

T.C.

MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA ANA BİLİM DALI

AKCİĞER BİLGİSAYARLI TOMOGRAFİSİNDE
İNSİDENTAL SAPTANAN MEME NODÜLLERİNİN
EVRIŞİMLİ SİNİR AĞLARI İLE BENİGN-MALİGN
OLARAK SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

ZİŞAN ERTUNÇ

EYLÜL 2023

MUĞLA

Z. ERTUNÇ

YAPAY ZEKA ANA BİLİM DALI

YÜKSEK LİSANS TEZİ

MUĞLA 2023

T.C.
MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA ANA BİLİM DALI

AKCİĞER BİLGİSAYARLI TOMOGRAFİSİNDE
İNSİDENTAL SAPTANAN MEME NODÜLLERİNİN
EVRIŞİMLİ SINIR AĞLARI İLE BENİGN-MALİGN
OLARAK SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

ZİŞAN ERTUNÇ

EYLÜL 2023

MUĞLA

MUGLA SITKI KOÇMAN ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

TEZ ONAYI

Zişan ERTUNÇ tarafından hazırlanan “**AKCİĞER BİLGİSAYARLI TOMOGRAFİSİNDE İNSİDENTAL SAPTANAN MEME NODÜLLERİNİN EVRİŞİMLİ SİNİR AĞLARI İLE BENİGN-MALİGN OLARAK SINIFLANDIRILMASI**” başlıklı tezinin, 01/09/2023 tarihinde aşağıdaki jüri tarafından Yapay Zekâ Ana Bilim Dalı’nda yüksek lisans derecesi için gerekli şartları sağladığı oybirliği/oyçokluğu ile kabul edilmiştir.

TEZ SINAV JÜRİSİ

Dr. Öğr. Üyesi Diyadin CAN (**Jüri Başkanı**) İmza: _____

Biyomedikal Mühendisliği Ana Bilim Dalı
İstanbul Yeni Yüzyıl Üniversitesi, İstanbul

Doç. Dr. İbrahim Önder YENİÇERİ (**Danışman**) İmza: _____

Radyoloji Ana Bilim Dalı
Muğla Sıtkı Koçman Üniversitesi, Muğla

Dr. Öğr. Üyesi Nida GÖKÇE NARİN (**Üye**) İmza: _____

İstatistik Bilgi Sistemleri Ana Bilim Dalı
Muğla Sıtkı Koçman Üniversitesi, Muğla

ANA BİLİM DALI BAŞKANLIĞI ONAYI

Dr. Öğr. Üyesi Nida GÖKÇE NARİN İmza: _____

Yapay Zeka Ana Bilim Dalı Başkanı
Muğla Sıtkı Koçman Üniversitesi, Muğla

Doç. Dr. İbrahim Önder YENİÇERİ (**Danışman**) İmza: _____

Radyoloji Ana Bilim Dalı
Muğla Sıtkı Koçman Üniversitesi, Muğla

Savunma Tarihi: 01/09/2023

Tez çalışmalarım sırasında elde ettiğim ve sunduğum tüm sonuç, doküman, bilgi ve belgelerin tarafımdan bizzat ve bu tez çalışması kapsamında elde edildiğini; akademik ve bilimsel etik kurallarına uygun olduğunu beyan ederim. Ayrıca, akademik ve bilimsel etik kuralları gereği bu tez çalışması sırasında elde edilmemiş başkalarına ait tüm orijinal bilgi ve sonuçlara atıf yapıldığını da beyan ederim.

Zişan ERTUNÇ

01/09/2023



ÖZET

AKCİĞER BİLGİSAYARLI TOMOGRAFİSİNDE İNSİDENTAL SAPTANAN MEME NODÜLLERİNİN EVRİŞİMLİ SINIR AĞLARI İLE BENİGN-MALİGN OLARAK SINIFLANDIRILMASI

Zişan ERTUNÇ

Yüksek Lisans Tezi

Fen Bilimleri Enstitüsü

Yapay Zekâ Ana Bilim Dalı

Danışman: Doç. Dr. İbrahim Önder YENİÇERİ

Ağustos 2023, 57 sayfa

Meme lezyonlarının saptanmasında en sık kullanılan yöntemler mamografi, ultrasonografi ve manyetik rezonans görüntülemedir. Bilgisayarlı tomografi (BT) içerdiği yüksek radyasyon dozları nedeni ile meme lezyonlarının saptanmasında ve karakterizasyonunda kullanılmamaktadır. Son yıllarda özellikle Covid-19 salgını sonrasında akciğer BT kullanımı belirgin düzeyde artmıştır ve değişik nedenlerle yapılan akciğer BT incelemelerinde %7 ye ulaşan oranlarda meme lezyonu saptandığı bildirilmiştir. Bu çalışmanın temel amacı; akciğer BT'lerinde insidental meme nodülü saptanan olgularda derin öğrenme yöntemleri kullanılarak eğitilecek evrişimli sınır ağlarının (ESA), lezyonları benign-malign ayrımındaki performansının test edilmesidir. Ayrıca alt amaç olarak görüntü işleme alanında yaygın olarak kullanılan EfficientNet ve ResNet mimarilerinin görüntü sınıflamasındaki doğruluk oranlarının kıyaslanması da hedeflenmiştir. Çalışmada Muğla Eğitim ve Araştırma Hastanesi Radyoloji Bölümünden alınan akciğer BT görüntüleri kullanılmıştır (1376 benign, 733 malign, toplam 2109). Test veri seti olarak eğitim ve doğrulamada kullanılan 2109 görüntü haricinde ayrıca seçilen karma 131 görüntü kullanılmıştır. Yapılan çalışmada BT görüntülerinde tespit edilen meme lezyonlarının benign-malign ayrımındaki performansının doğruluk oranı ortalama %91,5 olarak tespit edilmiştir. Ayrıca yapılan kıyaslamada kullanılan veri seti için EfficientNetB0 doğruluk oranının (%96) ResNet50'den (%87) yüksek olduğu belirlenmiştir. Bu çalışma BT görüntülerinde saptanan meme nodüllerinin benign-malign ayrımında ESA'ların başarılı olabileceğini göstermiştir.

Anahtar Kelimeler: Meme kanseri, derin öğrenme, akciğer tomografisi.

ABSTRACT

CLASSIFICATION OF BREAST NODULES DETECTED INCIDENTAL IN LUNG COMPUTERIZED TOMOGRAPHY AND AS BENIGN-MALIGNANT WITH CONVERSION NEURAL NETWORKS

Ziřan ERTUNÇ

Master of Science (M.Sc.)

Graduate School of Natural and Applied Sciences

Department of Artificial Intelligence

Supervisor: Associate Professor İbrahim Önder YENİÇERİ

August 2023, 57 pages

The most commonly used methods for detecting breast lesions are mammography, ultrasonography and magnetic resonance imaging. Computed tomography (CT) is not used in the detection and characterization of breast lesions due to the high radiation doses. In recent years, especially after the Covid-19 epidemic, the use of lung CT has increased significantly, and it has been reported that breast lesion up to 7% has been detected in lung CT examinations performed for various reasons. The main purpose of this study; is to test the performance of convolutional neural networks (CNN) in distinguishing benign-malignant lesions which will be trained using deep learning methods, in cases with incidental breast nodules detected in lung CT scans,. In addition, as a sub-purpose, it is aimed to compare the accuracy rates of the EfficientNet and ResNet architectures, which are widely used in the field of image processing, in image classification. In the study, lung CT images taken from the Radiology Department of Muęla Training and Research Hospital were used (1376 benign, 733 malignant, total 2109). Apart from 2109 images used in training and validation, 131 selected mixed images were used as test dataset. In the study, the accuracy rate of the performance of the breast lesions detected on CT images in the distinction between benign and malignant was found to be 91.5% on average. In addition, it was determined that the accuracy rate of EfficientNetB0 (96%) was higher than ResNet50 (87%) for the data set used in the comparison. This study showed that CNNs can be successful in the differentiation of benign and malignant breast nodules detected on CT images.

Keywords: Breast cancer, deep learning, lung tomography.



Türk Bilimine

ÖNSÖZ

Biyomedikal Mühendisliği lisans eğitimim boyunca kendisinden birçok şey öğrendiğim, beni lisansüstü eğitime yönlendiren akademik danışmanım Dr. Öğr. Üyesi Diyadin CAN'a teşekkürlerimi sunarım.

Çok güncel bir konu olan “Akciğer Bilgisayarlı Tomografisinde İnsidental Saptanan Meme Nodüllerinin Evrişimli Sınır Ağları İle Benign-Malign Olarak Sınıflandırılması” başlıklı çalışmayı öneren yüksek lisans danışmanım Doç. Dr. İbrahim Önder YENİÇERİ'ye yüksek lisans eğitimimin başından sonuna kadar göstermiş olduğu bilimsel yol ve yöntemler ile sonsuz desteği için teşekkürü bir borç bilirim.

İlkokuldan başlayarak lisansüstü eğitime kadar tüm eğitim hayatımda beni anlamaya, öğrenmeye, çalışmaya sevk eden, sürekli cesaretlendiren ilk öğretmenim sevgili anne annem İsmet KERKEZ'e, her zaman pozitif motivasyonu ile yanımda olan ablam Rabia Nilgün KERKEZ'e, annem Prof. Dr. Fatma İlker KERKEZ'e ve emeği geçen herkese minnettar olduğumu belirtmek isterim.

İÇİNDEKİLER

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
SEMBOLLER VE KISALTMALAR DİZİNİ	xi
1. GİRİŞ	1
1.1. Kadın Meme Anatomisi, Meme Hastalıkları ve Görüntüleme Yöntemleri.3	
1.1.1. Kadın meme anatomisi	3
1.1.2. Meme lezyonları	4
1.1.3. Meme kanseri (MK)	4
1.1.4. Memede görüntüleme yöntemleri.....	5
1.2. Derin Öğrenme, Yapay Sinir Ağları ve Evrişimli Sinir Ağları (ESA).....7	
1.2.1. Yapay sinir ağları (Neural Network)	8
1.2.2. Evrişimli sinir ağları (Convolutional Neural Networks/CNN).....11	
1.3. Transfer Öğrenme.....	15
1.4. Artık Ağ Mimarisi (Residual Network Architecture - ResNet).....16	
1.5. Ölçeklendirme Mimarisi (EfficientNet)	17
1.6. Literatür Taraması	17
2. MALZEME VE YÖNTEM	21
2.1. Kullanılan Veriler ve Yöntemler	21
2.1.1. Donanım	21
2.1.2. Veri seti.....	21
2.1.3. Görsellerin içeri aktarılması.....	22
2.1.4. Veri seti ön işleme.....	23
2.1.5. Yapay sinir ağlarının eğitilmesi.....	24
2.1.6. Derin öğrenme yöntemi ve yazılım detayları.....	24
3. BULGULAR VE İRDELEME.....	27
4. TARTIŞMA VE SONUÇ	30
KAYNAKLAR	36
ÖZGEÇMİŞ.....	44
EK-1: Etik Kurul Onayı.....	45

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 4.1. Görüntü analizi kullanan çalışmalar ve doğruluk oranları	33
---	----



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. DSÖ Kanser Verileri (2021).....	1
Şekil 1.2. Kadın meme anatomisi (National Cancer Institute, 2023).....	4
Şekil 1.3. X Işını tüpü temel gösterim (Arslan, 2017).....	7
Şekil 1.4. Yapay sinir hücresi (Yacim & Boshoff, 2018).....	10
Şekil 1.5. Yapay sinir ağı katmanları (Jain vd. 1996).....	12
Şekil 1.6. Özellik haritası (Dettmers, 2015).....	13
Şekil 1.7. Filtre kullanılarak uygulanan evrişim (Patterson & Gibson, 2017).....	15
Şekil 1.8. Düzleştirme katmanı (Superdatascience Team, 2018).....	16
Şekil 1.9. ESA mimarisi (Ergin, 2018).....	16
Şekil 1.10. Transfer öğrenme (Abir vd. 2022).....	17
Şekil 1.11. Artık ağ mimarisi (Üstündağ, 2022).....	18
Şekil 2.1. Gerekli kütüphanelerin içeri aktarılması.....	23
Şekil 2.2. Klasör yolunun tanıtılması.....	23
Şekil 2.3. Veri seti jeneratörlerinin tanımlanması.....	21
Şekil 2.4. Görüntülerin yeniden boyutlandırılması.....	25
Şekil 2.5. Hiperparametrelerin belirlenmesi.....	26
Şekil 2.6. ESA mimarilerinin tanıtılması.....	26
Şekil 2.7. Plotların oluşturulması ve kodun sonlandırılması.....	27
Şekil 3.1. İlk denemede 10 epoch için alınan görüntü (EfficientNet).....	28
Şekil 3.2. İkinci deneme 12 epoch için alınan görüntü (EfficientNet).....	29
Şekil 3.3. Üçüncü deneme 3 epoch için EfficientNetB0 ve ResNet50 çıktıları.....	29

