

T.C.
SİİRT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİSTOPATOLOJİK GÖRÜNTÜLERDEN DERİN ÖĞRENME TABANLI
MEME KANSERİ TEŞHİSİ

YÜKSEK LİSANS TEZİ

Abdulkerim ÇELİK
(223131002)

Bilgisayar Mühendisliği Anabilim Dalı

Dr. Öğr. Üyesi Cüneyt ÖZDEMİR

Aralık-2024
SİİRT

TEZ KABUL VE ONAYI

Abdulkerim ÇELİK tarafından hazırlanan “Meme Kanseri Histopatolojik Görüntü Sınıflandırması: Derin Öğrenme Uygulaması” adlı tez çalışması 26/11/2024 tarihinde aşağıdaki jüri tarafından oybirliği ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Yılmaz KAYA

.....

Danışman

Dr. Öğr. Üyesi Cüneyt ÖZDEMİR

.....

Üye

Dr. Öğr. Üyesi Yahya DOĞAN

.....

Yukarıdaki sonucu onaylarım.

Doç. Dr. Harun BEKTAŞ
Fen Bilimleri Enstitüsü Müdürü

ÖN SÖZ

Tez çalışmamı gerçekleştirdiğim süre içerisinde bilgi birikimini ve desteğini esirgemeyen değerli hocam Dr. Öğr. Üyesi Cüneyt ÖZDEMİR'e ve Abdurrezzak ÇELİK'e sonsuz teşekkür eder, saygılarımı sunarım.

Abdulkerim ÇELİK
SİİRT-2024



İÇİNDEKİLER

Sayfa

ÖN SÖZ	iii
İÇİNDEKİLER.....	iv
TABLolar DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	vii
KISALTMALAR VE SİMGELER LİSTESİ	viii
ÖZET.....	ix
ABSTRACT.....	x
1. GİRİŞ.....	1
1.1. Literatür Özeti.....	5
1.2. Çalışmanın Amacı ve Kapsamı.....	8
2. LİTERATÜR ARAŞTIRMASI	10
2.1. Derin Öğrenme	10
2.2. Tarihçe 10	
2.3. Yapay Sinir Ağları	11
2.3.1. Yapay sinir ağlarının genel özellikleri.....	12
2.3.2. Derin öğrenme yöntemleri ile sınıflandırma.....	13
2.4. Derin Öğrenme Mimarileri	14
2.4.1. Derin denetimli öğrenme	15
2.4.2. Yarı denetimli öğrenme	16
2.4.3. Deep unsupervised learning.....	16
2.4.4. Deep reinforcement learning	17
2.4.5. Derin öğrenme ağlarının türleri	18
2.4.6. Özyinelemeli sinir ağları.....	18
2.4.7. Yinelemeli sinir ağları (RNN)	19
2.4.8. Evrişimsel sinir ağları	20
2.4.9. Evrişim katmanı (Convolution)	22
2.4.10. Doğrusal olmayan katman (Non-Linearity Layer)	23
2.4.11. Havuzlama katmanı (Pooling Layer).....	23
2.4.12. Düzleştirme katmanı (Flattening Layer).....	24
2.4.13. Sınıflandırma katmanı (Classification Layer).....	25
2.4.14. Öğrenme aktarımı	26
2.4.15. Squeeze ve excitation bloğu	26
2.4.16. Performans kriterleri ve hesaplanması.....	27
3. MATERYAL VE METOT.....	29

3.1 Araştırma Modeli	29
3.2. Veri Toplama Süreci ve Veri Toplama Araçları.....	29
1.3.1. Tümör türleri ve özellikleri.....	32
4. BULGULAR VE TARTIŞMA.....	34
4.1. Meme Kanseri Histopatolojik Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması.....	34
4.2. Önerilen CNN Modelinin Yapısı	37
4.2.1. Özel convolutional neural network modeli.....	37
4.2.1.2. Katman: ikinci konvolüsyon katmanı	38
4.2.1.3. Katman: üçüncü konvolüsyon katmanı.....	38
4.2.1.4. Katman: dördüncü konvolüsyon katmanı	38
4.2.1.5. Katman: beşinci konvolüsyon katmanı.....	39
4.2.1.6. Son Katmanlar:	39
4.2.2. Modelin optimizasyonu ve performansı	40
5. SONUÇ	43
6. KAYNAKÇA.....	45
EKLER.	50
EK 1. Alan Yazında Çalışmalar.....	50
ÖZGEÇMİŞ	68

TABLULAR LİSTESİ

	<u>Sayfa</u>
Tablo 4.1. Modellerin eğitimi sırasında kullanılan hiperparametreler.....	35
Tablo 4.2. Transfer öğrenme modelleri performans sonuçları.....	36
Tablo 4.3. Model performans sonuçları	40



ŞEKİLLER LİSTESİ

	<u>Sayfa</u>
Şekil 2.1. Yapay sinir hücresinin yapısı	12
Şekil 2.2. Sinir ağı mimarisinin genel görünümü	14
Şekil 2.3. Derin öğrenme mimarileri	15
Şekil 2.4. RNN diagram	19
Şekil 2.5. Evrimsel sinir ağları sınıflandırma mimarisi	21
Şekil 2.6. Bir resmin convolution kernel ile kenarlarının bulunması	23
Şekil 2.7. Squeeze ve excitation mimarisi	27
Şekil 3.1. Meme kanseri görüntülemeleri	29
Şekil 3.2. Meme kanserinde histopatolojik görüntüler	30
Şekil 3.3. Büyütme oranlarına görüntü dağılımı	30
Şekil 3.4. Büyütme oranı ve histolojik alt tiplere göre dağılımı	33
Şekil 4.1. Önerilen model	39
Şekil 4.2. Önerilen modelin loss ve accuracy grafiği	41
Şekil 4.3. Önerilen modelin karmaşıklık matrisi	42

