	(0.2)	17.427	(0.2)


Kanser bölgesi	Numara. Yeni vaka sayısı (tüm sitelerin %'si)		Numara. Yeni ölümlerin (tüm sitelerin %'si)	
Penis	36.068	(0,2)	13.211	(0,1)
Kaposi sarkomu	34.270	(0,2)	15.086	(0,2)
Mezotelyoma	30.870	(0,2)	26.278	(0,3)
Vajina	17.908	(0,1)	7995	(0,1)
Melanom olmayan cilt hariç tüm siteler	18.094.716		9.894.402	
Tüm siteler	19.292.789		9,958,133	

Yeni vakalar bazal hücreli karsinomu hariç tutarken, ölümler tüm melanom dışı cilt kanseri türlerini içerir.

1.2.1. Türkiye’de Kanser İstatistikleri

Ülkemizde nüfus artmaya devam etmektedir. Bununla paralel olarak yıllık konulan yeni teşhis kanserli hastanın da arttığı belirtilmektedir. 2020 senesinde Türkiye’nin nüfusu 84.339.067 iken, yıllık yeni kanser teşhis sayısı 233.834 ve kanser sebebiyle ölüm sayısı 126.335 olarak bildirilmiştir (Temizsoy, 2021).

2020 Türkiye kanser istatistikleri



Şekil 1.4. 2020 yılına ait Türkiye’de kanser istatistikleri.

Türkiye nüfusu 2018 yılında 81.916.866 iken, yeni konulan teşhis adeti 210.537 ve kanser nedeniyle ölüm sayısı 116.710 olarak bildirilmiştir. 2020 yılındaki verilere göre Türkiye’de en çok teşhis edilen 5 kanser çeşidi akciğer kanseri, meme kanseri, kolorektal (kalın bağırsak) kanseri, prostat kanseri, tiroit kanseri iken, bu 5 kanser türü tüm kanserin %50’den fazlasını oluşturmaktadır (Keser ve ark., 2017).

1.3. Akciğer Kanseri

Tahmin olarak 2,2 milyon tane yeni teşhisi ve 1,8 milyon tane ölüm sayısı ile akciğer kanseri, 2020 yılında en fazla tespit edilmiş ikinci sırada kanser ve bu sebeple ölümlerin ilk sırasında olan nedendir ve tanısı konulan yaklaşık olarak 10 kanserden birini (%11,4) kapsamaktadır (Schabath ve Cote, 2019; Bracken-Clarke ve ark., 2021). Akciğer kanseri erkeklerde kanser morbidite ve mortalitesinin ilk sırada olan sebebi iken, kadınlarda meme ve kolorektal kanserden sonra insidans açısından üçüncü, ölüm oranı açısından meme kanserinden sonra ikinci sırada yer almaktadır (Bhatia ve ark., 2019). İnsidans ve ölüm oranları, kadınlara göre erkeklerde iki kat daha yüksektir. Ancak erkek-kadın oranı, bölgeler arasında Kuzey Amerika’da 1,2’den Kuzey Afrika’da 5,6’ya kadar büyük farklılıklar göstermektedir.

Dünya çapındaki akciğer kanseri ölümlerinin yaklaşık üçte ikisi sigaraya atfedilebilirken, hastalık etkili tütün kontrol politikaları ve düzenlemeleriyle büyük ölçüde önlenabilir. Tütün talebini azaltmak için ülke düzeyinde etkili müdahalelerin uygulanmasına yardımcı olmak için, DSÖ tütün kontrolü çerçeve sözleşmesi, 6 politika müdahale stratejisinden oluşan MPOWER paketini tanıttı (Ngo ve ark., 2017). Tütün kullanımını ve önleme politikalarını izleme, insanları tütün dumanından koruma, tütün kullanımını bırakmaya yardım et, tütünün tehlikeleri hakkında uyar, tütün reklam, promosyon ve sponsorluk yasaklarını uygula ve tütün vergilerini yükselt.

DSÖ tarafından tanıtılmasından bu yana, ilerleme önemli ölçüde olmuştur. 2018’de, 136 ülkedeki dünya nüfusunun %65’i, kapsamlı bir düzeyde en az bir seçilmiş önlem tarafından kapsanmaktaydı; bu oran, 2007’de 43 ülkedeki nüfusun %15’i idi. Ayrıca, 116 ülkede tütün kullanımının yaygınlığı azalmıştır.

Özellikle daha güçlü uygulama tedbirlerine sahip olanlar. Kadın tütün kullanıcılarının sayısındaki düşüşün 2000 yılından bu yana devam etmesiyle birlikte, ilk

kez 2018 yılında, nüfus artışına rağmen dünya genelinde tütün kullanan erkeklerin sayısı azalmaya başlamıştır.


Akciğer kanserli hastaların tanıdan sonraki 5 yıl içinde hayatta kalma oranları, 2010-2014 yılları arasında tanı konanlar arasında çoğu ülkede sadece %10 ila %20'dir. Yüksek riskli bireyler için (şu anda ve eskiden çok sigara içenler) düşük doz BT ile tarama, başarılı tedavinin daha olası olduğu durumlarda kanserin erken teşhisine yardımcı olabilir. Yıllık düşük doz BT taramasının akciğer kanseri mortalitesini azaltmadaki etkinliği birkaç bağımsız, uluslararası, randomize kontrollü klinik çalışmada doğrulanmıştır (Blanchon ve ark., 2007).

1.3.1. İyi Huylu Akciğer Kanseri

Göğüs BT'sinde akciğerde bir nokta, akciğer nodülü olarak tanımlanır ve iyi huylu veya kötü huylu olabilir (Slatore ve ark., 2016). Kötü huylu akciğer lezyonlarının doğru bir şekilde tanımlanması, akciğer kanserinin morbidite ve mortalitesini azaltmak için akılcı klinik yönetimin bir ön koşuludur.

Ancak akciğer nodüllerinin kötü huylu ve iyi huylu olarak sınıflandırılması, BT ve bazen PET görüntülemelerinde benzer özellikler göstermeleri nedeniyle invaziv doku biyopsilerini gerekli kıldığı için zordur (Li ve ark., 2023).

İyi huylu akciğer kanseri (Benign), akciğerde doğumla birlikte veya daha sonradan oluşan tümörlerdir (Agarwal ve ark., 2021). Hastalarda genellikle tesadüfen teşhis edilir. Şikâyetler genelde olmaz. Çekilmiş bir akciğer tomografisinde teşhis edilebilirler. Bu tür tümörle kötü huylu tümörler gibi metastaz yapmaz ve kişinin bedenine zararda bulunacak tarzda büyüme sağlamazlar. Genellikle enfeksiyon sonrasında da görülebilir. Tümör içinde bağ dokusu, kıkırdak ve yağ benzeri normal vücut yapıları yer alır (Wang ve ark., 2021).



Şekil 1.5. İyi huylu (Benign) akciğer kanseri görüntüsü (IQ-OTH/NCCD).

1.3.2. Kötü Huylu Akciğer Kanseri

Kötü huylu akciğer kanseri (Malign), kanser türleri arasında üremeye (büyümeye) devam eden metastaz yapmaya meyilli tümör çeşididir (Kanipriya ve ark., 2022). Dünya genelinde en çok teşhis tümörler arasına bulunmaktadır. Bu kadar çok rastlanmasına rağmen teşhis edilmesi ve tedavi edilmesi o kadar erken olamamaktadır. Bunun en önemli nedeni de şikâyetlerin oluşmasına kadar kanserin akciğer içerisinde belirgin bir büyüklüğe ulaşması ve bu sırada da akciğerin dışına metastaz yapmasıdır (Li ve ark., 2021).

Bu zaman zarfında genellikle belirti oluşmaz veya herkeste görülebilecek şikâyetlere benzer olduğundan pek ciddiye alınmazlar. En sık görülen şikâyetler arasında, kanserin göğüsün duvarına dayandığı zaman ciddi ağrılara sebep olması veya hava yollarını sıkıştırdığında ciddi öksürük ve zaman ile kanlı balgama sebep olmasıdır. Bu zaman için teşhis edilen kanserlerin çoğu da ilerlemiş akciğer kanserinin göstergesi olmaktadır (Wu ve ark., 2020).



Şekil 1.6. Kötü huylu (Malign) akciğer kanseri görüntüsü (IQ-OTH/NCCD).

1.4. Akciğer Görüntüleme Teknikleri

Bilgisayar destekli bilimlerinden yararlanarak tıp alanında, bazı yeni terimlerin oluşmasına neden olmuştur. Bunlardan biri uzman sistemler bir diğeri ise bilgisayar destekli tespit (BDT). BDT görüntü işleme tekniklerinden faydalanarak medikal görüntülerdeki normal olmayan dokuların tespiti aşamasında destek oluşturmaktadır. BDT sonuca varmaktaki süreyi hızlandırırken bu süreçteki insan kaynaklı hata payını da azaltmaya yardım etmektedir (Doğan ve ark., 2016).

BDT sistemleri, vücuttaki tümörün tespit edilmesi ve kategorilere ayrılmasında, kırılmış kemik gibi yapıların tespiti sürecinde, kanserin tespit ve sınıflandırılması gibi birden fazla alanda bilgisayar sistemleri ile tıbbi görüntüleme beraber kullanılmaktadır (Ekşi ve ark., 2012).

Uzman sistemler belli bir çalışma alanında, gerçek şahıslardan tespit edilmiş bilgilerden yol alarak, zaman içerisinde kendini geliştiren, karar sırasında az da olsa insana benzer şekilde karar verme yeteneğinde sistem çeşitleridir (Türçetin ve ark., 2019). Uzmanlar sistemleri geliştirilirken sistemin karar aşamasında, sağlıkçılar ile aynı sonuca ulaşabilmesi önemli bir süreçtir. Toplumda sık görülen düşüncenin tersine, geliştirilmiş olan sistemlerin hedefi bir uzman yerine geçmek değildir amaç tespit sırasında konunun üzerine çalışmış olan uzmanların elde ettiği bilgiler doğrultusunda verilecek olan karara destek olmaktır (Kutukız, 2014).

Akciğerde meydana gelen tümör bazen oldukça küçük veya yuvarlak yapısı sebebiyle tespiti oldukça zahmetli olmaktadır (Türçetin ve ark., 2019). Bu sebeple, geliştirilme aşamasında olan bir BDT sistem çalışması akciğerdeki tümörlerin erken safhada tespitinde önemli bir yol olacağı düşünülüyor. Radyologların ve hekimlerin akciğerdeki tümörleri başarıyla teşhis edebilmeleri için bir bilgisayar desteğiyle kullanılacak olan tanı / teşhis sistemlerinin kullanılma durumu önem arz etmektedir (Dandıl, 2017).

Tıbbi görüntülemelerde analiz ve tümörün ölçü bilgisinin de elde etmek için, görüntünün bir çeşit görüntü işleme sürecinden geçmesi gerekiyor (Althubaity ve ark., 2023). Tıptaki görüntülemenin içerisindeki veriler MR, x-ray radyografi, BT, US, PET gibi yöntemler kullanılarak elde edilebilmektedir (Porto-Álvarez ve ark., 2023). Akciğerdeki tümörlerin teşhis edilmesinde BT/PET yöntemleri kullanılabilir.

1.4.1. Bilgisayarlı Tomografi

BT kelimesinin anlamı eski yunanca kelimelerden olan tomo (kesit-slice) ve graphy (görüntü) ‘den oluşmuştur. Anlamı bilgisayarlı kesit görüntüsü oluşturmaktır (Jung, 2021). BT’nin temeli röntgen cihazında da kullanılan X-Ray tube (X-Işını Tüpü) teknolojisine benzer olan bir yapıya dayanmaktadır.

X-ışını kullanılarak vücuttan kesit şeklindeki görüntüleri alabilmeyi sağlayan radyolojik tanı koyma yöntemin şeklidir. Böyle bir yöntem, vücuttaki ince bir kesitten zayıflamaların detektörler yardımıyla ölçülüp bilgisayarın desteğiyle görüntünün oluşması temeline dayanmaktadır (Buckinx ve ark., 2015).

BT teori olarak Amerikalı bir fizikçi olan A. Cormak’ın geliştirmesi ve İngiliz fizikçi Dr. G. Hounsfield tarafından 1972 yılında icat edilmesiyle bilinmektedir (Matteson ve ark., 1996)




Şekil 1.7. Bilgisayarlı Tomografi (Medikalfizik, 2017).