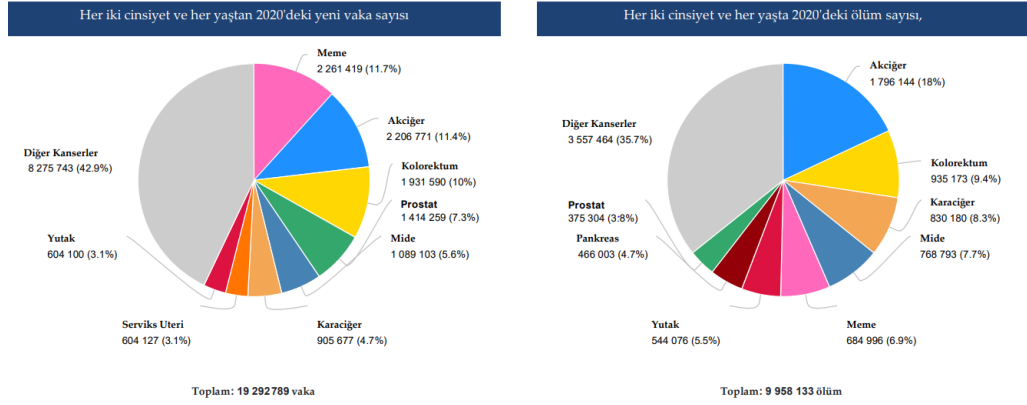
SEMBOLLER VE KISALTMALAR DİZİNİ

MK	Meme kanseri
ESA	Evrışimli sinir ağıları
ResNet	Artık Ağ Mimarisi
EfficientNet	Ölçeklendirme Mimarisi
Rescale	Yeniden boyutlandırma
Pycharm	Python Programlama dilinin kullanıldığı ara yüz programı



1.GİRİŞ

Meme kanseri (MK) kadınlarda en sık görülen malignitedir (Uluslararası Kanser Araştırma Ajansı-IARC, 2020; Türkiye Kanser İstatistikleri, 2017). Dünya Sağlık Örgütü'ne göre (DSÖ, 2021), 2020'de dünya çapında MK teşhisi konan 2,3 milyon kadın ve MK'ne bağlı 685.000 ölüm vardır. 2020 sonu itibariyle, son 5 yılda MK teşhisi konan hayatta olan 7,8 milyon kadın bulunmaktadır. MK, dünyanın her ülkesinde kadınlarda ergenlik çağından sonra herhangi bir yaşta görülür, ancak yaş ilerledikçe sıklığı artar. Tahminen her yıl 2,3 milyon yeni MK (%11,7) bildirilmektedir, bunu akciğer (%11,4), kolorektal (%10,0), prostat (%7,3) ve mide (%5,6) kanserleri izlemiştir (DSÖ, 2021).



Şekil 1.1. DSÖ Kanser Verileri (2021).

Kanserin artan insidansına rağmen, ölüm oranları aynı seviyede tutulmuştur. Bu teşhis ve tedavi yöntemlerinin sürekli geliştirilmesinden kaynaklanmaktadır çünkü uygun, etkili tedavi doğru teşhise bağlıdır (Gennari vd. 2021). Aynı zamanda giderek daha fazla hastanın meme ve koltuk altı lenf nodları koruyucu ameliyatlara geçmesi, MK'nin ilk ilerleme aşamasının belirlenmesi, uygun tedaviyi sağlamak için kesinlikle gereklidir (Madej-Czerwonka vd. 2022).

MK'ni hızlı ve doğru bir şekilde taramak için görüntüleme ve moleküler biyoteknolojiye dayalı birçok teşhis yöntemi geliştirilmiştir (He vd. 2020). Bu yöntemleri özetlemek ve değerlendirmek, klinik tanı için değer bilgisi sağlamak için vazgeçilmezdir. Jafari vd. (2018) MK hastalarını saptamak ve izlemek için kullanılan çeşitli görüntüleme tekniklerini ve biyokimyasal biyo-belirteçleri özetlediği çalışmada belirli biyo-belirteçlerin düzeyini ölçerek MK'li hastaları teşhis ve tedavi etmenin yararlı olduğunu vurgulamıştır. Weaver ve Leung (2018) görüntüleme "biyo-belirteçlerinin" tanımlarını ve uygulamalarını tanımlamış ve MK ile ilgili araştırmalara yardım sağlamak için bu belirteçlerle karar destek sistemi oluşturabileceğini savunmuştur. Pek çok makale, MK hastalarının teşhisinde görüntüleme tekniklerinin (moleküler görüntüleme belirteçleri dahil) katkısını sunarak ve bu bulguları yeni keşfedilen tümör yapıcılar ile MK hastaları arasındaki bağlantıya göre özetleyerek, esas olarak bu açılardan MK teşhisi için yeni yöntemleri gözden geçirmektedir (Marchiò ve Reis-Filho, 2008; Pareja vd. 2018). Son üç yılda, Avrupa Onkoloji Okulu (ESO) ve Avrupa Tıbbi Onkoloji Derneği (ESMO), meme kanserinin hem erken hem de ileri evrelerindeki hastalarda uygulanabilecek özel teşhis ve tedavi algoritmaları geliştirmiştir. BRCA gen mutasyonuna sahip hastalar için kesin prosedürler de tanımlanmıştır. Her prosedür için spesifik endikasyonlar belirlenmiş ve bunların klinik önemi derecelendirilmiştir (Sayegh vd. 2017; Gennari vd. 2021).

Ülkemize kanser kayıt faaliyetleri "14.09.1982 tarih ve 5621 sayılı Bakanlık genelgesi gereğince Kanser vakaları 1593 sayılı Umumi Hıfzısıhha Kanununun 57. maddesinde belirtilen ihbarı mecburi hastalıklar arasına alınması" ile resmen başlamıştır ancak kurulan aktif merkezlerden gelen verilerden oluşturulan rapor ilk olarak 2002'de yayınlanabilmiştir (Arayıcı vd. 2021; Tuncer, 2009). "03.06.2015 tarih ve 29375 sayılı Kanser Bildirimi ve Kanser Kayıt Merkezleri Yönetmeliği" ile kanser, bildirim zorunlu hastalıklar arasına alınmış ve tüm kurallar Resmî Gazetede (2015) Yayınlanmıştır. Kanser kayıt sistemi gerekli olsa da kanserle savaşmanın en önemli aşaması erken teşhistir. Erken teşhis edilen vakalarda ölüm oranları çok daha düşük olmaktadır. Bu aşamada çeşitli görüntü işleme ve bilgisayar destekli tanı (BDT) sistemleri radyologların iş yükünü azaltmakta, analiz edilmesi zor alanlarda

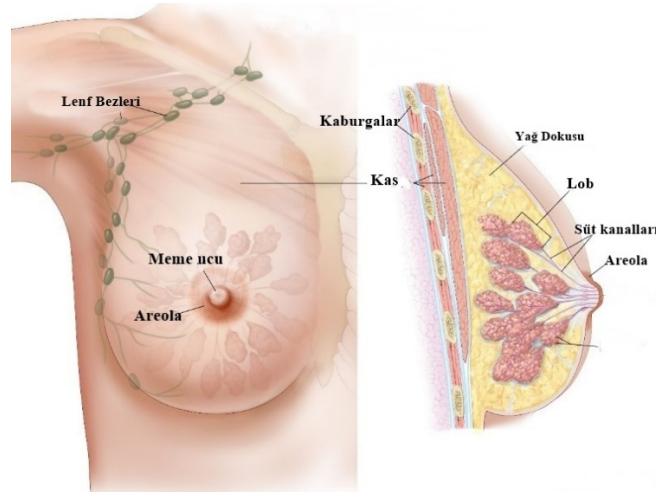
radyologlara destek sağlamaktadır. Bu süreçte tanı programa değil radyoloğa aittir, nihai tanı ve teşhis radyolog tarafından yapılır.

Bu tez çalışmasında temel hedef Covid-19 salgını ile birlikte artan radyolojik incelemelerde elde edilen görüntülerin işlenerek erken tanı aşamasına katkı sağlamasıdır. Bu amaçla akciğer BT'lerinde tesadüfen saptanan meme nodüllerinin derin öğrenme yöntemleri kullanılarak eğitilecek ağ ile malign lezyonları saptamada başarılı olup olmayacağını belirlenmesidir.

1.1. Kadın Meme Anatomisi, Meme Hastalıkları ve Görüntüleme Yöntemleri

1.1.1. Kadın meme anatomisi

Meme kadınlarda ikincil cinsel özelliği oluşturur. Değişik boyutlardaki yetişkin kadın memesi, anatomik pozisyonda toraks ön duvarında, üst ve altta iki-altıncı kostalar ile medialde sternum ve lateralde ön aksiller çizgi arasında olup üst tarafta m. pectoralis majör ve m. Serratus anteriore yapışır (10-12 cm çap). Meme bezleri kadınlarda sadece doğum sonrası dönemde aktif hale gelir ve süt bezlerinden süt salgılanır. Meme dokusu meme bezleri yanında yağ ve bağ dokusundan oluşur. Memenin apeksindeki meme başını çevreleyen pigmentli alana “areola” denmektedir. Kadınlarda meme dokusunda inflamatuvar, benign ya da malign karakterde hastalık gelişebilir (Solmaz, 2022).



Şekil 1.2. Kadın meme anatomisi (National Cancer Institute, 2023).

1.1.2. Meme lezyonları

Memede oluşan lezyonlar genelde oluşum bölgesine göre ya da kanser olup olmadığına göre benign (iyi huylu) ya da malign (kötü huylu) şeklinde sınıflandırılmaktadır (Görgel, 2011). Oluşum bölgesine göre meme derisinde gelişen lezyonlar (örneğin; epidermal ve sebace kistler), meme başında (areola) görülen lezyonlar (örneğin; meme başı adenomu), meme lobüllerinde gelişen lezyonlar (örneğin; kompleks fibroadenomlar, tubüler adenom) gibi. Benign türdeki lezyonlar iyi huylu olarak tanımlanırlar (kist, fibroadenom, lipom, adenom, galaktosel vb.). Malign grubunda yer alan lezyonlar kötü huylu olarak tanımlanmaktadır (karsinoma in situ, invaziv karsinoma) (Buldanlı, 2017).

1.1.3. Meme kanseri (MK)

Kanser, bazı hücrelerin kontrolsüz bir şekilde çoğalarak vücudun diğer bölgelerine yayıldığı bir hastalıktır. Kanser, trilyonlarca hücreden oluşan insan vücudunun hemen her yerinde başlayabilir. MK ise meme dokusu içinde süt kanallarında yer alan hücrelerin kontrolsüz şekilde çoğalmasına bağlı olarak gelişen lezyondur. Meme içindeki kötü huylu hücreler lenf bezlerinden ve kan damarlarından yayılarak diğer dokulara yerleşir. MK'de kanser hücreleri zaman içinde çoğalarak kitle oluşturur. Genelde meme dokusunun fazla olduğu üst dış bölümde oluşur. MK genel olarak uzun sürede gelişir. Çoğu vakada malign hücrenin oluşumundan 1 cm çapına ulaşmasının 7-8 yıl sürdüğü bildirilmiştir (Buldanlı, 2017).

MK'de tanı fizik muayene ile başlar (inspeksiyon ve palpasyon yanında anamnez ve özgeçmiş sorgulaması). MK taramasında 40 yaş üstü kadınlarda mamografi uygulanmaktadır. Memede muayene veya görüntüleme yöntemleri ile şüpheli bir lezyon saptanması halinde tanı için biyopsiye başvurulur. Ultrasonografinin yetersiz kalması durumunda lezyonun tam yerini belirlemede manyetik rezonans görüntüleme (MR) yöntemi kullanılabilir (Buldanlı, 2017). MK'de erken tanı, tedavi

seçeneklerinin artması, tedaviden etkili sonuç alınması ve hastanın hayatta kalım süresini önemli oranda artırır.

1.1.4. Memede görüntüleme yöntemleri

- **Ultrasonografi (USG)**


USG, dokulara yüksek frekansta ses dalgaları gönderip, farklı doku yüzeylerinden ses dalgalarının yansımaları ile elde edilen görüntüleme şeklidir. Bu ses frekanslarının oluşturulması ve yansıyan ses dalgalarının tekrar toplanıp elektronik veriye dönüştürülmesi transducerlar aracılığı ile olmaktadır. Meme ultrasonografisi genellikle mamografide şüpheli olan durumlarda ileri değerlendirilme, yüzeye yakın dokulardaki sıvı yoğunluğunu belirlemek, girişimsel işlemlere kılavuzluk için tercih edilmektedir.

USG'nin en temel avantajları; radyasyon kullanılmaması, hastanın ağrı veya rahatsızlık hissetmemesi, uygulamasının pratik olması, girişimsel işlemler için ön bilgi sağlamasıdır. Dezavantajları ise; uygulayıcının uzmanlığından etkilenmesi, küçük lezyonların (<5 mm) görülmesinde sınırlılıktır. Buna karşın yüksek teknolojili USG cihazlarının memedeki kitlenin BI-RADS skorunu belirlemede bilgi vereceğini gösteren çalışmalar yapılmıştır (Özel vd. 2015).