KISALTMALAR VE SİMGELER LİSTESİ

<u>Kısaltma</u>	<u>Açıklama</u>
CAD	: Bilgisayar Destekli Tanı
CNN	: Evrişimsel Sinir Ağları
FDA	: Food and Drug Administration (Amerikan Gıda ve İlaç Dairesi)
GAN	: Çekişmeli Üretici Ağ
GPU	: Grafik İşlemci Ünitesi
LSTM	: Uzun Kısa Süreli Bellek
MRI	: Manyetik Rezonans Görüntüleme
NLP	: Doğal Dil İşleme (Neuro Linguistic Programming)
RAAM	: Özyinelemeli Otomatik İlişkisel Bellek
RELU	: Doğrultulmuş Doğrusal Birim
RNN	: Yinelemeli Sinir Ağı
RvNN	: Özyinelemeli Sinir Ağı
SOB	: Cerrahi Açık Biyopsi
TSG	: Tüm Slay Görüntüleri, ing. Whole Slide Images – WSIs
X-RAY	: Röntgen Işınları
YSA	: Yapay Sinir Ağları

ÖZET

YÜKSEK LİSANS TEZİ

HİSTOPATOLOJİK GÖRÜNTÜLERDEN DERİN ÖĞRENME TABANLI MEME KANSERİ TEŞHİSİ

Abdulkerim ÇELİK

**Siirt Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Cüneyt ÖZDEMİR

2024, 68+X sayfa

Meme kanseri histopatolojik görüntülerinin doğru sınıflandırılması, erken teşhis ve etkili tedavi süreçlerinde kritik bir rol oynamaktadır. Bu tez çalışma, meme kanseri histopatolojik görüntülerinin sınıflandırılması amacıyla özel olarak tasarlanmış bir Convolutional Neural Network (CNN) modelinin geliştirilmesini ve performans değerlendirmesini kapsamaktadır. Araştırmanın ilk aşamasında, geniş veri kümeleri üzerinde önceden eğitilmiş transfer öğrenme modelleri değerlendirilmiştir. On bir farklı transfer öğrenme modeli kullanılmış ve öğrenme oranı, kayıp fonksiyonu, optimizasyon algoritması ve veri artırma teknikleri gibi parametreler titizlikle optimize edilmiştir. Xception ve InceptionV3 modelleri sırasıyla %89,89 ve %92,17 doğruluk oranları ile en yüksek performansı göstermiştir. Buna karşılık, MobileNetV2 ve EfficientNetV2B1 modelleri daha düşük başarı oranlarına sahip olmuştur. Transfer öğrenme modellerinden elde edilen sonuçlar doğrultusunda, sınıflandırma performansını daha da artırmak amacıyla özel bir CNN modeli tasarlanmıştır. Bu model, sıkıştırma-uyarı (squeeze-excite) mekanizmaları ve grup normalleştirme teknikleri ile optimize edilmiştir. Geliştirilen CNN modeli %93,93 doğruluk, %93,93 hassasiyet ve %93,98 F1 puanı ile transfer öğrenme modellerini geride bırakarak üstün bir performans sergilemiştir.

Anahtar Kelimeler: Meme kanseri, Convolutional Neural Network modeli, hiperparametre, transfer öğrenme

ABSTRACT

MS THESIS

**DEEP LEARNING-BASED BREAST CANCER DIAGNOSIS USING
HISTOPATHOLOGICAL IMAGES**

Abdulkerim ÇELİK

**The Graduate School of Natural and Applied Science of Siirt University
The Degree of Master of Science
In Computer Engineering**

Supervisor: Asst. Prof. Cüneyt ÖZDEMİR

2024, 68+X Pages

This The accurate classification of breast cancer histopathological images plays a crucial role in early diagnosis and effective treatment processes. This thesis focuses on the development and performance evaluation of a custom-designed Convolutional Neural Network model for the classification of breast cancer histopathological images. In the initial phase of the research, pre-trained transfer learning models were evaluated on large datasets. Eleven different transfer learning models were utilized, and parameters such as learning rate, loss function, optimization algorithm, and data augmentation techniques were meticulously optimized. Among these models, Xception and InceptionV3 demonstrated the highest performance with accuracy rates of 89,89% and 92.17%, respectively. In contrast, MobileNetV2 and EfficientNetV2B1 exhibited lower performance levels. Based on the results obtained from transfer learning models, a custom CNN model was designed to further enhance classification performance. This model was optimized using squeeze-excite mechanisms and group normalization techniques. The developed CNN model outperformed the transfer learning models with an accuracy of 93,93%, precision of 93,93%, and an F1 score of 93,98%, demonstrating superior performance.