BT aletinde üç ana bölüm vardır bunlar;

- Tarama bölümü
- Görüntüleme bölümü
- Bilgisayar sistemi


Tarama bölümü:



Şekil 1.8. BT Bölümleri (Medikalfizik, 2017).

BT'deki tarama kısmı gantri ve hasta masası olan bölümlerden oluşur. Gantri, içinde x-ışını tüpü ve dedektörleri bulunur (Medikalfizik, 2017). BT'de kesit görüntülerini elde etmek için tüp içerisinde çıkan x-ışını kolime edilip yelpaze şeklinde bir x-ışını demeti haline getirilir (Tabakov ve Bregant, 2022).

Kesitin alınması sürecinde x-ışın tüpü ve dedektörler karşılıklı bir şekilde hasta etrafında döner. Bu dönme sırasında tüp x-ışını oluşturmaya başlar (Medikalfizik, 2017)



Şekil 1.9. BT çalışma şekli.

Dedektörler bu süreçte üzerine düşen x-ışınının şiddetini algılayıp elektriksel bir sinyal oluşturma görevi üstlenirler. BT’lerde çeşitli dedektörler kullanılmıştır (Jung, 2021). Bunların ortak özellikleri;

- X-ışını tutma karakteristiği yüksek olmalı.
- Gelen X-ışınını geniş bir aralık ile iyi bir doğrusallıkla tepki gösterebilmektir.
- Çok az bir zaman zarfında üstüne gelen x-ışını şiddetini elektriksel sinyal olarak çevirip ve x-ışını bittiği anda sinyalin kesilmesini sağlamalıdır.
- Dedektör çıkışlarındaki analog sinyallerin yükseltilip sayısal verileri dönüştürülebileceği kadar yüksek olmalıdır.
- Gelen X-ışınları, dedektörlerce saptanmalarının ardından bilgisayar sayesinde hastanın diğer tarafına geçmiş olan x-ışınlarının zayıflama dereceleri hesaplanır.
- Hasta masası, BT çekilmesi sürecinde hastanın uzatıldığı yerdir. Otomatik veya manuel olarak uzaktan kumanda sayesinde masanın gantri açıklığına giriş ve çıkışı sağlanabilmektedir.
- İnceleme sırasında, incelenecek bölgenin ardı ardına kesit alabilmek nedeniyle her bir kesit alınması işleminden sonra masa hareket ettirilir.

Bilgisayar ünitesi (Passaretti ve ark., 2022):

- Bu ünite tarama ünitesinden gelmiş olan bilgileri işletip değerlendirir.
- Bu alanda bilgiler işlenir ve değerlendirilir, birden fazla matematiksel işlemlerin ve algoritmaların gerçekleştirilmesi sağlanır.
- Burada karmaşık işlemler yapıla bilinmesi için bilgisayar işlemcilerinin kapasitelerinin oldukça yüksek olması gerekmektedir.
- Bilgisayar kısmında, matematiksel işlemlerin ve algoritmaların elde ettiği sonuçları, tarama alanının temsil edildiği sayıları oluşturan haritaya dönüştürür.



Şekil 1.10. BT bilgisayar ünitesi

Görüntüleme ünitesi

- Bu ünite bilgisayar ünitesindeki oluşturulmuş haritayı görsel bir şekil haline getirir.



Şekil 1.11. BT görüntüleme ünitesi.

BT'nin Görüntü oluşturma (Seeram, 2018);


- BT'deki görüntü bir kesitin şeklidir. Kesit görüntüsünün oluşabilmesi için yapılacak çalışmalar sırayla şu şekilde özetlenebilir:
- Birinci işlem X-ışını tüpünün, kesit düzlemi çevresinde 360 derece dönecek şekilde dar bir X-ışını demeti gönderir.

- X-ışınları vücuda gönderilen ve vücuttan geçen ışınlar ölçülür, arada oluşan fark hesaplanır dedektörün karşısına denk düşen dokunun X-ışınının ne kadarını tuttuğu hesaplanır.
- Oluşan görüntü bu ölçümlerden sonra ortaya çıkan karmaşık bilgisayar işlemleri sayesinde oluşur.
- Tüm dijital görüntülerin oluşmasında olduğu gibi BT’de de görüntü küçük resim elementlerinden (piksellerden) oluşur. Buna görüntü matriksi denir.
- Matriks sayısı görüntülerin iki kenarlarındaki piksellerin sayılarının çarpılması şeklinde yorumlanır ve günümüzün aygıtlarında bu sayı genellikle 512x512’ye denk gelir.
- Piksel değerleri seçilmiş olan kesit kalınlığıyla orantılı olarak VOKSEL olarak adlandırılan hacme sahiptir.
- Voksel değerleri -1,0,1 olabilmektedir 0 sayısı suyu, eksi değerli sayılar hava ve yağı, artı değerliler yumuşak dokuları ve kanı temsil eder

Tomografi nasıl çekilir (Fleischmann ve Boas, 2011);

- BT’si istenilen hasta, radyoloji ünitesinde yer alan BT cihazının olduğu alana yönlendirilmesi yapılır.
- Çekim yapılmadan 6 saat öncesinden yemek yemeyecek olan ve 4 saat öncesinden beri su içmemiş hasta, kabinin içerisine, görüntülenecek olan bölümdaki takı kıyafet veya tüm giysilerini çıkartarak hastane önlüğünü giyer.
- Bu sırada gözlük, alyans, toka, takma dişler gibi tüm metal nesnelerin çıkarılması gerekmektedir.
- Hekimin yapmış olduğu bilgilendirmeler ve uyarılardan sonra hastanın BT cihazının olduğu sedye üzerine yatırılması istenir.
- Görüntülenmek istenen bölge konumu dikkate alınarak hasta yüz üstü veya sırt üstü yatırılır.
- BT cihazı model çeşidine göre görüntüleme sırasında hareket eden parça değişiklik gösterebilir.
- Çoğunluk olarak hasta sedyesi sabit olup cihaz hasta etrafında hareket edecek şekilde olsa da bazı cihaz modellerinde cihaz sabit, sedye ise hareket hâlinde olabilmektedir.

Çizelge 1.3.1. X-ışını yöntemlerinin ayırabildiği dokular (Tumrad, 2023)

Röntgen	Gri Ölçek	BT
Metal		Metal
Kemik ve Kalsifikasyon		- Kemik Kalsifikasyon - Hematom
Su (Yumuşak Dokular)		-Beyaz cevher - Karaciğer - Gri cevher -Dalak - Ödem - Su
Yağ		Yağ
Hava		Hava

1.4.2. Akciğer Kanserinin BT ile Tespiti

BT taramalarında akciğer kanseri teşhisinin temeli, akciğer nodüllerinin saptanması ve yorumlanmasıdır. BT tarayıcılarının yetenekleri geliştikçe, daha yüksek uzamsal çözünürlük seviyeleri daha küçük akciğer anormalliklerini ortaya çıkarır. Tespit edilen tüm akciğer nodüllerinin rapor edilmesi gerekmeseyse de, Radyologlar kanser teşhisi ile ilgili olabilecek tüm nodülleri tespit etmeye çalışır (Mao ve Deng, 2016).

Orta ila büyük akciğer nodülleri tutarlı bir şekilde tespit edilse bile, nodül boyutu 8-10 mm'nin altına düştüğünde, okuyucular arası uyum ve akciğer nodül tespiti için okuyucu hassasiyeti önemli ölçüde azalır.

Mutlak bir referans standardı oluşturmanın zorluğu, akciğer nodülü tespitini değerlendirmek için yapılan çalışmaların güvenilirliğini zorlaştırır.


Algılama performansını iyileştirmek adına, araştırmacılar, okuyucular arasında performansı artıracak stratejilerin mevcut olup olmadığını belirlemek için radyologların BT taramalarını arama yollarındaki nodülleri tanıma yeteneklerine göre etkililiğini analiz etmek için göz izlemeyi kullanır.

Enine BT rekonstrüksiyonlarının görüntülenmesinin ötesinde, okuyucu performansını önemli ölçüde iyileştirmek için ince levha maksimum yoğunluk projeksiyonları gibi görüntü işleme teknikleri kullanılır (Rubin, 2015).


BT taramasının etkinliğinin temeli, BT verileri içindeki pulmoner nodüller şeklindeki şüpheli lezyonları belirlemekle görevli radyologdur. Bu zorluğun boyutu, özellikle küçük akciğer nodülleri için önemli olabilir. Ulusal akciğer tarama denemesindeki insidans taramalarında tespit edildikleri sırada, akciğer kanserlerinin %35'inin çapı 10 mm veya daha küçüktü (Blanchon ve ark., 2007).

Akciğerlerin tamamından alınan ve 1 mm kalınlığında kesitlerle rekonstrükte edilen bir CT taraması, yaklaşık 9.000.000 pulmoner voksel içerir. Çapları 4 ila 10 mm arasında olan akciğer nodülleri, akciğer hacminin 77 ila 1200 vokselini veya %0,00085 ila %0,013'ünü kaplar ve radyologları ideal koşullar altında 2 ila 5 dakikalık bir arama süresi içinde hepsini tanımlamaya zorlar (Rubin, 2015).

BT yöntemi, bir hasta vücudunun belirli bir alanının yanal kesit görüntüsünü oluşturabilmek amacıyla birçok açıdan ve konumdan alınmış röntgen verilerini birleştirilip oluşturulması olan bir tıbbi görüntüleme çeşididir. Görüntülenmek istenen alan dijital dilimlere ayrılır. Doktorların dokuları, kemikleri ve organlardaki sorunlu bölgeleri belirleyebilmek için hastanın vücudunun bölümlerini gözden geçirmelerine olanak verir (Radsite, 2011). Şekil 1.12'de bir BT görüntüsü gösterilmiştir (Erbaş, 2011).



Şekil 1.12. Akciğer BT görüntüsü (Erbaş, 2011).




Şekil 1.13. Nodül tespitli akciğer BT görüntüsü (Rubin, 2015).

Şekil 1.14'te 1,25 mm kalınlığındaki BT kesiti, yaklaşık 2 mm'lik bir akciğer nodülünü (ok) göstermektedir. Bunun gibi veya daha küçük nodüller, genç erişkinliğin ötesinde elde edilen hemen hemen her BT taramasında bulunabilir.


Bu boyuttaki nodüller ezici bir çoğunlukla iyi huylu olduğundan, yayılmadıkça veya belgelenmiş malignitesi olan bir hastada yeni bir bulgu olarak sunulmadıkça, bunların tanımlanmasıyla hiçbir ilgisi yoktur.

Akciğer kanseri taraması bağlamında bu nodülü bildirmenin esasen bir rolü yoktur (Rubin, 2015). BT, çapı 1 mm kadar küçük olan nodülleri tespit edebildiğinden ve küçük akciğer nodüllerinin büyük çoğunluğu iyi huylu olduğundan araştırmacılar, altında akciğer nodüllerinin klinik olarak önemsiz olmasından dolayı göz ardı edilir (Benjamin MS ve ark., 2003).



Şekil 1.14. Görünür Nodül tespitli akciğer BT görüntüsü (Rubin, 2015).

Şekil 1.3.8. İki farklı hastadan iki adet 12 mm akciğer nodülü örneği. Soldaki nodül, çevresindeki normal akciğer yapıları ile ilişkili değildir ve bu nedenle tespit edilmesi kolaydır. Sağdaki nodül (ok) 5-8 mm pulmoner kan damarları ile yakından ilişkilidir. Bitişik kan damarlarından önemli ölçüde daha büyük olmasına rağmen, soldaki nodülden daha az dikkat çekici görünmektedir (Rubin, 2015)



Şekil 1.15. İşaretli nodül tespitli akciğer BT görüntüsü (Rubin, 2015).

Şekil 1.15'te 5 mm akciğer nodülü (kırmızı daireler) görülmektedir. Sol üst köşedeki sayı, nodülü tespit eden 13 radyologdan kaç tanesinin tespit ettiğinin sayısına karşılık gelmektedir.

Bölgesel akciğer karmaşıklığındaki farklılıklar ve akciğerlerin bu enine kesitler üzerindeki enine kesit alanı, bunların saptanmasında önemli bir belirleyici olabilir (Rubin, 2015).

1.4.3. Pozitron Emisyon Tomografi

PET medikal görüntüleme tekniği insan vücudundaki rahatsızlıkları görüntüleme ve kontrol etmede kullanılan bir görüntüleme tekniğidir (Nivetha ve Manickavasagam, 2014). PET ile görüntüleme tekniği kanserli hücreleri artan glukoz emilimine ve glikolizise göre bize bilgiler sunar. Bu teknikle yeni belirgin bir kitle meydana gelmeden, metabolik değişiklikler tespit edilebilir. Bunun için 2-deoksi-2- [florin-18]-floro-D-glukoz (18 F-FDG) hastaya verilir (Van den Abbeele ve Badawi, 2002).