- **X Işınları**

X ışınları ilk kez Wilhelm Conrad Röntgen tarafından 1895 yılında ortaya çıkarılmıştır. Görünür ışığa benzer bir elektromanyetik radyasyon şeklidir. Bununla birlikte, ışıktan farklı olarak, x-ışınları daha yüksek enerjiye sahiptir ve vücut da dahil olmak üzere çoğu nesneden geçebilir. Tıbbi amaçla x-ışınları (radyografi), vücuttaki doku ve yapıların görüntülerini oluşturmak için kullanılır. Bir radyografi oluşturmak için, bir hasta, görüntüleneni vücut kısmı bir x-ışını kaynağı ile bir x-ışını detektörü arasında olacak şekilde konumlandırılır. İnceleme sırasında oluşan x-ışınları dokuların yoğunluklarına ve kalınlıklarına bağlı olarak farklı dokular tarafından farklı miktarlarda emilirler. Radyolojik yoğunluk, görüntüleneni malzemenin hem yoğunluğu

hem de atom numarası (bir atomun çekirdeğindeki proton sayısı) tarafından belirlenir. Örneğin kemikler, diğer dokuların çoğundan daha yüksek bir atom numarasına sahip olan kalsiyum içerir. Bu özelliğinden dolayı, kemikler x-ışınlarını kolayca emer ve x-ışını detektöründe yüksek kontrast üretir. Sonuç olarak, kemikli yapılar, bir radyografinin siyah arka planına karşı diğer dokulardan daha beyaz görünür. Tersine, x-ışınları yağ, kas gibi radyolojik olarak daha az yoğun dokulardan ve akciğerler gibi hava dolu boşluklardan daha kolay geçer. Bu yapılar bir radyografide gri tonlarında görüntülenir.



Şekil 1.3. X Işını tüpü temel gösterim (Arslan, 2017)

X Işınlarının keşfi ile radyolojinin temelleri atılmış olup, günümüze kadar gelen süreçte farklı yöntemlerle kullanılıp, tıp alanında görüntüleme sistemlerinde tercih edilen başlıca yöntemlerden biri olmuştur.

- **Mamografi**

Mamografi , kanser ve diğer meme hastalıklarının erken teşhisi için memeyi incelemek amacıyla kullanılan bir radyografi yöntemidir.

Mamografinin herhangi bir şikâyeti olmasa da erken tanı olasılığını artırması nedeniyle özellikle 40 yaş üstü kadınlarda taramalarda kullanılması tavsiye edilir. Kitle, meme akıntısı gibi şikayetlerde veya daha önce kanser atlatanlarda tanı amaçlı mamografi uygulanır.

- **Manyetik Rezonans Görüntüleme (MRI)**

İnsan vücudunu oluşturan yağ ve suyun moleküler yapısında ağırlıklı olarak hidrojen atomları yer alır. Manyetik Rezonans Görüntüleme (MRI), üç boyutlu ayrıntılı anatomik görüntüler üreten bir görüntüleme teknolojisidir. Genellikle hastalık tespiti, teşhis ve tedavi takibi için kullanılır. Canlı dokuları oluşturan suda bulunan protonların dönme eksenini yönündeki değişimi uyaran ve saptayan gelişmiş teknolojiye dayanmaktadır. MRI'ler, vücuttaki protonları bu alanla hizalanmaya zorlayan güçlü bir manyetik alan üreten güçlü mıknatıslar kullanır. Daha sonra hastaya bir radyo frekansı akımı gönderildiğinde, protonlar uyarılır ve manyetik alanın çekimine karşı gerinerek dengeden çıkarlar. Radyofrekans alanı kapatıldığında, MRI sensörleri, protonlar manyetik alanla yeniden hizalanırken salınan enerjiyi algılayabilir. Protonların manyetik alanla yeniden hizalanma süresi ve salınan enerji miktarı, çevreye ve moleküllerin kimyasal yapısına bağlı olarak değişir. Uzmanlar bu manyetik özelliklere dayanarak çeşitli doku türleri arasındaki farkı söyleyebilirler (NIBIB, 2023; Oyar, 2008). Yumuşak dokularda daha iyi çalışmasından dolayı meme kanseri tanısında tercih edilen yöntemler arasında yer almaktadır.

1.2. Derin Öğrenme, Yapay Sinir Ağları ve Evrişimli Sinir Ağları (ESA)

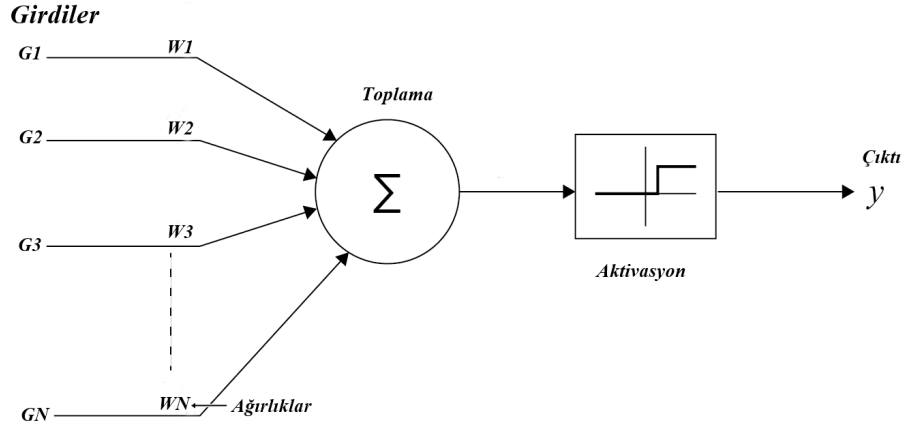
Yapay zekâ alanında insan sinir sisteminden esinlenerek düşünen ve karar verebilen zeki sistemlerin tasarlanmasını hedeflenmektedir. Bu amaçla 1940'lı yıllardan bu yana bilim adamları modellemeler geliştirmektedir. Denetimli makine öğreniminde (ML), algoritmalar, bilinmeyen bir girdiden doğru bir çıktıyı tahmin etmek için etiketli eğitim verilerinden özellikleri öğrenmeye çalışır. Derin öğrenme modelleri, bu modellerin girdi verilerinden art arda daha zengin özellikler çıkarmasını sağlayan, yığılmış katmanlardan oluşan özel makine öğrenimi modelleridir. Daha fazla katman oluşturuldukça, model derinleşir ve daha karmaşık özellikler öğrenilebilir, dolayısıyla buna derin öğrenme adı verilir. Makine öğreniminin kendisi geniş yapay zekâ (YZ) alanının bir parçasıdır (Hoeser ve Kuenser, 2020).

Derin öğrenme, insan beyni örnek alınarak modellenen algoritmaların çok miktarda veriden sonuç çıkardığı makine öğrenimini ifade eder. Bir modelleme yaklaşımı olarak makine öğrenimi, son yıllarda sağlık hizmetlerinde farklı hastalıkları tahmin etmek için, yaygın olarak kullanılan verilerden bilgi çıkarmak veya veriler içindeki gizli ilişkileri keşfetmek için kullanılmaktadır.

1.2.1. Yapay sinir ağları (Neural Network)

Yapay sinir ağları (Neural Network) kavramı, insan beyninin öğrenme, düşünme ve karar verme yapısını bilgisayar ortamına taşımayı hedefleyen sistemleri temsil eder. Diğer bir deyişle; öğrenme, hatırlama, bağlantı kurma, organizasyon yolu ile halihazırda duruma göre yeni veri üretebilen bilgisayar yazılımlarıdır (Öztürk ve Şahin, 2018; İnik ve Ülker, 2017). Bu amaçla insan beyninin işleyişini mantıksal olarak hesaplayarak yapay sinir ağlarının temelini oluşturan ilk model McCulloch-Pitts (1943) tarafından ortaya konulmuştur. McCulloch-Pitts nöronu olarak da bilinen yapay sinir hücresinin 5 bölümü aşağıdaki şekildedir;

- **Girdiler:** Girdiler sinir hücrelerine (nöronlara) duyu organlarından iletilen verileri temsil eder. Bu veriler nöron çekirdeğinde toplanır.
- **Ağırlıklar:** Girdinin çıktı üzerindeki etkisinin ayarlanabilmesi için çekirdeğe ulaşmadan önce geldikleri bağlantıların ağırlığıyla çarpılmasıdır.
- **Toplama (Birleştirme):** Ağırlıkların toplanmasıyla hücrenin net girdisinin hesaplanması fonksiyonudur.
- **Aktivasyon:** Tüm girdilerin ağırlıklı toplamının alınması ve doğrusal olmayan bir çıkış değeri üreterek bir sonraki katmana geçirme fonksiyonudur (örn; ReLU, sigmoid). Bu fonksiyon, veri yapılarından anlamlı bir sonuç oluşturulan bölümdür.
- **Çıktı:** Aktivasyon fonksiyonundan çıkan değerdir. Her hücrede çok sayıda girdi olmasına karşın tek bir çıktı vardır. Bu çıktı istenilen sayıda hücreye bağlanabilir.



Şekil 1.4.Yapay sinir hücresi (Yacim & Boshoff, 2018).

Aktivasyon Fonksiyonu Çeşitleri

Nöral ağlarda veriye ve problemlere göre kullanılan aktivasyon fonksiyonları değişir. Doğada veriler doğrusal olamayacağı için sistemin doğrusal olmayan problemleri öğrenerek uygun çıktı üretebilmesi önem taşır.

- **Sigmoid Aktivasyon Fonksiyonu**

En sık kullanılan aktivasyon fonksiyonlarından biri olan sigmoid fonksiyonu 0 ile 1 arasında çıktı üretir. Girdi değerlerindeki küçük değişiklikler çıktı değerlerinde gözlemlenebildiğinden öğrenme işlemi gerçekleştirilebilir.

$$Sigmoid(x) = \frac{1}{1+e^{-x}} \quad (1.1)$$

- **ReLU (Doğrultulmuş Doğrusal Birimler) Aktivasyon Fonksiyonu**

Doğrultulmuş Doğrusal Birimler (ReLU) fonksiyonunda çıktı değerleri $[0, +\infty]$ arasında yer almaktadır. Bu fonksiyonda ağırlık hızlı eğitilmesi 0'dan büyük olan

girdilerin sabit türev değerine sahip olmasından kaynaklanır. ReLU aşağıdaki gibi tanımlanır;

$$F(x) = \text{MAX}(X, 0) \quad (1.2)$$

- **Softmax Aktivasyon Fonksiyonu**

Softmax fonksiyonunda girdi ne olursa olsun (pozitif, negatif, sıfır vs.) 0 ile 1 arasında çıktılarını 0 ile 1 arasında dönüştürür yani elde edilen çıktılarının 1'e kadar olan toplamları normalize edilir. Bu fonksiyon sisteme girilen her girdiyi bir sınıfa dahil eden çıktılar üretir.

$$\sigma(\vec{Z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (1.3)$$

\vec{Z} = Softmax fonksiyonunun girdi vektörü

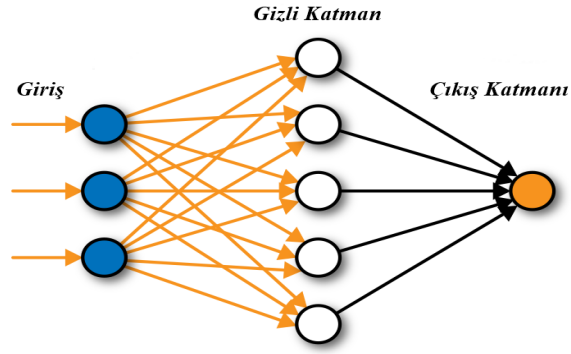
Z_i = Girdi vektörünün girdi değerleri

e^{z_i} = Girdi vektörünün her ögesine uygulanan eksponansiyel fonksiyon

K = Çoklu sınıflayıcılardaki sınıf sayısı

$\sum_{j=1}^K e^{z_j}$ = Normalizasyon

Yapay sinir ağları, yapay sinir hücrelerinin birbirine bağlanmasıyla oluşmaktadır. Yapay sinir ağları da 3 katmanda incelenir; giriş katmanı, gizli katman ve çıkış katmanı. Arada bulunan gizli katman sayısı ne kadar artarsa ağ o kadar derin ve karmaşık bir hal alır.



Şekil 1.5. Yapay sinir ağı katmanları (Jain vd. 1996).

Girdi katmanı ile ağı iletilen bilgiler ara katmanlarda işlenir ve çıktı katmanına gönderilir. Bilgi işlenmesi; ağı gelen bilgilerin ağı ait ağırlık değerlerinin kullanılmasıyla çıktıya dönüştürülmesi işlemidir. Doğru çıktı üretilmesi için ağırlıkların doğru değerlere sahip olması önem taşır. Ağ, birden çok nöron ve gizli katmana sahipse çok katmanlı (multilayer), tek bir katmana sahipse tek katmanlı (single layer) olarak nitelendirilmektedir. Yapay sinir ağlarında Identity, Sigmoid, Tanh, ReLU vb. gibi farklı aktivasyon fonksiyonları kullanılabilir.