Keywords: breast cancer, Convolutional Neural Network modeli, hyperparameter, transfer learning

1. GİRİŞ

İnsan beyninin görüntüler aracılığıyla bilişsel süreçler yürütmesi ve bu görüntülere anlam yüklemesi, iletişimin temel unsurlarından biridir. Görsel verilerin, iletişimde sözlü verilere kıyasla çok daha güçlü bir etki yarattığı bilinmektedir. Beynin görsel verilere verdiği tepki, sözlü verilere kıyasla çok daha güçlü olup, bu da görüntülerin iletişim açısından taşıdığı kritik önemi vurgulamaktadır (Chitradevi ve Srimathi, 2014). Günümüzde, bu görsel verilerin etkili bir şekilde işlenmesi ve anlamlandırılması, dijital teknolojiler aracılığıyla mümkün hale gelmiştir. Özellikle görüntü işleme, dijital görüntülerin çeşitli yazılımlar kullanılarak düzenlenmesi, iyileştirilmesi ya da analiz edilmesi sürecini ifade eder. Bu süreç, görüntülerden anlamlı bilgilerin çıkarılmasını veya yeni görüntülerin üretilmesini amaçlar. Görüntü işleme teknikleri, tıp, tarım, robot bilimi, güvenlik ve endüstri gibi birçok alanda kullanılmakta olup, operasyonel süreçlerin daha hızlı, etkin ve maliyet açısından verimli yürütülmesine katkı sağlamaktadır. Ayrıca, teknolojideki ilerlemelerle birlikte, görüntü işleme teknikleri yeni alanlarda da kendine yer bulmakta ve bu alanların verimliliğini artırmaktadır.

İnsan beyninin öğrenme süreçlerinin taklit edilmesi, yapay zeka alanında önemli bir araştırma konusudur. Yapay zeka (YZ), bilgisayar sistemlerinin veya makinelerin insan benzeri zeka ve bilişsel işlevleri taklit etmesini amaçlayan bir teknoloji ve bilim dalıdır. Bu sistemler, öğrenme, düşünme, problem çözme, anlama ve karar verme gibi insan zihnine özgü işlevleri simüle etmeye çalışır. Yapay zeka, bu amaca ulaşmak için matematiksel modelleme, algoritmalar, veri analizi, makine öğrenmesi ve derin öğrenme gibi çeşitli teknikleri kullanır. Özellikle, insan beyninin öğrenme süreçlerinin bir modelini oluşturmada yapay sinir ağları önemli bir yöntem sunmaktadır. Bu ağlar, beynin bilişsel süreçlerini taklit ederek çok katmanlı yapılarıyla veri işleme görevlerini yerine getirir ve derin öğrenme tekniklerinin temelini oluşturur.

Derin öğrenme algoritmaları, özellikle çoklu soyutlama katmanları aracılığıyla veri temsillerini daha verimli hale getirir. Bu özellik, konuşma tanıma, görsel nesne algılama, ilaç keşfi gibi karmaşık problemleri çözme konusunda derin öğrenmenin etkinliğini kanıtlamaktadır. Yapılan çalışmalar, özellikle görüntü, video, konuşma ve ses işleme alanlarında evrimsel sinir ağları ile geliştirilen derin öğrenme algoritmalarının başarılı sonuçlar verdiğini göstermiştir (LeCun ve ark., 2015). Bilgisayarlı görme

uygulamalarında, derin öğrenme tekniklerinin karmaşık sorunlara etkili çözümler sunduğu ve bu alanda önemli başarılar elde edildiği kanıtlanmıştır. Bu teknolojik ilerlemeler, yalnızca bilgisayarlı görme gibi alanlarla sınırlı kalmamış, tıbbi uygulamalarda da büyük bir etki yaratmıştır. Teknolojinin hızlı gelişimi, tıp alanında kullanılan cihazların yaygınlaşmasını sağlamakta ve hem pratisyen doktorların hem de araştırmacıların teşhis ve tedavi süreçlerindeki verimliliğini artırmaktadır..

Bu bağlamda, kanser gibi oldukça öldürücü bir hastalıkla mücadelede yapay zeka tekniklerinin önemi giderek artmaktadır. Oldukça öldürücü bir hastalık olan kanser, dünya çapında ölüm nedenleri arasında ikinci sıradadır (Deniz ve ark., 2018; Cortes ve ark., 2020). Meme, deri, akciğer, kolon, prostat ve lenfoma gibi 100'e yakın farklı türü bulunan kanser hastalığı, ismini köken aldığı dokuya göre sınıflandırılmaktadır (Deniz, ve ark., 2018; Grixti ve Ayers, 2020). Kanser vücudu etkilediğinde kan veya lenf yolu ile metastaz yapabilir ve organ hasarına yol açabilmektedir. Dünya çapında 2023 yılında yaklaşık olarak 19.3 milyon yeni kanser vakası ve yaklaşık 10 milyon kanser ilişkili ölüm meydana gelmiştir. Dünya Sağlık Örgütü'nün 185 ülkede yaptığı çalışma sonucunda elde ettiği verilere dayanarak 2040 yılında bu sayının 30 milyon üzerine çıkması beklenmektedir (Şen, 2023). Bu nedenle, kanser tanısının erken dönemde konulması hayatta kalma oranını iyileştirmesi için önemli bir unsur haline gelmektedir.