Bir başka deyişle kanserli hücrelerin glukoz kullanımı normal sağlıklı hücrelerinkinden daha yüksektir. PET-CT yöntemi bu bilgiler dahilinde elde ettiği önceden işaretlenmiş olarak hastaya verilen glukozların hasta vücudundaki normal olmayan dağılımını gösteren görüntüleme yöntemidir.

PET-CT yöntemi hasta vücudundaki kanserli bölgeyi değerlendirme, kanserin evresini belirleme, alınan kemoterapi/radyoterapi tedavilerinin kanserli olan alan üzerinde etkisini gözlemlemede kullanılmaktadır. Bu sayede gerekli olmayan tedaviler engellenir, gerekli olan tedaviler hemen başlanmış olunur. Gerekli hallerde tedavi yöntemi değiştirilebilir.

F-FDG PET şu anda akciğer lezyonlarının karakterizasyonu, küçük hücreli dışı akciğer karsinomunun (KHDAK) evrelenmesi, uzak metastazların saptanması ve tekrarlayan hastalığın teşhisi için endikedir (Bunyaviroch ve Coleman, 2006).




Şekil 1.16. PET Cihazı (Anadolusaglik, 2023).

1.4.4. PET ile Akciğer Kanseri Tespiti

Kanserli hücreler çoğalmak, gelişmek ve büyümek için glukoz kullanırlar. PET ile görüntüleme tekniğinde glukoz radyoaktif madde ile işaretlenir ve hastaya verilir. Bundan sonra, radyoaktif ile işaretlenmiş glukozu tutmuş olan kanserli bölge PET tarafından görüntülenir (Minn ve ark., 1995).

PET cihazı, normal görünmeyen bir doku içerisinde kanserli hücrelerin olup olmadığını belirlemede oldukça güvenilir bir yöntem olmasına rağmen, yeterli düzeyde anatomik bilgi veremediğinden, tümörün yerleşmiş olduğu yer hakkında veya radyoaktif madde ile işaretlenmiş glukozun tutulduğu yerin normal bir dokuya ait olup olmadığı hakkında soru işaretleri bırakabiliyor (Wahl ve ark., 1994).



Şekil 1.17. PET ile Akciğer Tümör görüntüsü (Bunyaviroch ve Coleman, 2006).

Puslu ve belirsiz bir kenar, endobronşiyal uzantı, pulmoner damarlara uzantı ve bitişik plevranın fokal retraksiyonunu içerir. Heterojen iç bileşim ve ilişkili nekroz, malignitenin göstergesidir.


Malign lezyonlar ayrıca, genellikle pnömoni ile ilişkilendirilen hava bronkogramları oluşturarak iyi huylu durumları simüle edebilir.

Bronşioalveoler hücreli karsinom ve lenfoma gibi varlıklar, iyi huylu akciğer lezyonları gibi görünebilir (Bunyaviroch ve Coleman, 2006.).

1.5. Görüntü işleme

Bu işlem yöntemi görüntüde yer alan bazı sorunları gidererek, normal görüntüden aldığımız bilgilerden daha çok bilgi elde etmemize yardımcı olmaktadır (Haque ve Neubert, 2020). Bu tekniklerinin en değerli kullanılan alanlarından bir tanesi de medikal alanıdır. Medikal görüntülerde görüntü işleme tekniği kullanılıyorken gürültü, düşük çözünürlük, görüntüleme yapılarının görünümü gibi birtakım sorunla karşılaşılabilir.

Bu sorunun nedeni kullanılan teknik cihazlar ve görüntü alma süresince dıştan denk gelinilen olumsuz etkenlerdir. Şekil 1.18’de görüntü işleme adımlar gösterilmiştir.



Şekil 1.18. Görüntü işleme adımları (Türkçetin ve ark., 2019).

Şekil 1.18’de gösterildiği gibi medikal görüntülerin içinde bulunan problemler, görüntü önileme, görüntü iyileştirme gibi işlemler yapılarak çözülebilmektedir. Görüntü işleme çalışmaları C++, Matlab, JAVA, Python gibi birden fazla bilgisayar programlama dili yardımıyla çözüle bilinmektedir.

Bilgisayar programlama dilini seçerken göz önünde bulundurulması gereken faktörler ise, en kısa zaman içerisinde ve en optimize sonucu elde etmemizi sağlayacak dili tercih etmektir. Yapılan bu çalışmada görüntü işleme yönüyle kullanımı zengin ve kolay kütüphanelerinin bulundurulması sebebiyle Python programlama dili tercih edilmiştir.


2. MATERYAL VE YÖNTEM

Bu çalışmada MÖ uygulamaları ve görüntü işleme için kütüphane sayısı zengin olan Python programlama dilini kullanılmıştır. Python programlama dili için Collab ortamını tercih edilmiştir.

2.1. Akciğer Görüntü Veri Seti

Bu çalışmada önerilen yöntem akciğer kanseri hastalığının teşhisi için Irak-Onkoloji Eğitim Hastanesi/Ulusal Kanser Hastalıkları Merkezi (IQ-OTH/NCCD) akciğer kanseri veri seti, yukarıda belirtilen uzman hastanelerde 2019 sonbaharında üç aylık bir süre boyunca toplanmıştır (Hamdalla, 2020). Akciğer kanseri teşhisi konan hastaların BT taramalarını içerir. Sağlıklı deneklerin yanı sıra farklı evrelerde kanser CT görüntüleri mevcuttur. IQ-OTH/NCCD slaytları bu iki merkezde onkologlar ve radyologlar tarafından işaretlenmiştir. Veri seti, 110 vakadan alınmış olan BT tarama dilimlerini temsil eden toplamda 1190 görüntü içermektedir. Bu vakaları normal, iyi ve kötü huylu olmak üzere üç sınıfa ayrılmıştır. Bunlardan 40'ı malign olarak teşhis edilmiş, Benign tanılı 15 olgu ve normal vaka olarak sınıflandırılan 55 vaka bulunmaktadır. BT taramaları orijinal olarak DICOM formatında toplanmıştır.

Kullanılan tarayıcı Siemens'ten SOMATOM'dur. BT protokolü şunları içerir: 120 kV, 1 mm dilim kalınlığı, pencere genişliği 350 ile 1200 HU arasında, pencere merkezi ise 50 ile 600 arasında değişen okumalar için kullanılmıştır. Tam inspirasyonda nefes tutma ile. Analiz yapılmadan önce tüm görüntülerin kimliği kaldırılmıştır (Hamdalla, 2020).



Şekil 2.1. Akciğer görüntü veri seti.

2.1.1. DICOM Standartı

Tıbbi görüntüleme, çeşitli modalitelerden verilerin saklanması ve aktarılması için standart bir DICOM geliştirilmiştir (Musta ve ark., 2008). Tıbbi bilişim için uluslararası bir standarttır. Yalnızca görüntüleme için bir format değil, aynı zamanda BT, ultrason (US), PET ve diğer modalitelerden tıbbi verilerin kullanımı için küresel standarttır. DICOM formatındaki her görüntü, benzersiz sayı yapısı olan SOP (Service-Object-Pair) sınıfı tarafından tanımlanan benzersiz bir kimliğe sahiptir.

DICOM görüntüleri yalnızca görüntüyü içermez, modalite, sunum, tarih, hasta ve daha fazla bilgi hakkında meta veriler barındırır. Modern sonografik cihazlar DICOM standardıyla çalışır. Ve veriler hastaneler ve doktorlar arasında birbirine bağlıdır (Kahn ve ark., 2007).

DICOM görüntüsü, dosya ve içerik olarak genellikle DCM veya DIC uzantısına sahiptir. DICOM' un dönüştürülmüş görüntüye karşı birincil faydaları, tek bir dosyada meta veriler ve çok sayıda dilim (katman) içeren orijinal kayıpsız kalitedir. ROI görüntüleme için kontrastı kolayca değiştirilebilir. DICOM standardı NEMA birliği (Ulusal Elektrik Üreticileri Birliği) tarafından yönetilmektedir (Ayayna ve Çalışkan, 2022).

2.2. Çalışmada Kullanılan Programlama Dili

DÖ gibi uygulamalar için çalışma veya geliştirmeler yapılırken özel problemlerde, sorunlara uygun olacak olan dinamiklikte bir program seçilmesi yerinde bir çözüm olacaktır. Çalışmada, karşılaşılabileceğimiz sorunların çözümünün yapılabileceği açık kaynak kodlu olan Python programlama dili kullanılmıştır.



Şekil 2.2. Python logo.

2.3. Bu Çalışmada Kullanılan Kütüphaneler

Görüntü segmente eden algoritmalar, görüntüdeki piksel sayısı ile orantılı bir şekilde doğrusal olarak çalışmalı ve verim katmalıdır. Kolay kullanım sağlaması için, segmentasyon yönteminin kenarları tespit etmede ve daha az değerli görüntü işleme teknikleri gibi hızlı çalışmayı gerektirir (Felzenszwalb ve Huttenlocher, 2004).

Yapılmış olan çalışmada, işlemleri yapabilmek için hazırladığımız yazılımda Python programlama dilindeki pandas, numpy, matplotlib, tensorflow ve keras, kütüphanelerinden yararlanılmıştır.

2.3.1. Pandas

Bu kütüphane verilerin çerçevelenmesinde kullanılması için geliştirilmiştir. Elde edilen verilerin tekrardan birleştirmede, şekillendirmede, dilimlemede vb. çeşitli özelliklerinden faydalanmamızı sağlamaktadır. Verilerin düzenlenmesi için Numpy kütüphanesi ile birlikte iş yaparlar (Salomon ve Bianca, 2018).

2.3.2. Numpy

N boyutundaki dizilerin veya matrislerin üzerinde kullanılmak ve hesaplamalar yapılmasını sağlayan kütüphanedir. Kütüphanenin amacı matematiksel işlemler yapmaktır (Salomon ve Bianca, 2018). Uygulama sırasında Numpy, veri işlemeden önce ve hazırlık aşamasında kullanılır.

2.3.3. Matplotlib

Genellikle iki boyut'taki (2B) çizimlerin ve grafiklerin kullanıldığı kütüphanedir. Bu kütüphane büyük dizilerde daha yüksek performans için Numpy kütüphanesi ile bir arada kullanılmaktadır. Matplotlib, basit komut yapısıyla grafikler oluşturmamıza yardımcı olan bir kütüphanedir (Bhartiya ve ark., 2021).

2.3.4. Tensorflow

Bu kütüphane, Google üzerinde açık kaynaklı olan bir DÖ kütüphanesidir. Google'ın yazılım üzerine çalışan mühendisleri tarafından MÖ ve DÖ çalışmaları için geliştirilmiştir. Bu kütüphane bilgisayarların ekran kart özelliğine dayanarak cpu veya gpu da çalışma performansını gösterir (Salomon ve Bianca, 2018).

2.3.5. Keras

Bu kütüphane DÖ hesaplamalarında kullanılan bir Python kütüphanesidir. Bu kütüphane, Python programlama dili ile yazılmış ve TensorFlow gibi kütüphanelerin üzerinde çalışabilecek olan bir sinir ağı API (Application Programming Interface)'sidir. Hızlı sonuç elde etmek için geliştirilmiştir (Gulli ve ark., 2017).

3. YAPAY ZEKÂ UYGULAMALARI

YZ, bir insanla karşılaştırılabilir akıllı davranışı ve eleştirel düşünmeyi simüle etmek için bilgisayarların ve teknolojinin kullanımını tanımlamak için kullanılan terimdir. John McCarthy, YZ terimini ilk olarak 1956'da akıllı makineler yapma bilimi ve mühendisliği olarak tanımladı (Malik ve ark., 2019). YZ, günlükteki sosyal hayatımızı ve ekonomimizdeki faaliyetleri destekleyen önemli bir teknolojidir (Lu, H., ve ark., 2018).

YZ, en az insan müdahalesi ile akıllı davranışı modellemek için bir bilgisayarın kullanılmasını ifade eden genel bir terimdir. YZ'nin genellikle robotların icadıyla başladığı kabul edilir. Terim, zorla çalıştırma olarak kullanılan biyosentetik makineler anlamına gelen Çekçe robota kelimesinden türemiştir (Hamet ve Tremblay, 2017).