Yapay sinir ağlarının işleyişlerine göre; İleri Beslemeli, Geri Beslemeli, Tekrarlayan, Evrişimli, Otomatik Kodlayıcı gibi türleri vardır. Bu çalışmada veriler BT görüntülerinden alınacağı için Evrişimli Sinir Ağları kullanılmıştır.


1.2.2. Evrişimli sinir ağları

Matematiksel olarak evrişim, 2 matrisin eleman bazında çarpımının toplamıdır. Tanım olarak evrişim iki fonksiyon (f , g) üzerinden üçüncü bir fonksiyon yaratmak için yapılan matematiksel işlemdir.

$$f(x)g(x) = \int_{-\infty}^{\infty} f(\tau)g(x - \tau)d\tau \quad (1.4)$$

$f(x)$ input (girdi), $g(x)$ ise impulse response (dürtü yanıtı), * Evrişim (Convolution)

Bu hesaplama ile girdi görüntüsünden belirli bir özelliği tespit eder ve o özellik hakkında bilgi sahibi olan sonucu elde ederiz. Buna 'özellik haritası' denir. Bunu gerçek görüntü örneğinde görürsek, sonuç aşağıda gösterilmiştir.



Şekil 1.6. Özellik haritası (Dettmers, 2015).

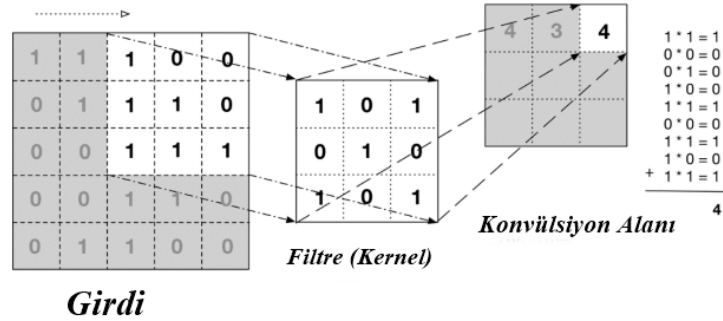
ESA görüntü verisine uygulanan çok sayıda katmandan oluşan derin öğrenme yöntemidir. ESA resimler ve videolar gibi görsel veriler için tasarlanmış özel bir sinir ağıdır ancak görüntü olmayan veriler için de iyi çalışır. ESA biyolojik görmede nöron gruplarının farklı fonksiyonları yerine getirmesi düşüncesini temel alır (Wani vd. 2020). İnsan beyninin görme merkezinde yer alan farklı nöronlar görme işlevinin gerçekleşmesi için farklı fonksiyonları yerine getirir. Örneğin; bazı nöronlar yatay çizgilere, bazıları dikey çizgilere, bir kısmı ise çapraz çizgileri algıladıklarında aktivasyon gösterir. ESA yapısında bir görselde öğrenilen özellik diğer görselde algılananla eşleştirilir. Yani bir resmin küçük bir kesitinde tüm noktalar karşılaştırmalı olarak taranmaktadır. ESA'nın kendi içerisinde katmanları bulunmaktadır, bunlar;

a. Giriş katmanı (Input Layer)

Giriş katmanı için üç boyutlu matrisle temsil edilen görüntü verileri gerekir. Üç boyutlu matrisin tek bir sütuna yeniden şekillendirilmesi gerekir. Örneğin; $28 \times 28 = 784$ boyutunda bir görüntünün girdiye girmeden önce 784×1 'e dönüştürülmesi gerekir. Görüntü analizinde ağ başarısı için uygun boyutta giriş görüntüsü seçilmesi önerilir (İnik ve Ülker, 2017).

b. Evrişim katmanı (Convulation Layer)

Bu katmana dönüşüm katmanı ya da filtre katmanı da denir, çünkü görüntünün özellikleri bu katman içinde çıkarılır. Bir filtre (kernel), bir girdi bölgesinin bir özelliğinin ne kadar yakın olduğunu ölçmek için bir ölçü sağlar. Bir özellik, belirgin herhangi bir yön olabilir - dikey kenar, yatay kenar, kemer, köşegen vb. Her şeyden önce, görüntünün bir kısmı evrişim işlemini gerçekleştirmek ve alıcı alan arasındaki iç çarpımı hesaplamak için evrişim katmanına bağlanır (giriş görüntüsünün, filtreninle aynı boyuta sahip yerel bir bölgesidir). Ardından, filtre aynı giriş görüntüsünün bir sonraki alıcı alanı üzerinde bir adım kaydırılır ve görüntünün tamamından geçene kadar aynı işlem tekrar yapılır. Adım, evrişim sırasında filtrenin giriş görüntüsünün pikselleri üzerinde yatay ve dikey olarak hareket etme hızını gösterir. Adım çıktı görüntüsünün özelliğine göre belirlenir, çok küçük ayrıntılar içeren bir görsel ise adım boyutu küçük seçilir, ayrıntı önemli değilse büyük adım boyutu seçilir. Çıktı, bir sonraki katman için girdi olacaktır. Evrişim katmanı, tüm negatif değerleri sıfıra getirmek için ReLU aktivasyonunu da içerir.



Şekil 1.7. Filtre kullanılarak uygulanan evrişim (Patterson & Gibson, 2017).


c. Havuzlama (Pooling) katmanı

Havuzlama katmanı evrişim katmanı sonucu oluşan görüntülerin hepsi için ağırlık sayısını azaltmak ve uygunluğu kontrol etmek için isteğe bağlı uygulanan işlemdir. Diğer bir deyişle bu katmanda kayma boyutu, ağ parametreleri ve hesaplama sayısı azaltılabilir. Havuzlama katmanı, evrişim katmanı tarafından oluşturulan bir özellik

haritası bölgesinde bulunan özellikleri özetler. Evrişim katmanında olduğu gibi, bu katmanda da belli filtrelerin görüntü üzerinde belli bir adım kaydırma değerine göre gezdirilerek işlem yapılır.


d. Düzleştirme katmanı (Flattening Layer)

Düzleştirme katmanı havuzlanmış özellik haritasının bir vektöre düzleştirildiği katmandır. Düzleştirme adımından sonra tek boyutlu hâle getirilen veri işlenmesi için tam bağlı katmana gönderilir.



Şekil 1.8. Düzleştirme katmanı (Superdatascience Team, 2018).

Sınıflandırma işlemi için yine sinir ağlarını kullanan bu yapı, özellik çıkarımı ve kalan işlemler için farklı katmanlar kullanır.



Şekil 1.9. ESA mimarisi (Ergin, 2018).

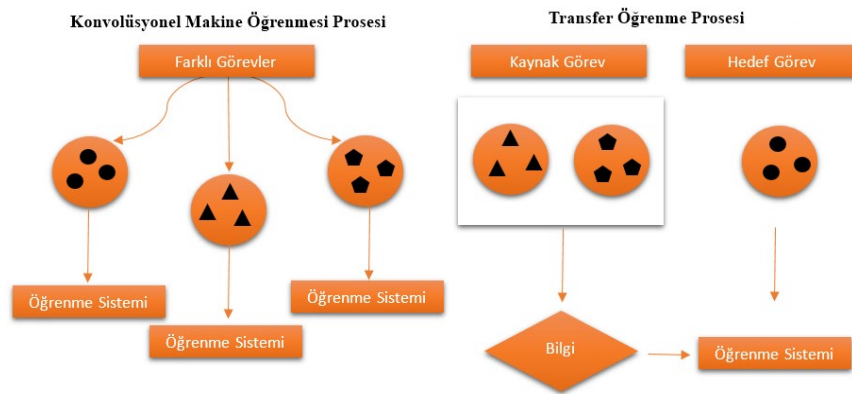
e. Tam bağı katman (Fully Connected Layer)

Düzleştirme işleminden sonra, önceki katmanlardan tek boyutlu bir vektör hâlinde gelen bilgi artık sınıflandırma için hazırdır. Sınıflandırma işleminin yapılacağı bu katmana tam bağı katman adı verilmektedir. Bu aşamada önceki katmanlardan alınan veriler sinir ağı içine alınır ve öğrenme işleminin gerçekleştiği katmandır.

1.3. Transfer Öğrenme

Transfer öğrenme, daha önce benzer veri setleri üzerinde eğitilmiş bir yapay sinir ağının benzer bir deney için kullanılmasıdır. Burada baştan bir eğitim yerine hali hazırda eğitilmiş yapay sinir ağları kullanılır ve bu sayede az veri ile dahi olsa yüksek doğruluk elde edilir. Ayrıca eğitilmiş bir yapay sinir ağı kullanıldığı için zaman ve kodlamadan tasarruf edilmiş olur.


Bu aşamada yoğun olarak ImageNet, DenseNet, ResNet gibi sinir ağları kullanılır. Hazır veriler üzerinde çalışma yapılması sürecin hızlanmasına olanak sağlar. Ayrıca yalnızca görseller üzerinden değil, doğal dil işleme seçeneğinde olduğu gibi belirli metinsel verilerin de ayıklanmasını sağlayan sinir ağları bulunmaktadır.



Şekil 1.10. Transfer öğrenme (Abir vd. 2022).

1.4. Artık Ağ Mimarisi (Residual Network Architecture - ResNet)

Derin öğrenme mimarilerinde katman sayısının belirli bir derinliğe ulaşması ağı yapısında bozulmaya neden olur. Bu durum ağ yapısındaki katman sayısının aşırı artması ile özellikle ilk katmanlarda gittikçe ağırlık güncellenmesinin kaybolmasına neden olarak eğitim setindeki sınıflandırma doğruluğunu azaltmaktadır. Eğitim ilerledikçe, bir katmandan diğerine geçerken gradyan sinyalleri kaybolmakta ve derin olmayan katmanlarda sifira yaklaşmaktadır (kaybolan gradyan sorunu). He vd. (2016) tarafından derin ağlardaki gradyanların yok olması problemine çözüm olarak artık öğrenme bloğu (residual block) çözümü getirilmiştir (ResNet (Residual Neural Network)). Şekil 1.11’de artık bloğun mimarisi görülmektedir. Bu mimaride x girdisinin derin katmanlara da aktarılması için f aktivasyonu sonucu oluşan çıktı ile toplanır.



Şekil 1.11. Artık ağ mimarisi (Üstündağ, 2022).

1.5. Ölçeklendirme Mimarisi (EfficientNet)

EfficientNet, bileşik ölçeklendirme ile tüm derinlik, genişlik ve çözünürlük boyutlarını tek tip olarak ölçekleyen ve model verimliliğini de koruyan bir evrişimli sinir ağı mimarisi ve ölçeklendirme yöntemidir (Tan ve Le, 2019). Geleneksel uygulamanın aksine, EfficientNet ölçeklendirme yöntemi ağ genişliğini, derinliğini ve çözünürlüğü bir dizi sabit ölçeklendirme katsayısıyla eşit şekilde ölçeklendirir. Bileşik ölçeklendirme yöntemi, giriş görüntüsü daha büyükse, ağı alıcı alanı artırmak için daha fazla katmana ve daha büyük görüntüde daha ince taneli desenler yakalamak için

daha fazla kanala ihtiyaç duyduğu sezgisiyle doğrulanır (Tan ve Le, 2019; Kızrak, 2019).

1.6. Literatür Taraması

Radyolojik görüntüleme sistemlerinin gelişmesi, tekniklerin artması ve görüntü işlemeye dayalı süreçlerin iyileştirilmesi ile, bu alanda pek çok çalışma yapılmaya başlanmıştır. Çeşitli görüntüleme sistemlerinden edilen görüntüler belli bir proses ile işlenir ve sonucunda dokuda bir saptama olup olmayacağı hesaplanır. Bu şekilde bilgisayarlı tanı sistemleri, radyologlara tanı aşamasında destek olmayı hedefler. Özellikle 2019 yılından itibaren Covid-19 salgını doğrultusunda elde edilen röntgen görüntüleri üzerinde analiz yapılarak meme kanseri gibi diğer hastalıkların saptanması için pek çok sistem geliştirilmiştir. Bu süreçler halen devam etmektedir.

Yu vd. (2006) kadınlarda meme kanserinin erken bir belirtisi olarak kabul gören, dijital mamografilerde meme kalsifikasyonlarının (MK) saptanması için bilgisayar destekli bir teşhis sistemi (CAD) geliştirmişlerdir. İki aşamalı çalışmada; öncelikle radyologlar tarafından işaretlenmiş 25 kümelenmiş MK alanı içeren 20 mamografide tüm şüpheli MK'ler hem Bayes sınıflandırıcısı hem de geri yayılım sinir ağı kullanılarak, ardından, Derin–Elliott modeline dayalı Markov rasgele alan parametreleri, birincil doku özellikleri olarak her şüpheli MK'nin komşuluğundan çıkarılmıştır. Bu yöntemle 1356 yanlış pozitiften 1341 yanlış pozitif kolayca kaldırdıklarını (%98.9 yanlış pozitif) Markov rasgele alan parametrelerine dayanan doku özelliğinin, MK'lerin doku bağlamından çıkarılan uygun şekilde tasarlanmış yardımcı özelliklerle birleştiğinde, dijital mamogramlarda MK'lerin tanınmasında olağanüstü çalışabileceğini kaydetmişlerdir.