Meme kanseri, meme dokusundaki hücrelerin kontrolsüz bir şekilde çoğalması ile ortaya çıkan bir hastalıktır. Kadınlarda daha sık görülmekle birlikte, nadiren erkeklerde de rastlanır. Dünya genelinde kadınlar arasında en yaygın kanser türü olan meme kanseri, erken teşhis ve tedavi yöntemlerindeki gelişmeler sayesinde hayatta kalma oranlarının artmasına rağmen hala önemli bir halk sağlığı sorunu olmaya devam etmektedir (Ewertz ve Jensen, 2011).

2020 yılında dünya çapında yaklaşık 2.3 milyon yeni meme kanseri vakası teşhis edilmiş ve 684.996 ölüm kaydedilmiştir. Bu oran, meme kanserini dünya genelindeki kanser ölümlerinin %6,7'si ile ciddi bir tehdit haline getirmektedir. Meme kanseri, özellikle 159 ülkede kadınlar arasında en sık teşhis edilen kanser türü olup, kansere bağlı ölümler arasında da önemli bir yer tutmaktadır. Bağırsak ve akciğer kanserleri ise meme kanserini izleyen diğer yaygın kanser türleridir (Sung ve ark., 2021).

Meme kanserinin teşhisi, genellikle fiziksel muayene, görüntüleme yöntemleri ve biyopsi gibi bir dizi tanı aracının birlikte kullanılmasıyla gerçekleştirilir. Tanı sürecinin her aşaması, hastalığın erken tespiti ve tedavi planlaması açısından büyük öneme sahiptir.

En sık başvuru alan tanı yöntemleri arasında mamografi, ultrason, manyetik rezonans görüntüleme ve biyopsi yer alır.

Fiziksel muayene, meme kanseri şüphesi olan hastalarda ilk adım olarak yapılır. Bu muayene sırasında memedeki anormallikler, şişlikler veya cilt değişiklikleri gibi belirtiler araştırılır. Meme kanseri çoğunlukla yumru şeklinde kendini göstermekle birlikte, meme cildinde çekilme, meme ucu akıntısı veya ağrı gibi belirtiler de yaygın olarak görülmektedir (Zgajnar, 2017).

Mamografi, meme kanseri teşhisinde en sık kullanılan görüntüleme yöntemidir. Düşük doz X-ışını kullanarak meme dokusunun detaylı incelenmesini sağlar ve kanserin erken evrede tespiti için etkili bir araçtır. Tarama mamografisi, belirti göstermeyen bireylerde bile kanserin erken teşhis edilmesine yardımcı olurken, tanısal mamografi ise spesifik belirtiler varlığında daha detaylı incelemeler için kullanılır. Ancak mamografinin yanlış pozitif sonuçlar verme olasılığı bulunmaktadır, bu da gereksiz biyopsilere yol açabilir (Seely ve Alhassan, 2018).

Ultrason, mamografi ile birlikte kullanılarak meme dokusunun daha detaylı incelenmesini sağlar. Yüksek frekanslı ses dalgaları ile çalışan ultrason, özellikle yoğun meme dokusuna sahip hastalarda mamografinin eksik kalabileceği durumlarda faydalıdır. Bununla birlikte, ultrason operatör yetkinliğine bağlıdır ve bazı yapılarda görüntüleme zorlukları yaratabilir (Hooley ve ark., 2013). Ancak mamografi ile kombine edildiğinde, erken teşhis oranlarını artırdığı gösterilmiştir (Zhang ve ark., 2019).

Manyetik rezonans görüntüleme, meme kanseri teşhisinde tümörlerin detaylı olarak incelenmesine olanak tanır. MRI, diğer yöntemlerin tespit edemediği tümörleri gösterebilme kabiliyeti ile tanı sürecine önemli katkılar sunar (Lehman ve Schnall, 2005).

Meme biyopsisi ise kanserin kesin teşhisi için en kritik adımdır. Biyopsi sırasında alınan doku örnekleri mikroskop altında incelenerek hücresel seviyede analiz edilir. Biyopsi yöntemleri arasında ince iğne aspirasyonu, çekirdek iğne biyopsisi ve vakum destekli biyopsi yer alır. Çekirdek iğne biyopsisi, daha büyük örnekler alarak daha kesin sonuçlar sunarken, vakum destekli biyopsi ise lezyonun çıkarılması imkânını sağlayarak tanı doğruluğunu artırır (Park ve Kim, 2011; Park ve Hong, 2014).

Meme kanseri gelişiminde birçok risk faktörü rol oynamaktadır. Yaş en belirgin risk faktörüdür; meme kanseri vakalarının büyük çoğunluğu 40 yaş üzeri kadınlarda teşhis edilir ve vakaların yarısı 50-69 yaş aralığında görülür (Kamińska ve ark., 2015; Rojas ve Stuckey, 2016). Aile öyküsü de önemli bir risk faktörüdür; özellikle birinci derece akrabalarında meme kanseri olan bireylerde risk daha yüksektir. Ayrıca BRCA1

ve BRCA2 genlerindeki mutasyonlar da meme kanseri riskini artıran genetik faktörlerdendir (Majeed ve ark., 2014). Hormonlara maruz kalma süresi de riski etkiler; erken yaşta adet görmeye başlamak veya geç menopoza girmek bu riski artırır (Collaborative Group on Hormonal Factors in Breast Cancer, 2012). Yaşam tarzı ise kontrol edilebilir risk faktörlerinden biridir. Alkol tüketimi, obezite ve sigara içmek meme kanseri riskini artırabilen başlıca yaşam tarzı faktörleri arasındadır (Dossus ve ark., 2014; Arnold ve ark., 2015; Sun ve ark., 2017).