YZ, tıbbi uygulamaları yavaş yavaş değiştiriyor. Dijitalleştirilmiş veri toplama, MÖ ve bilgi işlem altyapısındaki son gelişmelerle birlikte, YZ uygulamaları daha önce yalnızca insan uzmanların alanı olduğu düşünülen alanlara doğru genişliyor (Yu, KH. Ve ark., 2018). Bu modeller temel olarak sinir ağı katmanlarından meydana gelmektedir (Özcan, 2014). Katmanların şekli, sayısı, bağlanma şekilleri gibi özellikler DÖ modellerin şekillenmesine katkıda bulunmuştur.

3.1. Tıpta Yapay Zekâ Uygulamaları

Alan Turing (1950), modern bilgisayarların ve YZ'nin kurucularından biriydi. "Turing testi", bir bilgisayarın akıllı davranışının, bilişle ilgili görevlerde insan düzeyinde performans elde etme yeteneği olduğu gerçeğine dayanıyordu (Mintz ve Brodie, 2019). 1980'ler ve 1990'lar, YZ'ye olan ilgide bir artış gördü. Sağlık hizmetlerinde farklı klinik ortamlarda bulanık uzman sistemler, Bayes ağları, yapay sinir ağları (YSA) ve hibrit akıllı sistemler gibi YZ teknikleri kullanılmıştır. 2016'da YZ araştırmalarına yapılan yatırımların en büyük kısmı, diğer sektörlerle karşılaştırıldığında sağlık uygulamalarına yapıldı (Reis ve ark., 2019).

Tıp alanında YZ iki alt kısma ayrılabilir: Sanal kısım ve fiziksel kısım. Sanal kısım, elektronik sağlık kayıt sistemleri gibi uygulamalardan tedavi kararlarında sinir ağı tabanlı rehberliğe kadar uzanır. Fiziksel kısım, ameliyatların yapılmasına yardımcı olan robotlar, engelli insanlar için akıllı protezler ve yaşlı bakımı ile ilgilidir (Malik ve ark., 2019).

Radyoloji, yeni teknolojinin kullanımına en açık ve sıcak bakan branştır (Mayo ve Leung, 2018). Başlangıçta klinik görüntülemelerde görüntü elde etme ve depolama gibi idari işler için kullanılan bilgisayarlar, kökeni ile birlikte artık çalışma ortamının vazgeçilmez bir bileşeni haline gelmiştir. Resim arşivleme ve iletişim sistemi. Bir tarama mamografisinde CAD (bilgisayar destekli tanı) kullanımı iyi bilinmektedir. Son araştırmalar, pozitif öngörü değerleri, duyarlılık ve özgüllüğe dayalı olarak KAH'nin çok fazla tanısız yardım sağlamadığını göstermiştir. Ek olarak, yanlış pozitif tanıları radyoloğun dikkatini dağıtabilir ve gereksiz incelemelere neden olabilir (Fenton ve ark., 2007; Alcuskey ve ark., 2014). YZ, yalnızca anormal muayeneleri etiketleyerek değil, aynı zamanda BT'lerde, röntgenlerde, özellikle yüksek hacimli ortamlarda ve daha az insan kaynağına sahip hastanelerde MR görüntülerinde hızlı negatif muayeneleri belirleyerek radyolojide önemli yardım sağlayabilir.

3.2. Yapay Sinir Ağları

İnsan sinir sisteminin çalışması baz alınarak oluşturulan yöntem çalışmasına YSA denilmektedir, bu yapıdaki nöronlar farklı şekillerle birbirlerine bağlanmış ve bilgisayar destekli yapay bir beyin oluşturulmak istenmiştir. Tek bir hücreden oluşan basit bir YSA'ya nöron denilmektedir. Oluşturulan sinir ağları verilere uygun model çıkarmak için lineer olmayan hesaplamalar gerçekleştirir (Özcan, 2014).

Şekil 3.1'de bir YSA modeli gösterilmektedir. Görüntü sınıflandırması, insanların bebekken öğrendiği ön süreçlerden biridir.

Görüntü sınıflandırmasının temelleri, etrafımızdaki nesnelerin temel şekillerini ve geometrisini belirlemede yatar. Görüntünün ön işlenmesi (normalleştirme), görüntü segmentasyonu, temel özelliklerin çıkarılması ve sınıfın tanımlanması gibi aşağıdaki görevleri içeren bir süreçtir.

Mevcut görüntü sınıflandırma teknikleri, çalışma süresinde çok daha hızlı ve her zamankinden daha doğru, güvenlik özellikleri, kimlik doğrulama ve yetkilendirme için yüz tanıma, trafik tanımlama, tıbbi teşhis ve diğer alanlar dahil olmak üzere kapsamlı uygulamalar için kullanılabilir. Görüntü sınıflandırma fikri farklı yaklaşımlarla çözülebilir. Ancak MÖ algoritmaları aralarında en iyisidir.


Bu algoritmalar, yıllar önce önerilen fikre dayanmaktadır, ancak hesaplama gücü eksikliği nedeniyle uygulanamamıştır. DÖ fikriyle, modeller daha iyi eğitilir ve farklı görüntü temsili düzeylerini belirleyebilir.

Evrişimli sinir ağı, ilk katmanlardaki temel şekilleri öğrenerek ve daha derin katmanlardaki görüntünün özelliklerini öğrenerek daha doğru görüntü sınıflandırmasıyla sonuçlanarak bu alanda devrim yarattı.

Evrişimli sinir ağı fikri, 1962'de Hubel ve Wiesel tarafından nöronların hiyerarşik temsilinden ilham aldı, çalışmaları kedideki görsel korteksin uyarılarının çalışmasına dayanıyordu. İnsanlarda ve hayvanlarda görsel korteksin işleyişini anlamada bilgisayar görüşü alanında temel bir atılımdı.

Bu yazıda, bir görüntünün özelliği, DÖ kavramı kullanılarak evrişimli sinir ağı kullanılarak çıkarılmıştır.

Çeşitli uygulamalar için daha ileri sınıflandırma algoritmaları uygulanmaktadır (Jogin ve ark., 2018).




Şekil 3.1. YSA mimarisi.

3.3. Derin Öğrenme

Bu yöntem birincil olarak 2012 yılı gibi zamanda bilim insanlarımız tarafından kullanılmaya başlanmıştır. DÖ uygulamalarının oluşmasıyla birlikte kanser teşhisleri, görüntü/ses tanıma ve sanal gerçeklik gibi birden çok alanda çalışmalar geliştirmiştir. Bu yöntemin yaygın bir şekilde kullanılmasının en önemli sebebi problem çözümlerinde yüksek doğruluk oranında sonuç vermesidir (Özkan, 2017).

Bu algoritmanın yöntemi, MÖ algoritmasının bir alt dalıdır. Bu yöntem, verilerin kullanımında MÖ algoritması gibi aynı değil, katman olarak adlandırılan özel bir halini temsil eder.

Bu yöntemin algoritma yapıları YSA kökenli olup ve enerji tabanlı modellerden meydana gelmektedir. Mimari yapısı birden fazla katman ve saklı değişkenden oluşmaktadır (Özcan, 2014). Şekil 3.2’de DÖ mimarisi gösterilmiştir.



Şekil 3.2. Derin öğrenme mimarisi

DÖ modeli Şekil 3.1’de gösterilen YSA modelinin katman sayısının artırılmasıyla oluşmaktadır.

Şekil 3.2’de görüldüğü üzere YSA birden fazla yeni gizli katmanların eklenmesiyle ve bu katmanların yardımlarıyla çıkış katmanında sonucun tespit edilmesi sağlanmaktadır.

DÖ birçok gizli katmanların bulunması sebebiyle parametre sayısı da buna bağlı olarak çok yüksektir. Her bir katman kendinden sonra gelen birden fazla eğitilebilir katmanlardan oluşmaktadır (Özkan, 2017; Çalışkan, 2023c).

3.4. ESA Derin Öğrenme Modeli


Görüntü analizi ve bilgisayar görüşü bağlamında, DÖ yeni yollar açmaktadır (Chollet F. 2017). Onlarca yıldır araştırılan önceki sığ sinir ağı yaklaşımlarının aksine DÖ, art arda bağlanan sinirsel katmanların önemli ölçüde artan sayısı ile karakterize edilir (Kattenborn ve ark., 2021). ESA, girdi olarak 2B görüntüler biçiminde

milyonlarca parametrelili büyük veri kümelerini eğitebilen ve istenen çıktıları üretmek için filtrelerle birleştirebilen DÖ algoritmalarıdır (Chauhan ve ark., 2018).

ESA'lar, hedef sınıfı veya miktarı en iyi tanımlayan kenarlar, köşeler, dokular veya daha soyut şekiller gibi uzamsal özellikleri öğrenmek için tasarlanmıştır. Son araştırmalar, ESA karmaşık yapay görme problemleriyle başa çıkma yeteneğini göstermiştir. Sınıflandırma gibi görevlerde benzeri görülmemiş sonuçlar elde edilmiştir. Segmentasyon ve nesne algılama, genellikle insan doğruluğundan daha iyi performans göstermektedir (Cai ve Vasconcelos, 2019; Soni ve ark., 2022).

ESA'lar, el işi özellikler tasarlamak için herhangi bir çaba gerektirmeden girdi verilerinin hiyerarşik bir temsilini öğrenme yeteneğine sahiptir. Ağın farklı katmanları, farklı düzeylerde soyutlama yapabilir ve görüntüde bulunan örüntülerden farklı miktarda yapı yakalayabilirler. Görevlerin karmaşıklığı ve eğitim sırasında öğrenilmesi gereken çok sayıda ağ parametresi nedeniyle, ESA'lar rekabetçi sonuçlar elde etmek için çok sayıda açıklamalı eğitim görüntüsü gerektirir. Sonuç olarak, daha hızlı donanım ve daha yüksek miktarda eğitim verisi kullanılabilir hale gelir gelmez önemli performans artışı elde edilebilir (Milletari ve ark., 2017).

Şekil 3.3, giriş görüntüsünün dört seviyeli ayrıştırılmasıyla ESA modelinin genel görünümünü göstermektedir.



Şekil 3.3. ESA model örneği görselleştirmesi (Çalışkan, 2023c).

Şekil 3.3’de; k_l alçak geçiş filtre, k_h yüksek geçiren filtre, $\oplus$ kanal bazında birleştirme, $\rightarrow$ projeksiyon kısayolunu ifade etmektedir.

“ESA, girdi görüntüsünü 3×3 çekirdekli ve 1×1 dolgulu evrişim katmanları ile işler. Çıktının kanal sayısını evrişimden sonraki sayı belirtir. Özellik haritalarının


boyutunu küçültmek için iki ve 1×1 dolgu adımlı 3×3 evrişimli çekirdekler kullanılır. Ek olarak, girdi görüntüsü çoklu çözünürlüklü analiz yoluyla ayrıştırılır ve ayrıştırılan görüntüler kanal bazında birleştirilir. Projeksiyon kısayolları 1×1 kıvrımlarla yapılır. Evrişim katmanlarının çıktısı, küresel ortalama havuzlama ve ardından tamamen bağlı bir katman (fc) ile vektörleştirilir. Çıktının boyutu, girdi veri kümesine dâhil edilen sınıfların sayısına eşittir (Çalışkan, 2023c)''.

3.5.VGG16 Mimarisi

VGG16 mimarisi, 2014 senesinde ILSVR(Imagenet) başarıyla geçilmesi istenilmesiyle kullanılmış olan bir ESA mimarisidir (Çalışkan, 2022). Günümüze kadarki en iyi görüntü modellerinden bir tanesi olarak görülmektedir.

VGG16 için şu ana kadarki en değerli tarafı, birçok adette yüksek parametreye sahip olmasının aksine adım 1 ile 3×3 filtrenin evrişim katmanlarına kenetlenmesi ve her zaman aynı dolguyu ve adım 2'nin 2×2 filtresinin maxpool katmanını kullanmasıdır.

Bütün mimarisi boyunca sürekli olarak evrişim ve en yüksek havuz katmanları. En sonda 2 FC'ye (tamamen bağlı katmanlar) ve sonrasında çıktı için bir softmax'a sahiptir. Bu mimaride 16, ağırlıkları olan 16 katman barındırdığını temsil etmektedir. VGG16 ağ mimarisi oldukça büyük bir ağı sahiptir ve yaklaşık 138 milyon (yaklaşık) parametre barındırır (Thakur, 2019; Thakur ve ark., 2020).