Rakhlin vd. (2018) derin evrişimli sinir ağlarına dayalı hesaplamalı yaklaşımı geliştirdikleri çalışmada 2. sınıflandırma içeren karsinoma tespitinde yüksek hassasiyetli çalışma noktasında %93,8 doğruluk, AUC%97,3, duyarlılık %96,5 ve

özgüllüğü %88,0 rapor etmişler ve <https://github.com/alexander-rakhlin/ICIAR2018> sitesinde herkesin kullanımına sunmuşlardır.

Ragab vd. (2019) meme mamografi görüntülerinde iyi huylu ve kötü huylu kitle tümörlerini sınıflandırmak için yeni bir bilgisayar destekli tespit (CAD) sistemi önerdikleri çalışmada tarama mamografisi, derin evrişimli sinir ağları için dijital veri tabanı ve mamografi görüntüleri kullanılmıştır. Sonuçta yeni eğitilen evrişimli sinir ağlarında doğruluğun %76 olduğu ve önceki çalışmadan daha yüksek bir AUC düzeyine ulaşıldığı belirtilmiştir.

Benzer şekilde, ultrason görüntülerinde iyi huylu ve kötü huylu dokuları sınıflandırmak için ESA ve maske R-CNN ile derin öğrenme yöntemine dayalı bir model oluşturmayı amaçlayan diğer çalışmalar da vardır (Chiao vd. 2019; Zebari vd. 2019).

Anaya-Isaza vd. (2021) MK teşhisinde mamografilerde meme kitlelerinin segmentasyonu için mevcut derin evrişimel sinir ağlarını karşılaştırdıkları çalışmada UNet, Visual Geometry Group 19 (VGG19), InceptionResNetV2, EfficientNet, MobileNetv2, ResNet, ResNeXt, MultiResUNet, linkNet-VGG19, DenseNet, SEResNet ve SeResNeXt karşılaştırmışlardır. Çalışma sonucunda derin öğrenme modellerinde yeni gelişmeler ve teknikler ortaya çıkmasına rağmen, istenen göreve en uygun olana ulaşmak için farklı ağları keşfetmek gerektiğini, EfficientNet'in ikili çapraz entropi kaybı fonksiyonuyla birlikte %99,96'lık bir doğruluğa ulaştığını ve en son geliştirilen yaklaşımlardan daha iyi performans gösterdiğini kaydetmişlerdir.

Ayrıca benzer tıbbi görüntüler kullanılarak, MATLAB, PYTHON, C+ gibi farklı platformlarda pek çok çalışma yapılmıştır. Program olarak bu çalışmada da Python kullanıldığı için, yapılan çalışmalarda aynı program kullanılanlar temel alınmıştır. Çalışmaların bir kısmında doğrudan mamografi görüntüleri kullanılmış, bazı çalışmalarda ise X-Ray görüntüleri üzerinden gidilmiştir.

Boels (2020) yaptığı tez çalışmasında, derin öğrenme teknikleri kullanılarak meme görüntülerindeki malign dokuların ayrımı üzerinde bir kod geliştirmiştir. Bu kodlamada Resnet50V2, DenseNet121 ve VGG19 kıyaslamalarına yer vermiş, ayrıca

farklı optimizasyon algoritmalarının verdiği sonuçları da paylaşılmıştır. Kodlamada optimizasyon algoritması olarak Adam Optimizer kullanılmıştır, Resnet50V2 yapay sinir ağını kullanmayı tercih etmiş, görüntülerin kodlamaya dahil edilmesi için Image Data Generator kullanımını tercih etmiştir. Resnet50V2 ImageNet veri kümesi üzerinden eğitilmiş 50 katmanlı bir ağıdır. Burada isimlerin devamındaki sayı ne kadar büyük ise ağ o kadar kompleks ve günceldir. Ancak belli yapay sinir ağları belli işlemlerde daha çok tercih edilmektedir. Önceden eğitilmiş ağlar kullanılması, araştırma yapılacak veri setindeki veri sayısı az olsa bile yeterli sonuçlar alınmasını sağlar. Transfer Learning'in temelini oluşturan bu mantıkta önceden başka bir veri seti kullanılarak eğitilmiş olan ağın, başka bir amaçla yeniden düzenlenip eğitilmesini ve beklenen eleme işlemini yapması kolaylaştırılır. Resnet ve EfficientNet gibi, görüntü işleme çalışmalarında çok sık kullanılan önceden eğitilmiş sinir ağları bulunmaktadır.

Singla vd. (2018) ESA kullanarak 48 hastanın Optik Koherens Tomografi (OKT) görüntülerinden sağlıklı ve kanserli doku ayrımının %90 doğrulukla yapılabildiğini bu yöntemin operasyon sınırları belirlemede ve iğne biyopsi için rehberlik edebileceğini kaydetmişlerdir. Bareja vd. (2022) Optik Koherens Tomografi (OKT) taramalarında meme dokularının sınıflandırılması ESA kullandıkları çalışmada mastektomilerden ve meme küçültmelerden alınan insan meme örneklerinin görüntüleri kullanılmıştır. Ağın, 23 hastadan oluşan bir veri setinde %96,7 doğruluk, %92 hassasiyet ve %99,7 özgüllük elde ettiği belirtilerek derin öğrenmenin kullanımının OCT'nin klinik pratiğe entegrasyonu için önemli olduğu belirtilmiştir.

Bu çalışmada asıl amaç tümör görüntülerini malign ve benign olarak ayırabilen bir kod yapısı oluşturmaktır, ayrıca yoğun olarak kullanılan EfficientNet ve Resnet Sistemleri aynı kodlamanın içerisinde hız, doğruluk, hassasiyet gibi değerler üzerinden karşılaştırılmıştır.

MALZEME VE YÖNTEM

2.1. Kullanılan Veriler ve Yöntemler

Bu bölümde verilerin detayları, kullanılmış olan yöntemler ve donanım hakkında bilgiler verilmiştir.

2.1.1. Donanım

Bu çalışmada kullanılan bilgisayara ait donanım aşağıda sunulmuştur;

İşlemci: Intel Core i7-7700HQ 4 x 2.8- 3.8 GHz

Grafik kartı: NVIDIA GeForce GTX 1050 Mobile- 4 GB VRAM

Çekirdek: 1493 MHz, Bellek: 1752 MHz, GDDR5

Bellek: 16 GB, DDR4-2400

Görüntü: 15,60 inç 16:9, 1920 x 1080 piksel 141 PPI, IPS,

Anakart: Intel HM175

Harddisk: 512 MB NAND Flash, 0.5 GB, 439 GB Boş

Batarya: 73 Wh Lithium-Polymer, 8-cell,

Batarya kullanım süresi (üreticiye göre): 14 saat

İşletim sistemi: Microsoft Windows 10 Home 64

2.1.2. Veri Seti

Veriler Muğla Eğitim ve Araştırma Hastanesi Radyoloji Bölümünden alınmıştır. Eğitim (training) ve doğrulama (validation) seti için 1376 benign ve 733 malign dokuya ait görüntü olmak üzere toplam 2109 veri kullanılmıştır. Test veri seti olarak eğitim ve

doğrulamada kullanılan 2109 görüntü haricinde ayrıca seçilen karma 131 görüntü kullanılmıştır. Veri artırımı için aynalama yönteminden faydalanılmıştır.

```
import os
import cv2
import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import EfficientNetB0, ResNet50
from tensorflow.keras.layers import GlobalAveragePooling2D, Dense, Dropout
from tensorflow.keras.models import Model
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping
```

Şekil 2.1. Gerekli kütüphanelerin içeri aktarılması.

2.1.3. Görsellerin içeri aktarılması

Görüntüler bilgisayar içerisinde ayrı ayrı klasörlerde konumlandırılmıştır. Test, doğrulama (validation) ve eğitim (training) için üç klasör oluşturulmuştur. Eğitim (training) ve doğrulama (validation) klasörleri içerisine benign ve malign olarak iki ek klasör daha açılmıştır. Test klasörü içerisine bu iki klasör içinde yer almayan ayrı ve karışık benign ve malign görüntüleri eklenmiştir (n=131). Bu sayede kodun çalışması esnasında klasör yolunu doğru bir şekilde tanımlamak mümkün olmuştur. Ayrıca sınıflandırılan görüntüler iki yeni klasörle ana klasörün içerisine depolanacak şekilde düzenleme yapılmıştır. Bu işlem hep EfficientNetB0 hem de ResNet50 için uygulanmıştır.

```
# Define the data directories
train_dir = r'C:\Users\asus\Desktop\Image\train'
val_dir = r'C:\Users\asus\Desktop\Image\val'
test_dir = r'C:\Users\asus\Desktop\Image\test'
```

Şekil 2.2. Klasör yolunun tanıtılması.

2.1.4. Veri seti ön işleme

Görüntülerin klasör yolları tanımlandıktan sonra, yeniden boyutlandırma, görüntü çoğaltma işlemleri için her klasöre olacak şekilde ön işleme yapılmıştır. Bu sayede

görüntü değerleri yeniden boyutlandırılarak hazır hale getirilir. Sonraki aşamada *Data Generator* komutu kullanılarak test, eğitim (training) ve doğrulama (validation) görüntüleri için rescale işlemleri yapılmıştır.

```
# Create the data generators
train_datagen = ImageDataGenerator(rescale=1. / 255,
                                   shear_range=0.2,
                                   zoom_range=0.2,
                                   horizontal_flip=True)
val_datagen = ImageDataGenerator(rescale=1. / 255)
test_datagen = ImageDataGenerator(rescale=1. / 255)

train_generator = train_datagen.flow_from_directory(train_dir,
                                                    target_size=(IMG_SIZE, IMG_SIZE),
                                                    batch_size=BATCH_SIZE,
                                                    class_mode='binary')

val_generator = val_datagen.flow_from_directory(val_dir,
                                                target_size=(IMG_SIZE, IMG_SIZE),
                                                batch_size=BATCH_SIZE,
                                                class_mode='binary')

test_generator = test_datagen.flow_from_directory(test_dir,
                                                  target_size=(IMG_SIZE, IMG_SIZE),
                                                  batch_size=BATCH_SIZE,
                                                  class_mode='binary')
```

Şekil 2.3. Veri seti jeneratörlerinin tanımlanması.

Ayrıca *class mode binary* olarak seçilir, bu sayede benign ya da malign olarak ayrıştırma yapılması sağlanmıştır. *Class mode binary* seçimi ile verilen görüntüler 0 ya da 1 olacak şekilde dönüştürülmüş ve bu sayede sınıflandırma işlemi gerçekleştirilmiştir.

```
# Resize the images in the validation directory
for root, dirs, files in os.walk(val_dir):
    for file in files:
        img_path = os.path.join(root, file)
        img = cv2.imread(img_path)
        img = cv2.resize(img, (IMG_SIZE, IMG_SIZE))
        cv2.imwrite(img_path, img)

# Resize the images in the test directory
for root, dirs, files in os.walk(test_dir):
    for file in files:
        img_path = os.path.join(root, file)
        img = cv2.imread(img_path)
        img = cv2.resize(img, (IMG_SIZE, IMG_SIZE))
        cv2.imwrite(img_path, img)
```

Şekil 2.4. Görüntülerin yeniden boyutlandırılması.

2.1.5. Yapay sinir ağlarının eğitilmesi

EfficientNet ve ResNet ağlarının bizim tarafımızdan eğitimine ihtiyaç yoktur çünkü bu ağlar önceden ImageNet veri kümesindeki görüntüler üzerinde eğitilmiş ağlardır (EfficientnetB0 ve ResNet50 kullanılmıştır). Bu nedenle, modeldeki ağırlıklar genellikle iyi ayarlanmıştır ve birçok görev için iyi sonuçlar verir. Bu sayede iki sinir ağının tanımlanması ve gerekli değerlerin girilmesi, ağların koda dahil edilmesi için yeterli görülmüştür.

2.1.6. Derin öğrenme yöntemi ve yazılım detayları

Çalışmada öncelikli olarak hangi mimarilerin kullanılacağına karar verilmiştir. *Pycharm* kullanılarak gerçekleştirilen çalışmada, kodlama içerisinde hem EfficientNet hem de ResNet kullanılmasına karar verilmiştir. Bunun için *Keras modülleri* çağrılmıştır. *Keras*, *Tensorflow*'un bir parçası olarak sunulduğundan, bu çalışmada aslında iki modül bir arada kullanılmıştır. Sonraki aşamada hiper parametreler tanımlanmış ve değerler atanmıştır. Çalışma boyunca kod 5 kere tekrar çalıştırılmış ve farklı hiper parametre değerleri üzerinde deneme yapılmıştır.

```
# Define some hyperparameters
BATCH_SIZE = 32
EPOCHS = 1
LEARNING_RATE = 1e-4
IMG_SIZE: int = 512
```

Şekil 2.5. Hiperparametrelerin belirlenmesi.