Şüpheli bir vakanın değerlendirilmesi ve değerlendirme sonrası tanının doğru olması hayati öneme sahiptir. Tanı süreci kişisel ve aile tıbbi geçmişinin değerlendirilmesi, laboratuvar testlerinin yapılması, görüntüleme (MRI, X-Ray gibi) ve biyopsiyi içermektedir. Özellikle mikroskopik inceleme, kanser teşhisinde birincil yöntem olarak kullanılmaktadır. Histolojik analiz, hastalığın ortaya çıkış şeklinin tespiti, tanı koyma ve evresinin tespitinde yardımcı olmaktadır (Gupta ve Madoff, 2007; He ve ark., 2012; Li ve ark., 2021).

Tarihsel olarak kanserin teşhisi, tüm slayt doku görüntü (TSG, ing. Whole Slide Images - WSIs) kesitlerinin mikroskop altında incelenmesine dayanmaktadır. Ancak doku kesitlerinin dijitalleştirilmesi ve dijitalleştirilen kesitlerin hesaplamalı görüntü analizi yöntemlerinin gelişimi ile birlikte birincil tanı için FDA onayına olanak sağlamıştır (Evans ve ark., 2018; Barisoni ve ark., 2020).

TSG, büyük boyutu, değişken renk yoğunluğuna sahip olması ve pataloglar tarafından birebir olarak kapsamlı incelemesine ihtiyaç duyması nedeniyle kanser teşhisinde beraberinde çeşitli zorluklar getirmektedir. Patalogların genellikle tek bir hasta için birden fazla TSG'yi analiz etmesi gerekmektedir. Pataloglar açısından değerlendirildiğinde, bu durum zaman alan, yoğun emek gerektiren bir işlem olup, hata payı yüksek bir görevdir. TSG derecelendirilmesi, Patalogların bilgi, deneyim ve öznel bakış açısı ile değişkenlik gösterebilmektedir (Komura ve Ishikawa, 2018; Dimitriou, Arandjelović ve Caie, 2019; Salvi ve ark., 2020). Bu durum bilgisayar destekli tanı (CAD) tekniklerine olan ihtiyacı derinleştirmektedir.

CNN gibi derin öğrenme tekniklerini içeren CAD sistemleri son yıllarda umut vaat eden çözümler sunmaktadır. Uygulamalar ile görsel tanıma görevlerinde başarılarını kanıtlamış olan CNN'ler, TSG'lerin analizlerinde de kullanılabilir. Ancak TSG analizlerinin en büyük zorluğu, doku kompozisyonu ve heterojenliği ile görüntü karmaşıklığıdır (Gurcan ve ark., 2009; He ve ark., 2012; Komura ve Ishikawa, 2018; Otálora ve ark., 2021). Her ne kadar CAD sistemlerinin değerlendirmeleri subjektif ve

parametre ayarlarına bağılı olarak deęişkenlik gösteriyor olsa dahi hızlı ve tutarlı sonuçlar sunması yönüyle TSG yorumlamalarında giderek artan talebin karşılanmasında önemli rol almaktadır. Akademik çalışmalar sonucunda elde edilen bulgular ve patoloji alan uzmanlarının işbirliği sonucunda CAD'lerin araştırılması teşvik edilmektedir (He ve ark., 2012; Hinz ve ark., 2018; Barisoni ve ark., 2020; Bacanin ve ark., 2020).

1.1. Literatür Özeti

Literatürde yapılan araştırmalar sonucunda meme kanserinin derin öğrenme teknikleri ile incelendięi çalışmalar Ek 1 'de verilmiştir.

Kendi içinde büyük bir yükü oluşturan meme kanseri görüntülerinin değerlendirilmesi ve sınıflandırılması süreci, araştırmacılar tarafından incelenen bir alan olmuştur. Veta ve ark. (2014), meme kanseri tespiti için histopatoloji görüntülerinin kullanılmasındaki zorluklara değinmiş ve bu alandaki ilerlemelere odaklanan bir çalışma gerçekleştirmiştir. Bu konuya değinen ilk çalışma olması yönüyle değerli bir çalışmadır. Görüntü işleme tekniklerinin gelişimine rağmen histopatoloji numunelerinin hazırlanması ve dijital ortama aktarımındaki standartların oluşmadığından bahsedilebilir. Araştırmacıların uzun yıllardır bu alanda gerçekleştirdikleri çalışmaları genel olarak değerlendirildiğinde;

Bacha ve Taouali (2022), Meme kanseri teşhisi üzerine yaptıkları çalışmada, diferansiyel evrim algoritması tarafından kolaylaştırılan parametre optimizasyonu ile Radyal Tabanlı Fonksiyon Çekirdeęi Ekstrem Öğrenme Makinesi (RTF-ÇEÖM) algoritmasını kullanmışlardır. En ilişkili öznelikleri seçmek amacıyla Çekirdek Temel Bileşen Analizi yöntemini (KPCA) uygulamışlardır. Çalışmalarında doğrulama için Mamografik Görüntü Analizi Derneęi (MIAS) ve Wisconsin Meme Kanseri Veritabanından (WBCD) alınan veri kümeleri kullanılmıştır.