Şekil 3.4. VGG16 mimarisi (Thakur, 2019)

3.6.VGG19 Mimarisi

Bu ağ mimarisi, ismini Oxford Üniversitesi'nde yer alan “Visual Geometry Group” adlı gruptan almaktadır.

Sonunda yer alan 19 ise katman sayısını temsil etmektedir.

Bu mimari, kendi içinde 16 convolution, 3 full connected layer, 5 MaxPool ve 1 SoftMax katmanı barındırır. VGG19, 19,6 milyar flop’a sahiptir (Hasan ve ark., 2022).




Şekil 3.5. VGG19 mimarisi (Hasan ve ark., 2022).

3.7. Xception Mimarisi

Xception modeli, yeni bir derin evrişimli sinir ağı yapısı olan InceptionV3 modelinde geliştirilmiş bir modeldir ve derinlemesine ayrılabilir evrişim kullanır.

Xception modeli, 14 bloğa bölünmüş 36 evrişimli katman içerir ve ortadaki 12 bloğun tümü doğrusal artık bağlantılar içerir.

Aynı zamanda model, giriş verilerinin her kanalında uzamsal katman katman evrişim gerçekleştiren derinlemesine ayrılabilir evrişimin özelliklerini ifade eder (Chen ve ark. 2021). Xception ağ mimarisi Şekil 3.6’da gösterilmektedir.




Şekil 3.6. Xception ağ mimarisi (Şener, A., & Ergen, 2022).

3.8. Evrişimsel Sinir Ağı Katmanları

ESA algoritması, bir görüntüde bulunan eğri ve kenar gibi alt düzey sistemleri görerek seçim işlemi yapar. Bu işlemleri yapmak için de katmanlar kullanır bu katmanlar alt bölümde gösterilmiştir (Sun ve ark., 2020).

3.8.1. Evrişimsel Katman


Bu katmanda kullanılan doğrusal olan fonksiyon, evrişim katmanı diye adlandırılır. Bunun saklı katmanında bulunan her bir düğüm, görüntüyü işlemenin özelliğini kullanabilmede programcıya destek sağlamaktadır (Salomon ve Bianca, 2018). Şekil 3.7’de görüldüğü gibi bu katmanda şekilde ölçeklendirme işlemi yapılmaktadır.



Şekil 3.7. Görüntüleri ölçekleme (Salomon ve Bianca, 2018).

Girişteki görüntünün 4×4 ve evrişim matrisini boyutun, Şekil 3.8’de görüldüğü gibi 2×2 olarak varsayarsak eğer ki evrişim matrisinin girişteki görüntüsü üzerinde tutar isek, matrisin aynı konumundaki sayıları ile girdidekiler arasında olan durumları hesaplayabilmektedir. Burada meydana gelen durum toplanarak sadece bir sayı elde edilmektedir (Wu, 2017).

Örnek olarak, matrisin girişinde sol üst bölgesinde ile üst bölgesindekiler ile üste bindirirsek, uzamsal konumundaki evrişim sonucuyla şekilde gösterildiği gibi oluşmaktadır: $1 \times 12 + 1 \times 20 + 1 \times 8 + 1 \times 12 = 52$. Bu durum Şekil 3.8’de gösterilmiştir.




Şekil 3.8. Evrişim işleminin gösterimi.

3.8.2. Havuzlama Katmanı

ESA, birçok görsel görevdeki son atılımların kaynağı olmuştur. Özellik havuzlama katmanları, gizli katmanların özellik haritalarının uzamsal boyutlarını azaltmak için ESA'larda yaygın olarak kullanılmaktadır. Bu ESA'lara uzamsal değişmezlik özelliğini verir ve ayrıca hızlanmaya neden olur ve aşırı uyumu azaltır (Sing ve ark., 2020).


Bu katman hesaplamaların yapıldığı alandır. Havuzlamanın hedefi evrişim katmanında yapılan boyutlandırma işlemini tekrardan yapıp ve modelimizin başarısını yükseltmek için özelliklerin çıkarılması işlemidir. Şekil 3.9’da gösterildiği gibi en yüksek havuzlama modeldeki maksimum piksel sayısını çıkartmaktır (Salomon ve Bianca, 2018).



Şekil 3.9. Maksimum havuzlama (Firelord, 2018).

3.8.3. Düzleştirme Katmanı

Düzleştirme katmanı Şekil 3.10’da gösterildiği gibi bütün özellik haritasında yer alan değerlerin sadece tek adet sütuna düzleştirme işlemine denilmektedir.




Şekil 3.10. Düzleştirme (Flatten) (Escontrela, 2018).

3.8.4. Bırakma Katmanı

ESA’nın içinde sinir ağları aralarında bağımlılık bulundurulur bu sebeple birbirlerini uyarımda bulunma eğilimleri fazladır. Böyle bir durum bazı fonksiyonlarda daha yüksek ağırlık alabileceği ve modele uygun hale gelebildiğini göstermektedir. Evrişim ağındaki fazla yükselmeyi engellemek sebebiyle bırakma fonksiyonu kullanılmaktadır (Salomon ve Bianca, 2018).

Eğitim sürecinde rastgele seçilmiş bazı nöronlar ya birer birer veya 1-p olasılıklarla ağından çıkarılır. Bunun sonucunda bir düğüm için gelen ve giden kenarlar azaltılarak elde edilir. Şekil 3.11.’de gösterildiği gibi böyle bir durum ağdaki

devamlılığın âdetini iki katına çıkartsa da modelin eğitim süreci azaltılmış olur (Budhiraja, 2016). Bırakma, 0 ile 1 arasındaki bir değeri almaktadır.



Şekil 3.11. Standart sinir ağı ve bırakma sonrası sinir ağı (Budhiraja, 2016).

3.9. Sınıflandırma Modellerinin Değerlendirilmesi

MÖ, uyarlanabilir öğrenmenin inşasıyla ilgilenen bir YZ alanıdır (Okay ve Çalışkan, 2023). Deneyimlerden elde edilen bilgileri kullanarak performanslarını iyileştirebilen bilgi işlem sistemleri. MÖ, genelleme yapabilen algoritmaların analizi ve yapılandırmayı inceleyen disiplindir. Uygulamada gerçekleşen en yaygın öğrenme görevlerinden biri sınıflandırmadır.

Sınıflandırma, nesne türlerinin önemli bir tanınmasıdır, örneğin belirli bir doku, kötü huylu dokuyu temsil eder veya etmez (Novaković ve ark., 2017).

3.9.1. Doğruluk Oranı

Yapılan model için doğruluk, genellikle modelimizin parametrelerini öğrenip sabitledikten sonra ve hiçbir öğrenme gerçekleşmemiş olmasından önce belirlenmektedir. Sonrasında test verilerinizi modele sunup modelinizi eğitebilirsiniz. Modelinizin yapmış olduğu hataların sayısı hedeflediklerinizle karşılaştırılır sonrasında kaybedilir. Nihai sonuç olarak kayıp oranı yüzdesi hesaplanır olur (Chen, 2017).

3.9.2. Kayıp Oranı

Bu oran, her eğitim setinde meydana gelen kayıpların ortalamasıdır. Uygulanmış olan DÖ modeliniz zaman içerisinde değiştiğinden, bir adımın ilk zamandaki üzerinde meydana gelen kaybı genellikle son zamana göre daha fazladır. Bu oran, oluşturulmuş olan modelin eğitimi sırasındaki her yinelemesinden sonra ne kadar güçlü ya da zayıf olarak davrandığını göstermektedir. Çoğunlukla, birkaç yinelemeden sonra kayıp oranı azaltılması hedeflenir (Chen, 2017).

3.9.3. Performans Metriği

Bu aşama, sınıflandırmadaki algoritmalarda performansın değerlendirilmesi için, sınıflar gerçek ve tahmini değerleri karışıklık matrisi ile karşılaştırılmasının yapıldığı bölümdür (Polat ve ark., 2017). Alıcı işlem karakteristiği (AİK), sınıflandırmadaki performansın ölçülmesi nedeniyle biyoinformatikte sık sık yararlanılan bir yoldur (Lasko ve ark., 2005).

- DP: Pozitif olan örneğin doğru sınıflandırılması olarak adlandırılan işlemdir (Hastaya hasta demek).
- DN: Negatif olan örneğin doğru sınıflandırılması olarak adlandırılan işlemdir (Hasta olmayana hasta değil demek).
- YP: Negatif olan örneğin yanlış sınıflandırılması işlemidir (Hasta olmayana hasta demek.).
- YN: Pozitif olan örneğin yanlış sınıflandırılması işlemidir (Hasta olana hasta değil demek).

Veri setindeki tüm örneklerin sınıf etiketlerinin sınıflandırılması için algoritmanın performans değerlendirmesine doğruluk oranı denilir. Bu doğruluk formülü Denklem 3.1’de gösterilmiştir (Polat ve ark., 2017).

Doğruluk oranı doğru olarak sınıflandırılan örneklerin yüzde olarak gösterilmesidir.

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

Denklem 3.2, sınıflayıcının gerçek pozitif olan sonuçlarını hangi oranda pozitif sınıf olarak etiketlendiğini gösteren orana doğru pozitif oranı (duyarlılık) denilir.

Duyarlılık hesabı Denklem 3.2’de gösterilmiştir (Polat ve ark., 2017). Gerçek pozitiflerin ne kadarının doğru bir şekilde tespit edildiğini belirtir.


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

Denklem 3.3, bütün negatif veri noktalarına göre istenmeden pozitif olarak kabul edilmiş negatif veri noktalarının oranına yanlış pozitif oranı (özgüllük) denilir. Örneğin, bize akciğer tümörü bulunmayan hastaların yüzdelik olarak ne kadarının gerçekte doğru olarak etiketlendiğini gösterir.

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

Şekil 3.12’de gösterilen, aynı olmayan eşik değerleri için doğru ve yanlış pozitiflik oranlarının, yatay ve dikey ekseninde yer aldığı eğriye AİK eğrisi denilir (Metz, 2006). Öz olarak belirtmek istenirse; soldaki üst köşeye en yakın olan AİK eğrisini veren test en kullanışlı test olarak tespit edilir (Streiner ve Cairney, 2007).

Şekil 3.12’de AİK eğrisinde yer alan diagonal eğrisinin yukarısında kalmış olan ve soldaki üst köşeye yaklaşan AİK eğrisinde x ve y sınıflandırıcıları kıyaslandığında, sınıflandırmada başarılı performansı x, y’ye göre daha yüksektir.




Şekil 3.12. AİK eğrisinin gösterimi (Lane ve Gantley, 2017).

4. BULGULAR VE TARTIŞMA

Çalışmada kullanılmış olan IQ-OTH/NCCD akciğer kanseri veri seti, akciğer kanseri teşhisi konan hastaların BT taramalarını içermektedir. Sağlıklı deneklerin yanı sıra farklı evrelerde kanser CT görüntüleri mevcuttur. IQ-OTH/NCCD slaytları bu iki merkezde onkologlar ve radyologlar tarafından işaretlenmiştir. Veri seti, 110 vakadan alınmış olan BT tarama dilimlerini temsil eden toplamda 1190 görüntü içermektedir. Bu vakaları normal, iyi ve kötü huylu olmak üzere üç sınıfa ayrılmıştır.

Çalışmada, VGG16 VGG19 ve Xception sinir ağ modelleri önerilmiştir. Veri setindeki vakalar iyi huylu, normal ve kötü huylu olarak üç sınıfa ayrılmıştır. Bu görüntülerden 40'ı malign olarak teşhis edilir; Benign tanılı 15 olgu ve normal vaka olarak sınıflandırılan 55 vaka bulunmaktadır. BT taramaları orijinal olarak DICOM formatında toplanmıştır. Rastgele 1095 resim seçilerek, bu resimlerden test için aldığımız 3 sınıftan Normal 206 adet, Malign(iyi huylu) 60 adet, Malignant (kötü huylu) 261 adet olmak üzere toplam 527 adet resim seçilmiştir.

Eğitim için ise 3 sınıftan Normal yani sağlıklı 167 akciğer BT görüntüsü, Malign 69 görüntü, Malignant 332 olmak üzere toplam 568 adet görüntü seçilmiştir. Çalışmada Önerilen DÖ modeli Şekil 4.1'de sunulmuştur.



Şekil 4.1. Önerilen derin öğrenme modeli.