Sonraki aşamada yukarıda bahsedilen data ön işleme sürecine yer verilmiş ve devamında EfficientNet ve ResNet mimarileri oluşturulmuştur. Ardından iki modelin kıyaslanması için gerekli komutlar eklenmiştir. Burada *Adam optimizer* kullanılmış ve learning rate atamaları gerçekleştirilmiştir.

```

# Define the model architectures
efficientnet_model = EfficientNetB0(include_top=False, input_shape=(IMG_SIZE, IMG_SIZE, 3))
efficientnet_output = efficientnet_model.layers[-1].output
efficientnet_output = GlobalAveragePooling2D()(efficientnet_output)
efficientnet_output = Dense(512, activation='relu')(efficientnet_output)
efficientnet_output = Dropout(0.5)(efficientnet_output)
efficientnet_output = Dense(1, activation='sigmoid')(efficientnet_output)
efficientnet_model = Model(inputs=efficientnet_model.inputs, outputs=efficientnet_output)

resnet_model = ResNet50(include_top=False, input_shape=(IMG_SIZE, IMG_SIZE, 3))
resnet_output = resnet_model.layers[-1].output
resnet_output = GlobalAveragePooling2D()(resnet_output)
resnet_output = Dense(512, activation='relu')(resnet_output)
resnet_output = Dropout(0.5)(resnet_output)
resnet_output = Dense(1, activation='sigmoid')(resnet_output)
resnet_model = Model(inputs=resnet_model.inputs, outputs=resnet_output)

```

Şekil 2.6. ESA mimarilerinin tanıtılması.

Kodlama ilk oluşturulduğunda, hatalı bir işlem yapıldığı için belirtilen Epoch değerinden sonra da kod çalışmaya devam etmiştir. Bu hatayı düzenlemek adına *EarlyStopping* komutu ile deneme gerçekleştirilmiştir. Komut sistemde hatasız olarak çalışmış ve kodlamaya dahil edilmiştir.

Sonraki aşamada sürecin doğruluğunu değerlendirmek adına EfficientNet ve ResNet mimarileri için *Evaluate* komutları ile gerçek dünyadaki verilerle ne kadar iyi çalıştığının hesaplanması istenmiştir. Bu sayede aşırı uyma (overfitting) yapıp yapmadığı gibi durumlar değerlendirilmiştir.

Son aşamada ise elde edilen değerlerin tamamı için plot oluşturulması istenmiş, ayrıca ayrılan görüntüler malign ve benign isimli iki klasörde depolanacak şekilde bir kod yapısı oluşturularak kodlama sonlandırılmıştır.

```
# Plot the training and validation accuracy of the models over time
plt.plot(efficientnet_history.history['accuracy'], label='EfficientNet train accuracy')
plt.plot(efficientnet_history.history['val_accuracy'], label='EfficientNet val accuracy')
plt.plot(resnet_history.history['accuracy'], label='ResNet train accuracy')
plt.plot(resnet_history.history['val_accuracy'], label='ResNet val accuracy')
plt.xlabel('Epoch')
plt.ylabel('Accuracy')
plt.legend()
plt.show()

# Make predictions on the test data using the trained models
efficientnet_predictions = efficientnet_model.predict(test_generator)
resnet_predictions = resnet_model.predict(test_generator)

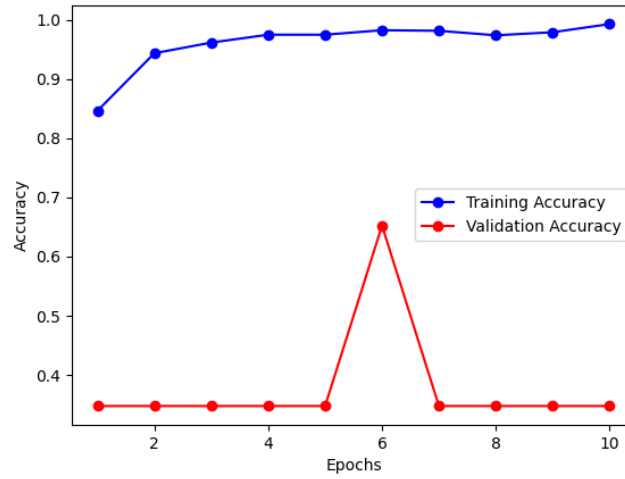
# Save the predictions as benign or malign images
test_images = os.listdir(test_dir)
for i, img in enumerate(test_images):
    if efficientnet_predictions[i] < 0.5:
        os.rename(os.path.join(test_dir, img), os.path.join(test_dir, 'benign', img))
    else:
        os.rename(os.path.join(test_dir, img), os.path.join(test_dir, 'malign', img))
)
```

Şekil 2.7. Plotların oluşturulması ve kodun sonlandırılması.

3. BULGULAR VE İRDELEME


Yapılan çalışmada BT görüntülerinde tespit edilen meme nodüllerinin benign-malign ayırımındaki performansının doğruluk oranı ortalama %91,5 olarak tespit edilmiştir. Ayrıca kıyaslamada kullanılan veri seti için EfficientNet doğruluk oranının (%96) ResNet'ten (%87) yüksek olduğu belirlenmiştir.

Yapılan 5 tekrar içerisinde EfficientNet yapay sinir ağı üzerinde aşırı uyum (overfitting) daha çok görülmüştür. Ayrıca bilgisayarın yeterli olmayışı sebebiyle kodlama süreçleri 10 epoch için 7 gün sürmüştür, diğer çalışmalarda sırasıyla 3 epoch, 1 epoch ve 2 epoch değerleri üzerinden denemeler yapılmıştır. Epoch sayıları veri setinin eğitilmesi ve elde edilen çıktılarının doğruluğu için önem arz etmektedir. 3 epoch değerleri yeterli olmamakla beraber, birkaç tekrar içerisinde iki yapay sinir ağı için karşılaştırma yapmak mümkün olmuştur. 3 epoch için kodun toplam çalışma süresi 4 gündür. Sürecin uzunluğundan dolayı manuel olarak durdurma yapılmış ve plot analizleri ayrı bir kodlama ile tekrar düzenlenmiştir. Elde edilen çıktılar, plot grafikleri ve değerler aşağıda yer almaktadır.



Şekil 3.1. İlk denemede 10 epoch için alınan görüntü (EfficientNet)

Yukarıdaki şemada görülmektedir ki validation accuracy değerlerinde 10 epoch için aşırı uyum (overfitting) izlenmektedir. Bu sorunun önüne geçmek adına hiper parametreler değiştirilip tekrar çalışma yapılmıştır.



Şekil 3.2. İkinci deneme 12 epoch için alınan görüntü (EfficientNet)

Bir sonraki denemede ise daha farklı değerler elde edilebilmiştir. Bu değerleri yukarıdaki grafikten takip etmeniz mümkündür. Ayrıca 3 epoch için EfficientNetB0 ve ResNet50 çıktılarının detayları aşağıdaki şekilde yer almaktadır.

3 Epoch İçin EfficientNetB0 ve ResNet50 Çıktıları								
EfficientnetB0				ResNet50				
	Val Loss	Val Accur.	Loss	Accuracy	Val Loss	Val Accur.	Loss	Accuracy
1	1.2517	0.3476	0.3551	0.8445	83.3307	0.6524	0.527	0.7796
2	0.6539	0.6524	0.1543	0.9412	0.6887	0.6524	0.3164	0.8706
3	1.651	0.3476	0.1154	0.9602	0.6682	0.6621	0.3142	0.8765

Şekil 3.3. Üçüncü deneme 3 epoch için EfficientNetB0 ve ResNet50 çıktıları.

Veri setinin yapısı, sınıflandırılması istenen görüntülerin türü, sayısı, sınıflandırma türü vb. pek çok detay yapay sinir ağlarının çalışmasını ve doğruluk oranlarını etkilemektedir. Bu nedenle her çalışma için EfficientNetB0'nun daha verimli olduğunu söylemek doğru olmayacaktır. Ancak her iki yapay sinir ağı da önceden eğitilmiş olduğu için, daha az veriye sahip olunan ve eğitim sürecinin aradan çıkabileceği

durumlarda bu yapay sinir ađlarını kullanmak avantajlı olacaktır. Aynı şekilde veri sayısının azlığından dolayı yine Transfer Learning yöntemleri kullanılmış ve bu sayede az veri ile sınıflandırma yapılabilmesi sağlanmıştır. Aşırı uyum (overfitting) gibi problemlerin önüne geçilmesi için hiper parametreler doğru seçilmelidir. Ayrıca kullanılan bilgisayar ve araçlar da aynı şekilde önem arz etmektedir.

Yapılan karşılaştırmada görülmüştür ki, kullanılan bu veri seti için EfficientNetB0 daha iyi sonuçlar vermektedir. Ayrılan klasörlerde 131 test datasını EfficientNetB0 en çok %96 oranında sınıflandırmış, ResNet50 ise en çok %87 oranında doğru sınıflandırma yapabilmıştır.

4. TARTIŞMA VE SONUÇ

Meme kanseri kadınlarda en sık görülen kanser türüdür. Meme kanserini erken saptamak uygun tedavi planı ve sağ kalımı uzatmak için önemlidir. Tanısal BT’de radyasyon dozu mamografiye göre yüksektir (6- 14 mSv) (Buck vd. 2008). Radyasyon dozu nedeni ile meme kanseri taramalarında BT kullanılmamaktadır. Kovid gibi pandemilerde hastaların rutin takiplerin aksamalar görülmektedir. Bu dönemlerde toraks BT gibi tetkik kullanımı artmıştır. Meme, toraks BT incelemelerinde görüntüleme alanı içerisinde bulunmaktadır. Bu nedenle ek tetkik yapmadan eldeki görüntüler ile meme dokusunu mamografilerdeki kadar olmasa da değerlendirmek mümkün olabilmektedir. Bu çalışmada Covid-19 nedeniyle gerçekleştirilen toraks BT taramalarında ESA kullanılarak insidental olarak meme nodüllerinde benign-malign ayrımının yapılması hedeflenmiştir. Çünkü ESA’lar, geleneksel yaklaşımlarla karşılaştırıldığında tıbbi görüntülemelerde tümör tespit ve sınıflandırma verimliliğini yüksek oranda artırması nedeniyle popüler hale gelen ESA tabanlı yaklaşımlar pek çok araştırmada farklı görüntülerden meme kanseri tanısında başarılı olmuştur ve önerilmiştir (Zuluaga-Gomez vd. 2021; Desai ve Shah, 2021; Jafarzadeh vd. 2021; Dabeer vd. 2019; Bardou vd. 2018; Iesmantas ve Alzbutas, 2018; Tan vd. 2017; Guan ve Loew, 2017; Rouhi vd. 2015; Übeyli, 2007).

BT görüntülerinde tespit edilen meme nodüllerinin benign-malign ayrımındaki performansının doğruluk oranı Singla vd. (2018) tarafından 48 hastadan (22 normal fibro-adipoz doku ve 26 İnvazif duktal karsinom kanserli doku) toplanan test veri kümeleriyle önceden eğitilmiş bir Inception-v3 ESA kullanılarak yaptıkları çalışma sonucunda %90 olarak bildirilmiştir.

Al-Haija ve Adebajo (2020) meme kanseri teşhisi için histopatolojik mikroskopi görüntülerini iyi huylu veya kötü huylu olarak sınıflandırmaya yönelik ImageNet üzerinde önceden eğitilmiş güçlü ResNet-50 ESS'nın transfer öğrenme tekniğini kullanan bir model önermişlerdir. Önerilen modelin aynı veri seti üzerinde eğitilen diğer karşılaştırılan modellerden %99 daha üstün bir performansla olağanüstü

sınıflandırma doğruluğuna ulaştığı beyan edilmiştir. Bu bulgu çalışmamızı desteklemektedir.

Zhang vd. ise (2020) uzaktan algılama görüntü sınıflandırması için ince ayar stratejisi ile önceden eğitilmiş EfficientNet modellerine dayalı bir transfer öğrenme yönteminin oldukça etkili olduğunu, uzaktan algılama görüntü sınıflandırmasında genelleme ve iyi uygulanabilirliğe sahip olduğunu ve yöntemin uzaktan algılama görüntü sınıflandırmasının performansını etkili bir şekilde geliştirebileceğini kaydettikleri çalışmada önceden eğitilmiş EfficientNet modellerine dayalı bir transfer öğrenme yönteminin görüntü işlemenin diğer alanlarında da uygulanabileceğini önermişlerdir. Çalışmamızda elde edilen sonuçlarla paralel olarak EfficientNet'in görüntü sınıflandırma alanındaki diğer en son modellere göre önemli ölçüde daha az parametre kullanarak mevcut en gelişmiş performansı elde ettiği de kaydedilmiştir.