Dai ve ark. (2018), sınıflandırma doğruluğunu artırmak için zayıf sınıflandırıcılardan gelen çıktıları birleştirerek Rastgele Orman (RF) ile topluluk öğrenmeyi araştırmıştır. Kabiraj ve ark.(2020), meme kanseri tahmini için Extreme Gradient Boosting (EGB) ve RF'yi karşılaştırmış ve burada RF, EGB'ye kıyasla üstün doğruluk (%74,73) sergilemiştir.

Ara ve ark. (2021), makine öğrenimi algoritmalarının WBCD'deki performansını değerlendirerek SVM ve RF'nin %96,5'lik en yüksek doğruluğuna ulaşmıştır.

Naji ve ark. (2021), WBCD'de birden fazla sınıflandırıcıyı analiz etmiş; SVM, %97,2'lik bir doğrulukla diğerlerinden daha iyi performans gösterdiğini tespit etmiştir.

Shukla ve ark. (2017), bir dizi algoritma kullanarak ve Rotation Forest algoritmasıyla en yüksek doğruluğu elde ederek meme histopatolojik görüntülerinin segmentasyonunu gerçekleştirmiştir.

Karthiga ve ark. (2018), hücre çekirdeklerinin segmente edilmesi yolunu seçmişler. Segmentasyon amacıyla k-means kümeleme uygulanmış ve elde edilen görüntüye Discrete Wavelet Transform (DWT) kullanılmıştır. Ardından Coiflets adı verilen dalgacık dönüşümü gerçekleştirilmiştir. Önerdikleri bu yöntem sonucunda SVM sınıflandırması %93,3 doğruluk oranına ulaşmıştır.

Mukkamala ve ark. (2018), Principal Component Analysis Network (PCANet) adı verilen basit ancak etkili bir öğrenme çerçevesi kullanmış olup öz nitelikleri buradan elde etmişlerdir. Bununla beraber renk bilgisine dayalı olan öz niteliklerin sağlanması amacıyla renkler LAB renk uzayına ayrılmaktadır ve her bir bileşen için temel görüntüleri veren kademeli PCA gerçekleştirilmektedir. Bu görüntülerden renk, açısız ve norm desen görüntüleri oluşturulmaktadır. Çıkarılan özellikler SVM sınıflayıcıya verilmektedir. Yapılan deneysel çalışmada 100x büyütme için %97 doğruluk elde edilmiştir.

Pratiher ve ark. (2018), yarı izometrik topolojik uzayın manifold ile kodlanmış görüntülerin çift yönlü LSTM (Bi-LSTM) ile sınıflandırılmasını önermişlerdir. Önerdikleri çerçeve ile elde edilen nokta bulutları, karmaşık uzaysal bağımlılıkların anlaşılması amacıyla Bi-LSTM tekrarlayan sinir ağına (RNN) beslenmektedir. Çalışmada %97.2'lik ortalama sınıflandırma başarısına ulaşılmıştır.

Elelimy ve ark. (2018), Tamamlanmış Yerel İkili Örüntü (CLBP), Tekil Değer Ayrışımı (SVD), Gabor Filtresi, Dalgacık Dönüşümü ve Destek Vektör Makineleri sınıflandırıcısına (SVM) dayanan hibrit bir özellik çıkarıcıya dayalı bir sınıflandırma sistemi sunmuş olup bunun sonucunda %96.63 başarı elde etmiştir.

George ve ark. (2019), sıfırdan bir CNN ağının tasarlanmasının çok fazla eğitim verisi gerekliliğini vurgulayarak önceden eğitilmiş CNN'leri kullanmıştır. ResNet18, ResNet50 ve AlexNet modellerinden elde edilen öz nitelikler normalizasyon havuzları aracılığı ile birleştirilmiş ve sınıflandırma için SVM kullanılmıştır. SVM sınıflandırması sonucunda önerilen yöntem ile %96.88 başarı elde edilmiştir.

Man ve ark. (2020), DenseNet121-AnoGAN adlı yeni bir yaklaşım önermişlerdir. Önerilen yaklaşım temel olarak iki bölümden oluşmaktadır. İlk bölümde hatalı etiketlenmiş yamaların tespiti amacıyla Üretken Rakip Ağlar (AnoGAN) kullanılmıştır. İkinci bölümde DenseNet modelinin kullanılmıştır. Çalışmada elde edilen sonuçlar 5 katlı çapraz doğrulama ile değerlendirilmiş ve %99,13'lük başarı elde edilmiştir.

Janney ve ark. (2023), meme kanserinin seviyesini tespit etmek amacıyla K-mean temelli kümeleme segmentasyonu, öznitelik çıkarımı ve sınıflandırma kullanmıştır. Segmente edilmiş bölgeler içinden korelasyon, homojenlik kontrast ve local ikili modeller (LBP) gibi öznitelikler elde edilmektedir. Elde edilen öznitelikler AlexNet ve GoogLeNet derin öğrenme mimarileri ile karşılaştırılmıştır. Gerçekleştirilen çalışma sonucunda AlexNet sınıflandırma yöntemi ile %100 başarı sağlandığı belirtilmiştir.

Spanol ve ark. (2016), CNN'yi eğitime tabi tutmak amacıyla görüntülerden yama çıkartımı ve elde edilen bu yamaların nihai sınıflandırılması sürecine girdi olarak birleştirilmesine dayanan bir yöntem önermiştir. Çalışmada odaklanılan nokta, yüksek çözünürlükte olan görüntülerin girdi olarak kullanılmasından kaçınılarak yamalar şeklinde görüntünün aktarılması ve böylelikle hesaplamalarda yüksek maliyetten kaçınılmıştır.