4.1.VGG16


Modelin eğitimi yapılırken verilerin bütünü birlikte eğitime katılmazlar. Belirli bir miktarda parça parça halde eğitimde bulunurlar. İlk parçanın eğitiminden sonra, modelin başarısı kontrol edilir. Modelin başarısına bağlı olarak geriye yayılım (“backpropagation”) yardımıyla ağırlıklar yenilenir. Sonrasında başka bir eğitim kümesiyle modelimiz tekrardan eğitilip ağırlıkları yeniden yenilenir. Modelin bu şekilde tüm eğitim adımlarında yenilenerek, en sağlıklı ağırlık değerlerini bulmaya çalışılmaktadır. Buradaki eğitim adımlarının tek tek her bir âdetine “Eğitim Tür Sayısı (Epoch)” denilir.

Bu çalışmamızda Epoch değeri 1000 olarak ayarlanmıştır. Modelde program en yüksek doğruluk değerine Çizelge 4.1’de görüldüğü üzere 25’inci adımda ulaşmıştır. Sonrasında değerler düşmeye başlamış ve program kendini 31’inci adımda durdurmuştur. Bu çalışma toplamda 1 saat 23 dakika sürmüştür.


Çizelge 4.1. VGG16 için Eğitim tur (Epoch) tablosu.

Tur	Doğruluk	Kayıp
1	0.5335	1.0615
8	0.8415	0.3823
15	0.9049	0.2570
22	0.9313	0.1748
25	0.9419	0.1637
26	0.9415	0.1481
28	0.9268	0.1792
31	0.9225	0.2073

Önerilen model Şekil 4.2’de gösterildiği üzere eğitim ve test verileri için doğruluk oranı % 94.19, en düşük kayıp oranı Şekil 4.3’te %0.1481 olarak elde edilmiştir.



Şekil 4.2. VGG16 ile önerilen model için doğruluk grafiği.



Şekil 4.3. VGG16 ile önerilen model için kayıp grafiği

4.2.VGG19


VGG19 modeli ile Epoch değeri 1000 olarak ayarlanmıştır. Modelde en yüksek doğruluk değerine Çizelge 4.2’de görüldüğü üzere 33’üncü adımda ulaşılmıştır. Sonrasında değerler düşmeye başlamış ve program kendini 38’inci adımda durdurmuştur. Bu uygulama ise toplamda 2 saat 47 dakika sürmüştür.

Çizelge 4.2. VGG19 için Eğitim tur (Epoch) tablosu.


Tur	Doğruluk	Kayıp
1	0.762324	0.615734
9	0.813380	0.429712
15	0.864437	0.282081

22	0.913732	0.215169
32	0.945423	0.147346
33	0.952465	0.116154
36	0.934859	0.155801
38	0.947183	0.134220

Önerilen model Şekil 4.4'te gösterildiği üzere eğitim ve test verileri için doğruluk oranı %95,24, en düşük kayıp oranı Şekil 4.5'te %0.1161 olarak elde edilmiştir.




Şekil 4.4. VGG19 ile önerilen model için doğruluk grafiği.



Şekil 4.5. VGG19 ile önerilen model için kayıp grafiği.

```
[90] from tensorflow.keras.preprocessing.image import *
      from tensorflow.keras.applications.efficientnet import preprocess_input

img = load_img('/content/drive/MyDrive/VL/dataset/dataset/ornekler/ornek2.jpg', target_size = (100,100))
display(img)
img= img_to_array(img)
img = img/255
img = np.expand_dims(img, axis=0)
img = preprocess_input(img)
pred = model.predict(img)
predicted_index = np.argmax(pred[0])
class_labels = list(test_ds.class_indices)
print(class_labels[predicted_index])
print(pred[0])
```



```
1/1 [=====] - 0s 344ms/step
Malignant cases
[9.3002658e-04 9.9844545e-01 6.2450639e-04]
```


Şekil 4.6. VGG19 ile önerilen model ile sınıflandırma.

4.3.Xception


Xception ile olan çalışmamızda Epoch değeri 10000 olarak ayarlanmıştır. Modelde program en yüksek doğruluk değerine Çizelge 4.3'te görüldüğü üzere 12'inci adımda ulaşmıştır. Sonrasında değerler düşmeye başlamış ve program kendini 14'üncü adımda durdurmuştur. Bu uygulama ise toplamda 25 dakika sürmüştür.

Çizelge 4.3. Xception için tur (Epoch) tablosu.

Tur	Doğruluk	Kayıp
1	0.864437	0.314785
3	0.855634	0.343633
12	0.901408	0.261188
14	0.889085	0.262471



Şekil 4.7. Xception ile önerilen model için doğruluk grafiği.



Şekil 4.8. Xception ile önerilen model için kayıp grafiği.

Önerilen model Şekil 4.7’de gösterildiği üzere eğitim ve test verileri için doğruluk oranı %90.14, modelin en düşük kayıp oranı Şekil 4.8’de %0.2611 olarak elde edilmiştir.

Çizelge 4.4. Modellerden elde edilen sonuçların karşılaştırılması

Model / Yöntem	Sınıf	Kayıp Oranı	Doğruluk (%)
VGG16	İyi huylu	0,1481	94,19
	Kötü huylu	0,1484	
VGG19	İyi huylu	0,1165	95,24
	Kötü huylu	0,1152	

Xception	İyi huylu	0,2611	90,14
	Kötü huylu	0,259	

DÖ teknikleri kullanılarak akciğer kanserinin tespit edilip sınıflandırılması amaçlanarak oluşturulan modelde, VGG16, VGG19, Xception modelleri ile sırası ile %94,19, %95,24, %90,14 başarı oranları elde edilmiştir. Bu oranlar, benzer veri setleri ile gerçekleştirilmiş çalışmalar ile Çizelge 4.5'te karşılaştırılmıştır.

Çizelge 4.5. Benzer veri setleri ile gerçekleştirilmiş çalışmaların karşılaştırılması

Çalışma	Yıl	Sınıf türü	Model / Yöntem	Doğruluk (%)
Bhatia ve ark.	2019	İyi huylu, normal, kötü huylu	UNet ve ResNet	84
Niki ve ark.	2001	İyi huylu, normal, kötü huylu	K-means algoritması. Lineer karmaşıklık algoritması. Karar destek makine algoritması.	80
Ciompri ve ark.	2017	İyi huylu, normal, kötü huylu	Çok ölçekli ESA modeli	79.5
Teramoto ve Fujita	2013	İyi huylu, normal, kötü huylu	Silindirik nodül iyileştirme filtresi	80
Song ve ark.	2017	İyi huylu, normal, kötü huylu	DSA ESA SAE	%82,37 %84,15 %82,59
Elnakib ve ark.	2020	İyi huylu, normal, kötü huylu	VGG19	96,25
Sun ve ark.	2016	İyi huylu, normal, kötü huylu	ESA DBN SDAE	79,76 0 81,19 79,29
Kalaivani ve ark.	2020	İyi huylu, normal, kötü huylu	DenseNet	90,85
Bu çalışma	2023	İyi huylu, normal, kötü huylu	VGG16 VGG19 Xception	94,19 95,24 90,14

5. SONUÇ VE ÖNERİLER

YZ'nin sağlık alanında uygulanmasının değeri gün geçtikçe artmaktadır. Özellikle hastalığın tanısının konması bazen uzun sürebilmektedir. Bu süre zarfında, hastalığın ilerlemesi artık tedavinin imkân dışı olmasına sebebiyet verip, yaşam kalitesini kötü etkilemenin yanı sıra bazen de ölümle sonuçlanmaktadır.

Akciğer kanseri gibi yüksek riskli hastalıkların mümkün oldukça erken teşhis edilip kanserin iyi huylu veya kötü huylu olarak sınıflandırılması hayati önem taşımaktadır. İleri seviye de olan akciğer kanserinin tedavisi çoğu kez imkânsız olarak görülür. Akciğer kanserinin beyin bölgesine metastaz olasılığının yüksek olması açısından da hassasiyeti daha da önem arz etmektedir.

YZ'nin gelişimiyle birlikte medikal ve tıbbi alanda sağlıkçıların, doktorların iş yüklerini hafifletilmekle birlikte kesin tanı konusunda büyük önem arz etmektedir. Akciğerin BT görüntülerinde yapılan sınıflandırmada eğitim fazı sırasında iyi huylu ve kötü huylu kanserler için kayıp oranı eğitim aşaması sırasında kayıp oluşmuştur. Eğitimin kayıp değerleri, eğitimin sonucunda en düşük değer elde edilmesi hedeflenerek devamlı değişiklik yapılması gerekmektedir. Önerilen mimarideki kaybın değeri, devamlı değişiklik göstermiştir. Eğitimdeki kayıp miktarı minimuma düşürmek amaçlanmış olup, örneklerin eğitebilecek duruma getirilip kayıp değerinin sıfıra yakın olması amaçlanmıştır.

Bu çalışmada, DÖ teknikleri kullanılarak akciğer kanserinin tespit edilip sınıflandırılması amaçlanmıştır. Oluşturulan modelde, VGG16 modeli ile doğruluk oranı %94,19, en düşük kayıp oranı %0.1481, VGG19 modeli ile doğruluk oranı %95,24, en düşük kayıp oranı %0.1161, Xception modeli ile 90,14, en düşük kayıp oranı %0.2611 olarak elde edilmiştir.

Sonuç olarak, bu çalışma da elde edilen sonuçların doğruluk oranının yüksek olduğu görülmüş olup, akciğer kanserinin erken teşhisi ve sınıflandırılması açısından doktorların iş yükünü hafifletmekle birlikte, doğru sonuca ulaşmak için hasta üzerinde herhangi bir operasyona gerek kalmadan hastalığa doğru teşhis konulmasına yardımcı olacağı düşünülmektedir. Gelecek çalışmalarda, farklı görüntüleme yöntemiyle elde edilmiş veri setleri kullanılarak akciğer kanserinin tanı sürecinde DÖ tabanlı yeni yaklaşımlar tasarlanacaktır.

6. KAYNAKLAR

- Aberle, D. R., DeMello, S., Berg, C. D., Black, W. C., Brewer, B., Church, T. R., & Sicks, J., 2013, Results of the two incidence screenings in the National Lung Screening Trial, *New England Journal of Medicine*, 369(10), 920-931.
- Abiwinanda, N., Hanif, M., Hesaputra, S. T., Handayani, A., & Mengko, T. R., 2019, Brain tumor classification using convolutional neural network, *In World Congress on Medical Physics and Biomedical Engineering 2018: June 3-8*, 1, 183-189.
- Agarwal, A., Patni, K., & Rajeswari, D., 2021, Lung cancer detection and classification based on alexnet CNN, *In 2021 6th International Conference on Communication and Electronics Systems (ICCES)*, 1390-1397.
- Aggarwal, T., Furqan, A., & Kalra, K., 2015, Feature extraction and LDA based classification of lung nodules in chest CT scan images, *In 2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 1189-1193.
- Akram, S., Javed, M. Y., Hussain, A., Riaz, F., & Usman Akram, M., 2015, Intensity-based statistical features for classification of lungs CT scan nodules using artificial intelligence techniques, *Journal of Experimental & Theoretical Artificial Intelligence*, 27(6), 737-751.
- Alakwaa, W., Nassef, M., & Badr, A., 2017, Lung cancer detection and classification with 3D convolutional neural network (3D-CNN), *International Journal of Advanced Computer Science and Applications*, 8(8).
- Alcusky, M., Philpotts, L., Bonafede, M., Clarke, J., & Skoufalos, A., 2014, The patient burden of screening mammography recall, *Journal of Women's Health*, 23(S1), S-11.
- Ali, A., Manzoor, M. F., Ahmad, N., Aadil, R. M., Qin, H., Siddique, R., & Aizhong, L., 2022, The burden of cancer, government strategic policies, and challenges in Pakistan: A comprehensive review, *Frontiers in Nutrition*, 1553.
- Althubaity, D. D., Alotaibi, F. F., Osman, A. M. A., Al-khadher, M. A., Abdalla, Y. H. A., Alwesabi, S. A., ... & Alhemairy, M. A., 2023,. Automated Lung Cancer Segmentation n Tissue Micro Array Analysis Histopathological Images Using a Prototype of Computer-Assisted Diagnosis, *Journal of Personalized Medicine*, 13(3), 388.
- Alyasriy, H., & Muayed, A. H., 2020, The IQ-OTHNCCD lung cancer dataset, *Mendeley Data*, 1(1), 1-13.
- Anadolusaglik, 2023, Eriřim Adresi: <https://www.anadolusaglik.org/saglik-teknolojileri/pet-ct>. [Ziyaret Tarihi: 26 Ocak 2023]
- Asuntha, A., & Srinivasan, A., 2020, Deep learning for lung Cancer detection and classification, *Multimedia Tools and Applications*, 79, 7731-7762.