Anaya-Isaza vd. (2021) MK teşhisinde mamografilerde meme kitlelerinin segmentasyonu için mevcut derin evrimsel sinir ağlarını karşılaştırdıkları çalışmada UNet, Visual Geometry Group 19 (VGG19), InceptionResNetV2, EfficientNet, MobileNetv2, ResNet, ResNeXt, MultiResUNet, linkNet-VGG19, DenseNet, SEResNet ve SeResNeXt karşılaştırmışlardır. Çalışma sonucunda derin öğrenme modellerinde yeni gelişmeler ve teknikler ortaya çıkmasına rağmen, istenen göreve en uygun olana ulaşmak için farklı ağları keşfetmek gerektiğini, EfficientNet'in ikili çapraz entropi kaybı fonksiyonuyla birlikte %99,96'lık bir doğruluğa ulaştığını ve en son geliştirilen yaklaşımlardan daha iyi performans gösterdiğini kaydetmişlerdir. Ancak lezyonlar küçük olduğunda ölçümlerle ilgili hatayı azaltmak için yeni yöntemlerin araştırılmasını önermişlerdir.

Görüntü analizi yapılan farklı çalışma örnekleri ve doğruluk oranları Çizelge 4.1'de sunulmuştur.

Çizelge 4.1. Görüntü analizi kullanan çalışmalar ve doğruluk oranları.

Araştırma	Yöntem	Veri Seti	Doğruluk
Chen vd. (2023)	ESA, VGG, ResNet 101, EfficientNet	Dataset-BUSI-with-GT Kaggle'dan 780 görüntü BreakHis, 82 görüntü	%89,98
Mishra vd. (2023)	LASSO Regresyon ve Uyarlanmış LASSO Regresyon	56 Meme Termogramı	%96,79
Mahoro & Akhloufi (2022)	Birinci Adım: TransUNet İkinci Adım: EfficientNet-B7, ResNet-50, VGG-16 ve DenseNet-201	3989 Meme Termogramı	%97,26
Chakravarthy vd. (2022)	AlexNet, GoogleNet, ResNet50 ve DenseNet121 ESA	322 açıklamalı dijital mamografi	MIAS için %97,93 INbeast için %96,64
Zuluaga-Gomez vd. (2021)	ESA	DMR-IR veri tabanında yaşları 21 ile 80 arasında değişen 57 hasta (19 sağlıklı, 38 malign)	%92
Torres-Galván vd. (2021)	ResNet-101 ESA	Yaşları $54,95 \pm 12,6$ olan 311 kadın ve anormal termogramları olan 44 hasta ve 267 kontrol	
Anaya-Isaza vd. (2021)	UNet, Visual Geometry Group 19 (VGG19), InceptionResNetV2, EfficientNet, MobileNetv2, ResNet, ResNeXt, MultiResUNet, linkNet-VGG19, DenseNet, SEResNet ve SeResNeXt	Tarama Mamografisi Dijital Veri tabanı (DDSM), Mamografik Görüntü Analizi Derneği (MIAS) veri tabanı ve INbreast dahil olmak üzere açık erişimli veri tabanlarından 714 Mamogram	EfficientNet iki görevde %94,75 ve %99 VGG19 %96,97 ResNet50V2 %97,73

Çizelge 4.1. (devam)

Araştırma	Yöntem	Veri Seti	Doğruluk
Gour vd. (2020)	ResHist	BreakHis veri seti 782 hastanın 7909 meme kanseri histopatolojik görüntüsünü içermektedir. 7909 görüntü (2480'i iyi huylu, 5429'u kötü huylu) 40X, 100X, 200X ve 400X büyütme faktörlerinde kullanılmıştır.	%84,34
Gupta vd. (2020)	Hybrid ESA	Brezilya'daki P&D Lab tarafından Ocak 2014 ile Aralık 2014 arasında yapılan bir anketin sonucunda toplanan BreakHis veri tabanı, 7909 görüntü (2480 benin, 5429 malign) ($\times 40$, $\times 100$, $\times 200$ ve $\times 400$) görüntüleri kullanılmıştır.	%93,27
Al-Haija & Adebajo (2020)	ResNet-50 ESA	BreakHis histopatoloji görüntüleri meme kanseri veri tabanı, 7909 görüntü (2480 benin, 5429 malign) ($\times 40$, $\times 100$, $\times 200$ ve $\times 400$) görüntüleri kullanılmıştır.	%99,10
Ragab vd. (2019)	CAD	Mamogram	%99,7
Dabeer vd. (2019)	LeNet-5 ESA	Brezilya'daki P&D Lab tarafından Ocak 2014 ile Aralık 2014 arasında yapılan bir anketin sonucunda toplanan BreakHis veri tabanı, 7909 görüntü (2480 benin, 5429 malign) ($\times 40$, $\times 100$, $\times 200$ ve $\times 400$) görüntüleri kullanılmıştır.	%99,86

Çizelge 4.1. (devam)

Araştırma	Yöntem	Veri Seti	Doğruluk
Gandomkar vd. (2018)	ResNet-152 ESA	81 hastadan oluşan halka açık bir veri tabanı, 7786 görüntü için her hastanın dört büyütme faktöründe ($\times 40$, $\times 100$, $\times 200$ ve $\times 400$) görüntüleri kullanılmıştır.	%98,77
Singla vd. (2018)	ESA	48 hastanın Optik Koherens Tomografi (OKT) görüntüleri	%90
Rakhlin vd. (2018)	ESA	400 Hematoksilen-Eozin Boyama (H&E) seti	%93,8

Bu çalışmadaki sonuçlar akciğerlere yönelik yapılan toraks BT görüntülerdeki insidental olarak saptanan meme nodüllerinin benign-malign olarak ayırt etmede ESA ların kullanışlı olabileceğini göstermektedir.

Öneriler

- Çalışmanın sonraki aşamalarında malign dokuyu kendi içinde sınıflandırılacak bir yapı oluşturulması planlanması önerilir. Ayrıca çalışmanın ilerletilmesi halinde işlem sürelerini kısaltacağı ve daha geniş bir yelpazede çalışma olanağı sunacağından online bir platform olan ve Drive üzerinden klasörleri depolamaya müsaade eden Google Colab kullanılması önerilmektedir.
- Çalışmamızda elde edilen sonuçlar veri setinin kalitesinin ve temsiliyetinin önemini vurgulamaktadır. Bu alanda yapılacak çalışmalarda benin ve malign örneklerinin dengesi, veri setinin büyüklüğü ve kalitesi hakkında daha fazla analiz yapılması önerilir.
- Çalışmanın ikinci adımında belirtildiği gibi, hiperparametrelerin etkisi önemlidir. Farklı hiperparametre ayarlarının denendiği senaryolar ile bu ayarların neden tercih edildiğini vurgulayan çalışmalar yapılması önerilir.

- Yapılan alıřmada BT grntlerinde tespit edilen meme nodllerinin benign-malign ayırımındaki performansının doęruluk oranı yksektir. Hangi durumlar veya faktrlerin bu sonuları etkileyebileceęini ortaya koyan alıřmalar yapılması nerilir.
- alıřmamızda ortaya koyulan yazılımın geliřtirilerek hastanelerde meme kanseri teřhisinde destek saęlaması amacıyla pilot uygulama olarak kullanılması nerilir.

KAYNAKLAR

- Abir, W.H., Uddin, M.F., Khanam, F.R., Tazin, T., Khan, M.M., Masud, M., Aljahdali, S. (2022). Explainable AI in diagnosing and anticipating leukemia using transfer learning method. *Computational Intelligence and Neuroscience*, 1-14, 10.1155/2022/51401485140148.
- Al-Haija, Q. & Adebajo, A. (2020). Breast Cancer Diagnosis in Histopathological Images Using ResNet-50 Convolutional Neural Network, 2020 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS), <https://ieeexplore.ieee.org/xpl/conhome/9211388/proceeding>, 1-7.
- Anaya-Isaza, A., Mera-Jiménez, L., Cabrera-Chavarro, J.M., Guachi-Guachi, L., Peluffo-Ordóñez, D. ve Rios-Patiño, J.I. (2021). "Comparison of Current Deep Convolutional Neural Networks for the Segmentation of Breast Masses in Mamograms" IEEE Access, 9, 152206-152225, 10.1109/ACCESS.2021.3127862.
- Arayıcı, M.E., Yalçın, F., Ellidokuz, H. (2021). Kanser Kaydının Önemi ve Kanser Kontrolündeki Yeri, *Sted*, 30(5), 366-375.
- Arıcan, P. (2012). Meme kanserinde sentinel lenf nodülü saptanmasında planar lenfosintigrafi ve SPECT/BT. *Turkish Journal of Surgery*, Issue: 2012, Volume 28, Issue 4, 201-206, 10.5152/UCD.2012.20.
- Arslan, M. (2017). *Sabit Anotlu X Işını Tüpü Tasarımı ve İmalatı*. 2016-2017 EÖY Lisans Bitirme Tezi, Mühendislik Fakültesi Mekatronik Mühendisliği Bitirme Tezi, Ömer Halisdemir Üniversitesi, Niğde, 52 sayfa.
- Bareja, R., Mojahed, D., Hibshoosh, H. and Hendon, C. (2022). Classifying breast cancer in ultrahigh-resolution optical coherence tomography images using convolutional neural networks. *Applied Optics*, 61 (15), 4458-4462 (2022), [10.1364/AO.455626](https://doi.org/10.1364/AO.455626)
- Bardou, D., Zhang, K. & Ahmad, S.M. (2018). Classification of Breast Cancer Based on Histology Images Using Convolutional Neural Networks. *IEEE Access*, 6, 24680-24693.

- Boels, M. (2020). *Predicting malignancy in breast cancer using Deep Learning*. PhD Thesis. University of Surrey, Guildford, Surrey, UK.
- Buck, A.K., Nekolla, S., Ziegler, S., et al. (2008). SPECT/CT. *J Nucl Med*, 49: 1305-1319, 10.2967/jnumed.107.050195.
- Buldanlı, M.Z. (2017). *Selim ve Habis Meme Hastalıklarında Dr-70 Elisa Testinin Tanısal Duyarlılık ve Özgüllüğünün Değerlendirilmesi*. Uzmanlık Tezi, İstanbul Medeniyet Üniversitesi, Göztepe Eğitim ve Araştırma Hastanesi, Genel Cerrahi Ana Bilim Dalı, İstanbul.
- Chakravarthy, S.R.S., Bharanidharan, N. & Rajaguru, H. (2022). Multi-Deep CNN based Experimentations for Early Diagnosis of Breast Cancer. *IETE Journal of Research*, 10.1080/03772063.2022.2028584.
- Chen, N., Han, B., Li, Z., Wang, H. (2023). Breast Cancer Prediction Based on the CNN Models. *Highlights in Science, Engineering and Technology*, Volume 34, 103-109.
- Chiao, J.Y., Chen, K.-Y., Liao, K. Y.-K., Hsieh, P.-H., Zhang, G., & Huang, T.-C. (2019). Detection and classification the breast tumors using mask R-CNN on sonograms. *Medicine*, 98(19), e15200.
- Czemin, J., Allen-Auerbach, M. & Schelbert, H.R. (2007). Improvements in cancer staging with PET/CT: literature-based evidence as of September 2006. *Journal of Nuclear Medicine*, 48: 78-88.
- Dabeer, S., Khan, M.M. & Islam, S. (2019). Cancer diagnosis in histopathological image: CNN based approach. *Informatics in Medicine Unlocked*, Volume 16, 10.1016/j.imu.2019.100231.
- Desai, M. & Shah, M. (2021). An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN), *Clinical eHealth*, Volume 4, 1-11, 10.1016/j.ceh.2020.11.002.

- Dettmers, T. (2015). <https://timdettmers.com/2015/03/26/convolution-deep-learning/> (Eriřim Tarihi: 05.12.2022).
- DSÖ (2021). Meme kanseri. <https://www.who.int/news-room/fact-sheets/detail/breast-cancer> (01.05.2023 tarihinde eriřildi).
- Ergin, T. (2018). Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır? <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> (Eriřim Tarihi: 04.05.2023).
- Gandomkar, Z., Brennan, P.C. & Mello-Thoms, C. (2018). MuDeRN: Multi-category classification of breast histopathological image using deep residual networks. *Artificial Intelligence in Medicine*, 88, 14 – 24.
- Gennari, A., André, F., Barrios, C.H., Corté, J. et al. (2021). ESMO Clinical Practice Guideline for the diagnosis, staging and treatment of patients with metastatic breast cancer. *Annals of Oncology*, 32 (12), 10.1016/j.annonc.2021.09.019.
- Gour, M., Jain, S. & Kumar, T.S. (2020). Residual learning-based CNN for breast cancer histopathological image classification. *International Journal of Imaging Systems and Technology*, 30: 621– 635, 10.1002/ima.22403
- Görgel, P. (2011). *Görüntü İşleme Teknikleri Kullanılarak, 2-Boyutlu Mamografik Verilerde Kanserli Bölge Tanısı*. Doktora Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, İstanbul.
- Guan, S. & Loew, M. (2017). Breast Cancer Detection Using Transfer Learning in Convolutional Neural Networks. *IEEE Applied Imagery Pattern Recognition Workshop (AIPR)*, 10.1109/aipr.2017.8457948.
- Gupta, K. & Chawla, N. (2020). Analysis of Histopathological Images for Prediction of Breast Cancer Using Traditional Classifiers with Pre-Trained CNN, *Procedia Computer Science*, 167, 878-889, 10.1016/j.procs.2020.03.427.
- He, Z., Chen, Z., Tan, M., Elingarami, S., Liu, Y., Li, T., Deng, Y., He, N., Li, S., Fu, J. et al. (2020). A review on methods for diagnosis of breast cancer cells and tissues. *Cell Proliferation Journal*, 53, 10.54097/hset.v41i.6802.