Song ve ark. (2017), ImageNet üzerinde eğitilmiş olan VGG-VD modelinden elde edilen özelliklerin transfer learning kullanılarak Fisher vektörlerine adapte edilmesi yöntemini kullanmıştır.

Han ve ark. (2017), BreakHis veri setine yönelik çalışmaların ikili sınıflandırmaya yönelik çalışmalarına eleştiri getirmiştir. Buna karşılık olarak görüntülerden alt kanser türlerine yönelik (Ductal carcinoma, Fibroadenoma, Lobular carcinoma vb.) sınıflandırma çalışması gerçekleştirmiştir. Sınıf yapısına dayalı bir CNN mimarisi önerilmiş olup çoklu sınıf başarıları %93.2 olarak belirtmişlerdir. Bununla beraber ikili sınıflandırma sonuçlarını da paylaşan araştırmacılar hasta bağımsız olarak %96.9'luk bir başarı elde etmişlerdir.

Bardou ve ark. (2018), elle çıkarılmış öz nitelikler ve CNN mimarisi karşılaştırması yoluna gitmişlerdir. Elde ettikleri sonuçlara göre CNN mimarisinin daha başarılı olduğu yönünde idi. Bununla beraber çalışmada çoklu sınıf ve ikili sınıf değerlendirmesi gerçekleştirilmiştir. Çoklu sınıf sonuçlarının önceki çalışmalara göre düşük kaldığı ancak ikili sınıflandırmanın %98.33'lük başarı ile literatürdeki sonuçları yakaladığı ifade edilmiştir.

Jonnalagedda ve ark. (2018), kanser sınıflandırması için NuView adını verdikleri Gauss modellerine dayalı kümeleme yöntemi kullanmışlardır. Kümelemedeki temel amaç olarak hücre çekirdeklerinin kümelenmediği alanların tespit edilmesi ve tümörün nerede yerleşik hale geldiğinin anlaşılması amaçlanmıştır. Evrişim mimarisinin dikkatine sunulan yerel belirteçlerin başarıyı arttırdığı tespit edilmiştir. Çalışmada MVPNet kullanılmış ve %92,2'lik başarı raporu edilmiştir.

Liu ve ark. (2023), özellik çıkarma ve tahmin için transfer öğrenmeyi entegre eden ve çok sınıflı sınıflandırma için etkileyici bir %98,29 doğruluk elde eden İşbirliğine Dayalı Transfer Ağını (CTransNet) önermiştir.

Chowdhury ve ark. (2022), erken kanser tespitinde %99,58'lik yüksek bir doğruluk oranı sergileyen ResNet10 ile transfer öğrenmeyi kullanmıştır.

Alzubaidi ve ark. (2020), biyopsi görüntü sınıflandırması için transfer öğrenmeyi kullanmış ve dört sınıflı bir sınıflandırma yaklaşımıyla %97,4'lük sağlam bir doğruluk sergilemiştir.

Alom ve ark. (2019), IRRCNN adını verdikleri bir model tanıtmışlardır. Bu model Inception Network (Inception-v4), Residual Network (ResNet) ve Recurrent Convolutional Neural Network (RCNN) birleşiminden oluşmaktadır. Gerçekleştirilen çalışmada ikili sınıflandırmada %99.05 başarı sağlanırken çoklu sınıflandırmada %98.59 başarı rapor edilmiştir.

1.2. Çalışmanın Amacı ve Kapsamı

Histopatoloji, temel amacı normal, kötü huylu ve iyi huylu hücre yapılarını ayırt etmek amacıyla hastalık belirtileri gösteren organ, doku veya hücrelerin mikroskopik incelenmesidir. Histopatolojik inceleme için doku elde etme yöntemi olan biyopsi yaygın olarak kullanılmaktadır ve cerrahi açık biyopsi baskın yöntemdir. SOB'de görüntülemeyle tespit edilen ve tel ile tanımlanan şüpheli alanın bir kısmı veya tamamı cerrahi olarak çıkarılır (Fejzullahu ve Güney, 2020). Meme biyopsilerinde, özellikle dokunun mikroyapıları, görsel muayene ile kesin tanıyı koyan patologlar tarafından histolojik olarak değerlendirilir (Gazioğlu, ve ark., 2009). Ancak bu aşamada patoloğun deneyimi, dikkati, yorgunluğu gibi faktörler nedeniyle yanlış tanıya eğilim artar. İnsan beyninin bilişsel süreçlerinden ilham alan derin öğrenme yöntemlerinin entegrasyonu, hassas ve gelişmiş kanser tespiti için gereklidir.

Bu çalışma, çeşitli transfer öğrenme yöntemlerini kullanarak histopatolojik meme kanseri görüntülerinin sınıflandırılmasında önceden eğitilmiş evrimsel sinir ağlarından yararlanmayı amaçlamaktadır. Araştırma, BreakHis veri kümesini kullanmakta ve uygulama ortamı olarak Google Collaboratory (Colab) Notebook ile birlikte Python programlama dilini kullanmaktadır. Bulut destekli bir platform olan Colab, ücretsiz GPU desteği sağlayarak kullanıcıların veri kümelerini Drive'a yüklemesine ve doğrudan bağlantı kurmasına olanak tanımaktadır. Ayrıca Colab, makine öğrenimi araştırmalarını

ve çalışmalarını kolaylaştırmak için tasarlanmış bulut tabanlı bir Jupyter Notebook ortamı olarak hizmet vermektedir.