- Ayayna, F. & Çalışkan, A., 2022, Processing of Medical Diagnostic Medical Images, *International Informatics Congress (IIC2022)*, 307-317.
- Benjamin, M. S., Drucker, E. A., McLoud, T. C., & Shepard, J. A. O., 2003, Small pulmonary nodules: detection at chest CT and outcome, *Radiology*, 226(2), 489-493.
- Bhandary, A., Prabhu, A., Rajinikanth, V., Krishnan, P., Satapathy, S., Robbins, D., Shasky, C., Zhang, Y.-D., Tavares, J., & Raja, N., 2020, Deep-learning framework to detect lung abnormality – a study with chest X-ray and lung CT scan images, *Pattern Recognition Letters*, 129, 271–278.
- Bhartiya, P., Yadav, S., Gupta, A., & Gupta, D., 2021, Pneumonia Detection Using CNN and ANN Based on Deep Learning Approach, *Emerging Technologies for Healthcare: Internet of Things and Deep Learning Models*, 181-201.
- Bhatia, S., Sinha, Y., & Goel, L., 2019, Lung cancer detection: a deep learning approach, *In Soft Computing for Problem Solving*, Springer, Singapore, 699-705.
- Bhuvaneswari, P., & Therese, A. B., 2015, Detection of cancer in lung with k-nn classification using genetic algorithm, *Procedia Materials Science*, 10, 433-440.
- Blanchon, T., Bréchet, J. M., Grenier, P. A., Ferretti, G. R., Lemarié, E., Milleron, B., & Flahault, A., 2007, Baseline results of the Depiscan study: a French randomized pilot trial of lung cancer screening comparing low dose CT scan (LDCT) and chest X-ray (CXR), *Lung cancer*, 58(1), 50-58.
- Bracken-Clarke, D., Kapoor, D., Baird, A. M., Buchanan, P. J., Gately, K., Cuffe, S., & Finn, S. P., 2021, Vaping and lung cancer—A review of current data and recommendations, *Lung Cancer*, 153, 11-20.
- Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R. L., Torre, L. A., & Jemal, A., 2018, Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries, *CA: a cancer journal for clinicians*, 68(6), 394-424.
- Buckinx, F., Reginster, J. Y., Dardenne, N., Croisier, J. L., Kaux, J. F., Beudart, C., & Bruyère, O., 2015, Concordance between muscle mass assessed by bioelectrical impedance analysis and by dual energy X-ray absorptiometry: a cross-sectional study, *BMC musculoskeletal disorders*, 16(1), 1-7.
- Budhiraja, A., 2016, Dropout in (Deep) Machine Learning, Erişim Adresi: <https://medium.com/@amarbudhiraja/https-medium-com-amarbudhirajalearning-less-to-learn-better-dropout-in-deep-machine-learning-74334da4bfc5> [Ziyaret Tarihi: 12 Kasım 2022]
- Bunyaviroch, T., & Coleman, R. E., 2006, PET evaluation of lung cancer, *Journal of nuclear medicine*, 47(3), 451-469.

- Cai, Z., & Vasconcelos, N., 2019, Cascade R-CNN: high quality object detection and instance segmentation, *IEEE transactions on pattern analysis and machine intelligence*, 43(5), 1483-1498.
- Cao, W., Chen, H. D., Yu, Y. W., Li, N., & Chen, W. Q., 2021, Changing profiles of cancer burden worldwide and in China: a secondary analysis of the global cancer statistics 2020, *Chinese medical journal*, 134(07), 783-791.
- Carter, D., 2014, New global survey shows an increasing cancer burden, *AJN The American Journal of Nursing*, 114(3), 17.
- Cengil, E., & Cinar, A., 2018, A deep learning based approach to lung cancer identification, *In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, 1-5.
- Chabat, F., Yang, G. Z., & Hansell, D. M., 2003, Obstructive lung diseases: texture classification for differentiation at CT, *Radiology*, 228(3), 871-877.
- Chauhan, R., Ghanshala, K. K., & Joshi, R. C., 2018, Convolutional neural network (CNN) for image detection and recognition, *In 2018 First International Conference on Secure Cyber Computing and Communication (ICSCCC), IEEE*, 278-282.
- Chen, K., 2017, How to interpret “loss” and “accuracy” for a machine learning model, ErişimAdresi:<https://stackoverflow.com/questions/34518656/how-to-interpret-loss-and-accuracy-for-a-machine-learning-model> [Ziyaret Tarihi: 13 Kasım 2022].
- Chen, Y., Yi, H., Liao, C., Huang, P., & Chen, Q., 2021, Visual measurement of milling surface roughness based on Xception model with convolutional neural network, *Measurement*, 186, 110217.
- Chollet, F., 2017, Xception: Deep learning with depthwise separable convolutions, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-1258.
- Collins, L. G., Haines, C., Perkel, R., & Enck, R. E., 2007, Lung cancer: diagnosis and management, *American family physician*, 75(1), 56-63.
- Çalışkan, A., 2022, Classification of Tympanic Membrane Images based on VGG16 Model, *Kocaeli Journal of Science and Engineering*, 5(1), 105-111.
- Çalışkan, A., 2023a, Detecting human activity types from 3D posture data using deep learning models, *Biomedical Signal Processing and Control*, 81, 104479.
- Çalışkan, A., 2023b, Diagnosis of malaria disease by integrating chi-square feature selection algorithm with convolutional neural networks and autoencoder network, *Transactions of the Institute of Measurement and Control*, 45(5), 975-985.
- Çalışkan, A., 2023c, Dalgacık Evrişimsel Sinir Ağı Yöntemi ile Koronavirüs Hastalığının Tespiti, *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 26(1), 203-212.

- Dandıl, E., 2017, Implementation and comparison of image segmentation methods for detection of brain tumors on MR images, *In 2017 International Conference on Computer Science and Engineering (UBMK)*, 1025-1029.
- De Wever, W. Stroobants, S. Coolen, J., & Verschakelen, J. A., 2009, Integrated PET/CT in the staging of nonsmall cell lung cancer: technical aspects and clinical integration, *European Respiratory Journal*, 33(1), 201-212.
- Doğan, B., Demir, Ö., & Çalık, S. K., 2016, Computer-aided detection of brain tumors using morphological reconstruction, *Uludağ University Journal of The Faculty of Engineering*, 21(2).
- Duan, X., Liu, N., Gou, M., Wang, W., & Qin, C. (2020). SteganoCNN: Image steganography with generalization ability based on convolutional neural network, *Entropy*, 22(10), 1140.
- Dwivedi, S. A., Borse, R. P., & Yametkar, A. M., 2014, Lung cancer detection and classification by using machine learning & multinomial Bayesian, *IOSR Journal of Electronics and Communication Engineering (IOSR-JECE)*, 9(1), 69-75.
- Ekşi, Z., Dandıl, E., & Çakıroğlu, M., 2012, Computer aided bone fracture detection, *In 2012 20th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Elnakib, A., Amer, H. M., & Abou-Chadi, F. E., 2020, Early lung cancer detection using deep learning optimization, *International Association of Online Engineering*.
- Erbaş, G., 2012, Adım Adım Akciğer Bilgisayarlı Tomografisi: Bölüm 2, *Yoğun Bakım Dergisi*, 10(4).
- Escontrela, A. (2018). Convolutional Neural Networks from the ground up, *Towards Data Science*, 17.
- Felzenszwalb, P. F., & Huttenlocher, D. P., 2004, Efficient graph-based image segmentation, *International journal of computer vision*, 59(2), 167-181.
- Fenton, J. J., Taplin, S. H., Carney, P. A., Abraham, L., Sickles, E. A., D'Orsi, C., & Elmore, J. G., 2007, Influence of computer-aided detection on performance of screening mammography, *New England Journal of Medicine*, 356(14), 1399-1409.
- Firelord, P., 2018, Max-pooling/Pooling, Erişim Adresi: https://computersciencewiki.org/index.php/Max-pooling/_Pooling [Ziyaret Tarihi: 13 Kasım 2022].
- Fleischmann, D., & Boas, F. E., 2011, Computed tomography—old ideas and new technology, *European radiology*, 21, 510-517.
- Forte, G. C., Altmayer, S., Silva, R. F., Stefani, M. T., Libermann, L. L., Cavion, C. C., & Hochegger, B., 2022, Deep learning algorithms for diagnosis of lung cancer: a systematic review and meta-analysis, *Cancers*, 14(16), 3856.

- Fu'adah, Y. N., Pratiwi, N. C., Pramudito, M. A., & Ibrahim, N., 2020, Convolutional neural network (cnn) for automatic skin cancer classification system, *In IOP conference series: materials science and engineering*, 982 (1), 012005.
- Gulli, A., & Pal, S., 2017, Deep Learning with Keras, *Packt Publishing Ltd*.
- Gumma, L. N., Thiruvengatanadhan, R., Kurakula, L., & Sivaprakasam, T., 2022, A Survey on Convolutional Neural Network (Deep-Learning Technique)-Based Lung Cancer Detection, *SN Computer Science*, 3, 1-7.
- Ha, W., & Vahedi, Z., 2021, Automatic breast tumor diagnosis in mri based on a hybrid cnn and feature-based method using improved deer hunting optimization algorithm, *Computational Intelligence and Neuroscience*, 2021.
- Hamdalla, A., 2020, The IQ-OTHNCCD Lung Cancer Dataset, <https://www.kaggle.com/datasets/antonixx/the-iqothnccd-lung-cancer-dataset>. [Ziyaret Tarihi: 20 Ağustos 2022].
- Hamet, P., & Tremblay, J., 2017, Artificial intelligence in medicine, *Metabolism*, 69, S36-S40.
- Haque, I. R. I., & Neubert, J., 2020, Deep learning approaches to biomedical image segmentation, *Informatics in Medicine Unlocked*, 18, 100297.
- Hasan, M. M., Islam, N., & Rahman, M. M., 2022, Gastrointestinal polyp detection through a fusion of contourlet transform and Neural features, *Journal of King Saud University-Computer and Information Sciences*, 34(3), 526-533.
- Ibrahim, D. M., Elshennawy, N. M., & Sarhan, A. M., 2021, Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases, *Computers in biology and medicine*, 132, 104348.
- Jogin, M., Madhulika, M. S., Divya, G. D., Meghana, R. K., & Apoorva, S., 2018, Feature extraction using convolution neural networks (CNN) and deep learning, *In 2018 3rd IEEE international conference on recent trends in electronics, information & communication technology (RTEICT)*, 2319-2323.
- Jung, H., 2021, Basic physical principles and clinical applications of computed tomography, *Progress in Medical Physics*, 32(1), 1-17.
- Kahn, C. E., Carrino, J. A., Flynn, M. J., Peck, D. J., & Horii, S. C., 2007, DICOM and radiology: past, present, and future, *Journal of the American College of Radiology*, 4(9), 652-657.
- Kalaivani, N., Manimaran, N., Sophia, S., & Devi, D. D., 2020, Deep learning based lung cancer detection and classification, *In IOP conference series: materials science and engineering*, 994 (1), 012026.
- Kanipriya, M., Hemalatha, C., Sridevi, N., SriVidhya, S. R., & Shabu, S. J., 2022, An improved capuchin search algorithm optimized hybrid CNN-LSTM architecture for malignant lung nodule detection, *Biomedical Signal Processing and Control*, 78, 103973.

- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S., 2021, Review on Convolutional Neural Networks (CNN) in vegetation remote sensing, *ISPRS journal of photogrammetry and remote sensing*, 173, 24-49.
- Keser, İ., Özdemir, K., Ertürk, B., Haspolat, M., Duman, T., & Esmer, M., 2017, Kanser Hastalarına yönelik onkolojik rehabilitasyon ünitesi'nde sunulan hizmetlerin analizi, *Gazi Sağlık Bilimleri Dergisi*, 2(1), 18-27.
- Krizhevsky, A., Sutskever, I., Hinton, G. E., Pereira, F., Burges, C. J. C., Bottou, L., & Weinberger, K. Q., 2012, Advances in neural information processing systems, 1097–1105.
- 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(12), 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.
- Lei, S., Zheng, R., Zhang, S., Wang, S., Chen, R., Sun, K., & Wei, W., 2021, Global patterns of breast cancer incidence and mortality: A population-based cancer registry data analysis from 2000 to 2020, *Cancer Communications*, 41(11), 1183-1194.
- Li, J., Sina, A. A., Antaw, F., Fielding, D., Möller, A., Lobb, R., & Trau, M., 2023, Digital decoding of single extracellular vesicle phenotype differentiates early malignant and benign lung lesions, *Advanced Science*, 10(1), 2204207.
- Li, K., Liu, K., Zhong, Y., Liang, M., Qin, P., Li, H., & Liu, X., 2021, Assessing the predictive accuracy of lung cancer, metastases, and benign lesions using an artificial intelligence-driven computer aided diagnosis system, *Quantitative Imaging in Medicine and Surgery*, 11(8), 3629.
- Liu, X., Li, K. W., Yang, R., & Geng, L. S., 2021, Review of deep learning based automatic segmentation for lung cancer radiotherapy, *Frontiers in Oncology*, 11, 717039.
- Malik, P., Pathania, M., & Rathaur, V. K., 2019, Overview of artificial intelligence in medicine, *Journal of family medicine and primary care*, 8(7), 2328.
- Mao, K., & Deng, Z., 2016, Lung nodule image classification based on local difference pattern and combined classifier, *Computational and Mathematical Methods in Medicine*, 2016, 1091279.
- Matteson, S. R., Deahl, S. T., Alder, M. E., & Nummikoski, P. V., 1996, Advanced imaging methods, *Critical Reviews in Oral Biology & Medicine*, 7(4), 346-395.
- Mayo, R. C., & Leung, J., 2018, Artificial intelligence and deep learning–Radiology's next frontier?, *Clinical imaging*, 49, 87-88.

- Medikalfizik., 2017, erişim adresi, <https://www.medikalfizik.net/2017/02/07/bilgisayarli-tomografi-bt/> [Ziyaret Tarihi: 25 Ocak 2023].
- 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.
- Milletari, F., Ahmadi, S. A., Kroll, C., Plate, A., Rozanski, V., Maiostre, J., & Navab, N., 2017, Hough-CNN: deep learning for segmentation of deep brain regions in MRI and ultrasound, *Computer Vision and Image Understanding*, 164, 92-102.
- Minn, H., Zasadny, K. R., Quint, L. E., & Wahl, R. L., 1995, Lung cancer: reproducibility of quantitative measurements for evaluating 2-[F-18]-fluoro-2-deoxy-D-glucose uptake at PET, *Radiology*, 196(1), 167-173.
- Mintz, Y., & Brodie, R., 2019, Introduction to artificial intelligence in medicine, *Minimally Invasive Therapy & Allied Technologies*, 28(2), 73-81.
- Mustra, M., Delac, K., & Grgic, M., 2008, Overview of the DICOM standard, *In 2008 50th International Symposium ELMAR*, 1, 39-44.
- Nageswaran, S., Arunkumar, G., Bisht, A. K., Mewada, S., Kumar, J. N. V. R., Jawarneh, M., & Asenso, E., 2022, Lung cancer classification and prediction using machine learning and image processing, *BioMed Research International*, 2022.
- Nasrullah, N., Sang, J., Alam, M. S., Mateen, M., Cai, B., & Hu, H., 2019, Automated lung nodule detection and classification using deep learning combined with multiple strategies, *Sensors*, 19(17), 3722.
- Navaneethakrishnan, M., Anand, M. V., Vasavi, G., & Rani, V. V., 2023, Deep Fuzzy SegNet-based lung nodule segmentation and optimized deep learning for lung cancer detection, *Pattern Analysis and Applications*, 1-17.
- Ngo, A., Cheng, K. W., Chaloupka, F. J., & Shang, C., 2017, The effect of MPOWER scores on cigarette smoking prevalence and consumption, *Preventive medicine*, 105, S10-S14.
- Nivetha, P., & Manickavasagam, M. R., 2014, Lung cancer detection at early stage using PET/CT imaging technique, *International Journal of Innovative Research in Computer and Communication Engineering*, 2(3).
- Novaković, J. D., Veljović, A., Ilić, S. S., Papić, Ž., & Tomović, M., 2017, Evaluation of classification models in machine learning, *Theory and Applications of Mathematics & Computer Science*, 7(1), 39.
- Okay, H., & Çalışkan, A., 2023, Heart Attack Risk Analysis and Estimation Using Machine Learning Methods, *Intelligent Methods In Engineering Sciences*, 2(1), 1-4.

- Özcan, H., 2014, Çok Düşük Çözünürlüklü Yüz İmgelerinde Derin Öğrenme Uygulamaları, Deniz Harp Okullu, *Deniz Bilimleri ve Mühendisliği Enstitüsü*, İstanbul.
- Özkan, İ., & Ülker, E., 2017, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85104.
- Passaretti, D., Ghosh, M., Abdurahman, S., Egito, M. L., & Pionteck, T., 2022, Hardware optimizations of the x-ray pre-processing for interventional computed tomography using the fpga, *Applied Sciences*, 12(11), 5659.
- 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.
- Porto-Álvarez, J., Barnes, G. T., Villanueva, A., García-Figueiras, R., Baleato-González, S., Huelga Zapico, E., & Souto-Bayarri, M., 2023, Digital Medical X-ray Imaging, CAD in Lung Cancer and Radiomics in Colorectal Cancer: Past, Present and Future, *Applied Sciences*, 13(4), 2218.
- Reddy, N. S., & Khanaa, V., 2023, Intelligent deep learning algorithm for lung cancer detection and classification, *Bulletin of Electrical Engineering and Informatics*, 12(3), 1747-1754.
- Reis, J., Santo, P. E., & Melão, N., 2019, Artificial intelligence in government services: A systematic literature review, *New Knowledge in Information Systems and Technologies*, 1, 241-252.
- Rubin, G. D., 2015, Lung nodule and cancer detection in CT screening, *Journal of thoracic imaging*, 30(2), 130.
- Salomon, J., & Bianca, S. (2018), Lung cancer detection using deep learning, *Dublin Institute of Technology*.
- Schabath, M. B., & Cote, M. L., 2019, Cancer progress and priorities: lung cancer, *Cancer epidemiology, biomarkers & prevention*, 28(10), 1563-1579.
- Schalekamp, S., Klein, W. M., & van Leeuwen, K. G., 2022, Current and emerging artificial intelligence applications in chest imaging: a pediatric perspective, *Pediatric Radiology*, 52(11), 2120-2130.
- Seeram, E., 2018, Computed tomography: a technical review, *Radiologic technology*, 89(3), 279CT-302CT.
- Shimazaki, A., Ueda, D., Choppin, A., Yamamoto, A., Honjo, T., Shimahara, Y., & Miki, Y., 2022, Deep learning-based algorithm for lung cancer detection on chest radiographs using the segmentation method, *Scientific Reports*, 12(1), 727.
- Siah, K. W., Khozin, S., Wong, C. H., & Lo, A. W., 2019, Machine-learning and stochastic tumor growth models for predicting outcomes in patients with advanced non-small-cell lung cancer, *JCO clinical cancer informatics*, 1, 1-11.

- Slatore, C. G., Wiener, R. S., Golden, S. E., Au, D. H., & Ganzini, L., 2016, Longitudinal assessment of distress among veterans with incidental pulmonary nodules, *Annals of the American Thoracic Society*, 13(11), 1983-1991.
- 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.
- Soni, M., Khan, I. R., Babu, K. S., Nasrullah, S., Madduri, A., & Rahin, S. A., 2022, Light weighted healthcare CNN model to detect prostate cancer on multiparametric MRI, *Computational Intelligence and Neuroscience*, 2022.
- Streiner, D. L., & Cairney, J., 2007, What's under the ROC? An introduction to receiver operating characteristics curves, *The Canadian Journal of Psychiatry*, 52(2), 121-128.
- Sun, W., Zheng, B., & Qian, W., 2016, Computer aided lung cancer diagnosis with deep learning algorithms, *In Medical imaging 2016: computer-aided diagnosis*, 9785, 241-248.
- Sun, Y., Xue, B., Zhang, M., Yen, G. G., & Lv, J., 2020, Automatically designing CNN architectures using the genetic algorithm for image classification, *IEEE transactions on cybernetics*, 50(9), 3840-3854.
- Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F., 2021, Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries, *CA: a cancer journal for clinicians*, 71(3), 209-249.
- Şener, A., & Ergen, B., 2022, Yüz görüntülerine ayrık kosinüs dönüşümü uygulanarak görüntü sınıflandırma sonuçlarının iyileştirilmesi, *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 27(3), 1193-1206.
- Tabakov, S., & Bregant, P., 2022, Introduction to Diagnostic Radiology (X-Ray and Computed Tomography Imaging), *In Introduction to Medical Physics*, 95-142.
- Talerman, A., 1994, Nonspecific tumors of the ovary, including mesenchymal tumors and malignant lymphoma, *Blaustein's pathology of the female genital tract*, 915-937.
- Temizsoy, M., 2021, Kanser hastalarında kırılğanlığın umutsuzluğa ve yaşam doyumuna etkisi, *Master's thesis, İstanbul Medipol Üniversitesi Sağlık Bilimleri Enstitüsü*.
- Thakur, R., 2019, Step by step VGG16 implementation in Keras for beginners, *Towards Data Science*, 6.
- Thakur, S. K., Singh, D. P., & Choudhary, J., 2020, Lung cancer identification: a review on detection and classification. *Cancer and Metastasis Reviews*, 39, 989-998.
- Tumrad, 2023,

http://www.tumrad.net/FileUpload/ds58732/File/bilgisayarli_tomograf1__bt_.pdf

[Ziyaret Tarihi: 25 Ocak 2023].

- Türkçetin, A. Ö., Bayrakçı, H. C., Danışman, I. I., & Aksoy, Ö. Ü. B., 2019, Akciğer kanserinin tespit edilmesinde derin öğrenme algoritmalarının kullanılması.
- Van den Abbeele, A. D., & Badawi, R. D., 2002, Use of positron emission tomography in oncology and its potential role to assess response to imatinib mesylate therapy in gastrointestinal stromal tumors (GISTs), *European journal of cancer*, 38, S60-S65.
- Wahl, R. L., Quint, L. E., Greenough, R. L., Meyer, C. R., White, R. I., & Orringer, M. B., 1994, Staging of mediastinal non-small cell lung cancer with FDG PET, CT, and fusion images: preliminary prospective evaluation, *Radiology*, 191(2), 371-377.
- Wang, T., Lei, Y., Tian, S., Liu, T., Curran, W. J., Higgins, K., & Yang, X., 2021, Lung tumor segmentation of PET/CT using dual pyramid mask R-CNN, *In Medical Imaging 2021: Image Processing*, 11596, 841-846.
- Wu, J., 2017, Introduction to convolutional neural networks, *National Key Lab for Novel Software Technology, Nanjing University, China*, 5(23), 495.
- Wu, Z., Wang, L., Li, C., Cai, Y., Liang, Y., Mo, X., & Liu, Y., 2020, DeepLRHE: a deep convolutional neural network framework to evaluate the risk of lung cancer recurrence and metastasis from histopathology images, *Frontiers in Genetics*, 11, 768.
- Zhao, X., Wu, Y., Song, G., Li, Z., Zhang, Y., & Fan, Y., 2018, A deep learning model integrating FCNNs and CRFs for brain tumor segmentation, *Medical image analysis*, 43, 98-111.

7. ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Ferhat AYAYNA
Uyruğu :

EĞİTİM

Lise : **Batman Anadolu Lisesi** **2011**
Üniversite : **Çukurova Üniversitesi / ADANA** **2017**
Yüksek Lisans : **Batman Üniversitesi** **2023**
Doktora :

İŞ DENEYİMLERİ

Yıl :(2019-2020) Kurum: **Batman Medical Park Hastanesi** Görevi: **Biyomedikal mühendisi**
Yıl :(2021-2022) Kurum: **AYAYNA MEDİKAL** Görevi: **Sorumlu müdür.**

UZMANLIK ALANI: Medikal Görüntüleme, Görüntü İşleme, Tıbbi Cihazlar.

YABANCI DİLLER: İngilizce

YAYINLAR

Uluslararası kongre ve sempozyumlarda sunulan bildiriler

Ayayna, Ferhat; Çalışkan, Abidin (2022). Processing of Medical Diagnostic Medical Images. *International Informatics Congress (IIC2022)*, 307-317.

Ayayna, Ferhat; Çalışkan, Abidin; Aslan, Ammar (2022). Akciğer Kanserinin Derin Öğrenme Yaklaşımları Kullanılarak Tespit Edilmesi. *International Conference on Scientific and Academic Research (ICSAR '22)*, 1076-1082.