He, K. Zhang, X. Ren, S. and Sun, J. (2016). Deep residual learning for image recognition. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 770–778, 10.1109/CVPR.2016.90.

Hoeser, T. & Koenser, C. (2020). Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: *A Review-Part I: Evolution and Recent Trends. Remote Sensing*, 12, 1667; 10.3390/rs12101667.

Iesmantas, T. & Alzbutas, R. (2018). Convolutional capsule network for classification of breast cancer histology images, *In book: Image Analysis and Recognition Springer*, Berlin, 853-860.

İnik, Ö: & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, 6 (3), 85-104.

Jafari, S.H., Saadatpour Z., Salmaninejad, A., et al. (2018). Breast cancer diagnosis: imaging techniques and biochemical markers. *Journal of Cellular Physiology*, 233(7):5200-5213.

Jafarzadeh, S. Ghouschi, Ranjbarzadeh, R. Najafabadi, S.A. et al. (2021). “An extended approach to the diagnosis of tumor location in breast cancer using deep learning,” *Journal of Ambient Intelligence and Humanized Computing*, 14, 8487–8497, 10.1007/s12652-021-03613-y.

Jain, A. K. Mao, J. & Mohiuddin, K. M. (1996). "Artificial neural networks: a tutorial," in *Computer*, vol. 29, no. 3, 31-44, 10.1109/2.485891.

Kızrak, A. (2019). Ölçeklendirme ile CNN Modelinin Doğruluk ve Verimliliğini Artırma: EfficientNet. <https://ayyucekizrak.medium.com/%C3%B6l%C3%A7eklendirme-ile-cnn-modelinin-do%C4%9Fruluk-ve-verimlili%C4%9Fini-art%C4%B1rma-efficientnet-cb6f2b6512de> (Erişim Tarihi: 04.05.2023).

Madej-Czerwonka, B., Korga-Plewko, A. & Czerwonka, M. (2022). Modern breast cancer diagnostic methods. *Current Issues in Pharmacy and Medical Sciences*, Vol. 35, No. 1, Pages 1-5, 10.2478/cipms-2022-0001.

- Mahoro, E. & Akhloufi, M. A. (2022). Breast cancer classification on thermograms using deep CNN and transformers. *Quantitative InfraRed Thermography Journal*, 10.1080/17686733.2022.2129135.
- Marchiò, C., Reis-Filho, J.S. (2008). Molecular diagnosis in breast cancer. *Diagnostic Pathology*, 14(5):202-213.
- McCulloch, W.S., Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* 5, 115–133 (1943). 10.1007/BF02478259
- Mishra, V., Rath, S.K. & Mohapatra, D.P. (2023). Thermograms-based detection of cancerous tumors in breasts applying texture features, *Quantitative InfraRed Thermography Journal*, 10.1080/17686733.2023.2174341.
- National Cancer Institute (2023). Anatomy of the female breast (<https://www.cancer.gov/publications/dictionaries/cancer-terms/def/breast>).
- National Institute of Biomedical Imaging and Bioenergeeing (NIBIB). (Erişim tarihi: 09.05.2023)<https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri>
- Oyar, O. (2008). Magnetik Rezonans Görüntüleme (Mrg)'nin Klinik Uygulamaları ve Endikasyonları. *Harran Üniversitesi Tıp Fakültesi Dergisi*, 5(2),31-40.
- Özel, B.D., Özel, D., Özkan, F., Halefoğlu, A.M., Özer, Ö., Başak, M. (2015). BIRADS Ultrasonografi Solid Meme Lezyonlarında Biyopsi Öncesi Yeterli Fikir Verebilir Mi? *Ş.E.E.A.H. Tıp Bülteni*, 49(4):284-8.
- Öztürk, K. ve Şahin, M.E. (2018). Yapay Sinir Ağları ve Yapay Zekâya Genel Bir Bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Pareja, F., Marchiò, C., Reis-Filho, .JS. (2018). Molecular diagnosis in breast cancer. *Diagnostic Histopathology*, 24(2):71-82.

- Patterson, J. & Gibson, A. (2017). *Deep Learning: A Practitioner's Approach*. O'Reilly Media, 1st Edition, 530 pages.
- Ragab, D., Sharkas, M. & Attallah, O. (2019). Breast Cancer Diagnosis Using an Efficient CAD System Based on Multiple Classifiers. *Diagnostics*, 9, 165; 10.3390/diagnostics9040165.
- Rakhlin, A., Shvets, A., Iglovikov, V. & Kalinin, A.A. (2018). Deep Convolutional Neural Networks for Breast Cancer Histology Image Analysis. *International Conference Image Analysis and Recognition, ICIAR 2018: Image Analysis and Recognition*, 737–744.
- Resmî Gazete (2015). Kanser Bildirimi ve Kanser Kayıt Merkezleri Yönetmeliği, (Erişim tarihi: 01.05.2023), erişim adresi: <https://www.resmigazete.gov.tr/eskiler/2015/06/20150603.htm>
- Rouhi, R., Jafari, M., Kasaei, S. & Keshavarzian, P. (2015). Benign and malignant breast tumors classification based on region growing and CNN segmentation. *Expert Systems with Applications*, 42 (3), 990-1002, 10.1016/j.eswa.2014.09.020.
- Sayegh, H.E., Asdourian, M.S., Swaroop, M.N. et al. (2017). Diagnostic Methods, Risk Factors, Prevention, and Management of Breast Cancer-Related Lymphedema: Past, Present, and Future Directions. *Current Breast Cancer Reports* 9, 111–121. [10.1007/s12609-017-0237-8](https://doi.org/10.1007/s12609-017-0237-8).
- Singla, N., Dubey, K., Srivastava, V. (2018). Automated assessment of breast cancer margin in optical coherence tomography images via pretrained convolutional neural network. *Journal of Biophotonics*, 10.1002/jbio.201800255J.
- Solmaz, E. (2022). *Kadın Meme Anatomisi, Sağlık ve Bilim- Hemşirelik*. Efe Akademi, İstanbul.
- SuperDataScience Team (2018). Convolutional Neural Networks (CNN): Step 3 – Flattening. <https://www.superdatascience.com/blogs/convolutional-neural-networks-cnn-step-3-flattening> (Erişim Tarihi: 21.10.2022).

- Tan, M. & Le, Q.V. (2019). "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks", *Proceedings of the 36th International Conference on Machine Learning*, 97, 6105–6114.
- Tan, Y.J. Sim, K.S. Ting, F.F. (2017). Breast cancer detection using convolutional neural networks for mammogram imaging system. *2017 International Conference on Robotics, Automation and Sciences (ICORAS)*, 10.1109/icoras.2017.8308076.
- Torres-Galván, J.C., Guevara, Kolosovas-Machuca, E.S., Ocegüera-Villanueva, A., Flores, J.L. & González, F.J. (2021). Deep convolutional neural networks for classifying breast cancer using infrared thermography. *Quantitative InfraRed Thermography Journal*, 19:4, 283-294, 10.1080/17686733.2021.1918514
- Tuncer, M. (2009). *Ulusal Kanser Programı 2009-2015*. T.C. Sağlık Bakanlığı Kanserle Savaş Dairesi Başkanlığı: Yayın No 760.
- Türkiye Kanser İstatistikleri (2017). T.C. Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü, Ankara, 2021.
- Übeyli, E.D. (2007). Implementing automated diagnostic systems for breast cancer detection. *Expert Systems with Applications*, 33(4), 1054-1062, 10.1016/j.eswa.2006.08.005.
- Üstündağ, E. (2022). *Evrşimli Sinir Ağları, Transfer Öğrenme ve Destek Vektör Makineleri Kullanarak Akciğer Röntgen Görüntülerinden Covid-19 Sınıflandırması*. Yüksek Lisans Tezi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Ana Bilim Dalı, Afyonkarahisar.
- Wani, M. A., Bhat, F. A., Afzal, S., & Khan, A. I. (2020). Advances in Deep Learning. *Studies in Big Data*. Volume: 57, [10.1007/978-981-13-6794-6](https://doi.org/10.1007/978-981-13-6794-6).
- Weaver, O. & Leung, J.W.T. (2018). Biomarkers and imaging of breast cancer. *American journal of roentgenology*, 210(2):271-278.
- Von Schulthess, G.K., Steinert, H.C., Hany, T.F. (2006). Integrated PET/CT: current applications and future directions. *Radiology*, 238: 405-422. 10.1148/radiol.2382041977

- Yacim, J.A. & Boshoff, D.G.B. (2018). Impact of artificial neural networks training algorithms on accurate prediction of property values. *Journal of Real Estate Research*, 40(3):375-418, 10.1080/10835547.2018.12091505.
- Yu, S.N., Li, K.Y. & Huang, Y.K. (2006). Detection of microcalcifications in digital mammograms using wavelet filter and Markov random field model. *Computerized Medical Imaging and Graphics*, 30(3), 163-173.
- Zebari, D.A., Haron, H., Zeebaree, S.R., & Zeebaree, D.Q. (2019). Enhance the mammogram images for both segmentation and feature extraction using wavelet transform. *International Conference on Advanced Science and Engineering (ICOASE)*, 100–105.
- Zhang, D., Liu, Z. & Shi, X. (2020). Transfer Learning on EfficientNet for Remote Sensing image Classification. 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE), 2255–2258.
- Zuluaga-Gomez, J., Al Masry, Z., Benaggoune, K., Meraghni, S.& Zerhouni, N. (2021). A CNN-based methodology for breast cancer diagnosis using thermal images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 9:2, 131-145, 10.1080/21681163.2020.1824685.

ÖZGEÇMİŞ

Kişisel Bilgiler

Ad Soyadı : Z**** E*****
Uyruk : T.C.
Doğum Tarihi : **/0*/****
Telefon : 0 5*****7
E-posta : z*****c@eposta.mu.edu.tr

Eğitim

Alınan Derece	Aldığı Kurum/Üniversite	Mezuniyet Yılı
Lise	Körfez Atatürk Anadolu Lisesi	2015
Lisans	İstanbul Yeni Yüzyıl Üniversitesi Biyomedikal Mühendisliği	2020
Yüksek Lisans	Muğla Sıtkı Koçman Üniversitesi Yapay Zekâ Ana Bilim Dalı	2023

İş Tecrübesi

Yıl	Yer	Pozisyon/görev
2020-2023	İstanbul	Tıbbi Cihaz Firmasında Üretim Sorumlusu
2023- Halen	İzmir	İş Geliştirme Mühendisi

Yabancı Dil(ler)

Dil	Başlangıç	Orta (Almanca)	İleri (İngilizce)
Yazma		X	X
Konuşma		X	X
Anlama		X	X
Okuma		X	X

Bilimsel Faaliyetler

1. TÜBİTAK 2209-A kapsamında Yürüyüş Bozukluğunu Önleyici Ayakkabı Tasarımı.

Ek-1: Etik Kurul Onayı

MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ TIP VE SAĞLIK BİLİMLERİ ETİK KURULU - 1 (TIP) KARARI

Protokol No : 220061

Karar No : 49

Araştırma Yürütücüsü	Dr Öğr Üys İBRAHİM ÖNDER YENİÇERİ
Kurumu / Birimi	TIP FAKÜLTESİ / RADYOLOJİ
Araştırmanın Başlığı	Akciğer Bilgisayarlı Tomografisinde İnsidental Saptanan Meme Nodüllerinin Evrişimli Sinir Ağları İle Benign-Malign Olarak Sınıflandırılması
Başvuru Formunun Etik Kurula Geldiği Tarih	12.06.2022
Başvuru Formunun Etik Kurulda İncelendiği Tarih	14.06.2022
Karar Tarihi	05.07.2022

KARAR : **UYGUNDUR**

AÇIKLAMA :Beyan edilen veri formlarının dışına çıkmaması şartıyla araştırmanın uygulanabilirliği konusunda bilimsel araştırmalar etiği açısından bir sakınca yoktur.

Prof.Dr. Haşim OLGUN
Başkan

Doç.Dr. Cem ŞAHİN
Üye

Prof. Dr. Müesser ÖZCAN
Üye

Doç.Dr. Suzan DEMİR PEKTAŞ
Üye

Doç.Dr. Emine Tuğba ALATAŞ
Üye

Doç.Dr. Ozan GÖKDOĞAN
Üye

Doç.Dr. Hasan DELİKTAŞ
Üye

Bu belge elektronik imza ile imzalanmıştır.
Doğrulama adresi <https://etikkurulbasvuru.mu.edu.tr/dogrulama/BNKS9489>