Transfer öğrenme modellerinin değerlendirilmesinin ardından, sınıflandırma performansını daha da iyileştirmek için özel bir CNN modeli geliştirilmiştir. Bu model, özellik çıkarımını ve model istikrarını artırmak amacıyla sıkıştırma mekanizmaları ve grup normalizasyonu gibi gelişmiş teknikleri içermektedir. Mimari, her birinin batch normalizasyon ve ReLU etkinleştirme fonksiyonları tarafından izlenen çoklu konvolüsyon katmanlarından oluşmaktadır. Bu özgün yaklaşım, farklı transfer öğrenme modelleri ile karşılaştırılarak sınıflandırma sonuçlarına etkisi detaylı olarak analiz edilmiştir.



2. LİTERATÜR ARAŞTIRMASI

2.1. Derin Öğrenme

Derin öğrenme, verilerin çoklu düzeylerdeki temsillerinin öğrenilmesi amacıyla otomatik özellik çıkarım modellerinin oluşturulmasına dayanan bir makine öğrenmesi yöntemidir. Bu yaklaşım, karmaşık veri yapılarının öğrenilmesi için farklı katmanlardan oluşan derin yapay sinir ağlarını (DYSA) kullanır. Derin öğrenme, çeşitli alanlarda önemli başarılar elde etmiştir. Örneğin, görüntü tanıma (He ve ark., 2016), nesne tanıma ve nesne tespiti (Redmon ve ark., 2016), tıbbi görüntü analizi (Kaya ve Kuncan, 2022), ilaç keşfi ve genomik (Eraslan ve ark., 2019) gibi alanlarda etkin bir şekilde uygulanmıştır.

Derin öğrenme, özellikle büyük veri kümelerinde karmaşık yapıları keşfetmek amacıyla geri yayılım (backpropagation) algoritmasını kullanır. Bu algoritma, modelin hata oranını minimize etmek için ağırlıklarını güncelleyerek öğrenme sürecini yönetir. İlk olarak Kelley (1960) ve daha sonra Lecun ve arkadaşları (1989) tarafından geliştirilen bu yaklaşım, günümüzün derin öğrenme sistemlerinin temelini oluşturur.

Görüntü, video, ses ve konuşma işleme alanlarında DYSA ile elde edilen yüksek performans, bu algoritmaların potansiyelini ortaya koymaktadır. Tekrar eden sinir ağları ise ardışık veriler içeren problemleri çözmekte kullanılır, örneğin, metin ve konuşma verilerinin işlenmesi gibi. Derin öğrenme, veri madenciliği, doğal dil işleme, yapay zekâ ve robotik gibi alanlarda hem günümüzde hem de gelecekte etkisini sürdürmeye devam edecektir (Lecun ve ark., 2015).

Bu alandaki gelişmeler, birçok farklı disiplinin işleyişini dönüştürmüş ve verimliliği artırmıştır. Özellikle yüksek hacimli veri setlerinin karmaşık örüntülerini öğrenme ve anlamlandırma kapasitesi, derin öğrenmenin diğer makine öğrenimi yaklaşımlarından ayrılmasını sağlamıştır.

2.2. Tarihçe

Kapsam olarak daha geniş olan makine öğreniminin bir alt alanı olarak kendine yer bulan derin öğrenme, özellikle “Büyük veri”nin ortaya çıkardığı veri hacmine bir yerde yanıt olarak çok önemli bir paradigmadır. Geleneksel makine öğrenimi yaklaşımları değerlendirildiğinde, sürekli gelişen veri ortamı ile başa çıkmasında ortaya

koyduğu yetersizlikleri ve azalan etkinliđi, derin öğrenmenin ön plana çıkışını hızlandırmıştır.

Özellikle karmaşık sinir ađı mimarileri ve kapsamlı veri kümelerinden karmaşık modellerin ayırt edilmesi ile ifade edilen derin öğrenme, gerek performans gerekse başarı sonuçları açısından geleneksel makine öğrenmesi yöntemlerini önemli ölçüde geri bırakmıştır.

Derin öğrenme, temel olarak çok katmanlı Yapay Sinir Ağlarından (YSA) oluşmaktadır. YSA ve derin öğrenme, 1990'lı yılların başlarında sınırlı miktardaki veri setleri, işlemci arabirimlerinin yetersiz kapasitesi nedenleri başta olmak üzere uygun olmayan başlatma teknikleri ve kesinlik kazandırmayan aktivasyon fonksiyonları faktörlerinden kaynaklı olarak durgunluk dönemi ile karşılaşmıştır. Teknolojik gelişmelerin ortaya çıkışı, özellikle Grafik işleme birimlerinin (GPU) daha aktif olması YSA ve derin öğrenme alanında 2000'li yıllarda yeniden hareketlenmenin gerçekleşmesini sağlamıştır. Çalışmaların artışıdaki temel faktör GPU kapasitelerinin hesaplama yeteneklerini arttırması ve sığ mimarilerden derin mimarilere geçişte sinir ağlarının optimizasyonuna izin vermesidir.

2.3. Yapay Sinir Ağları

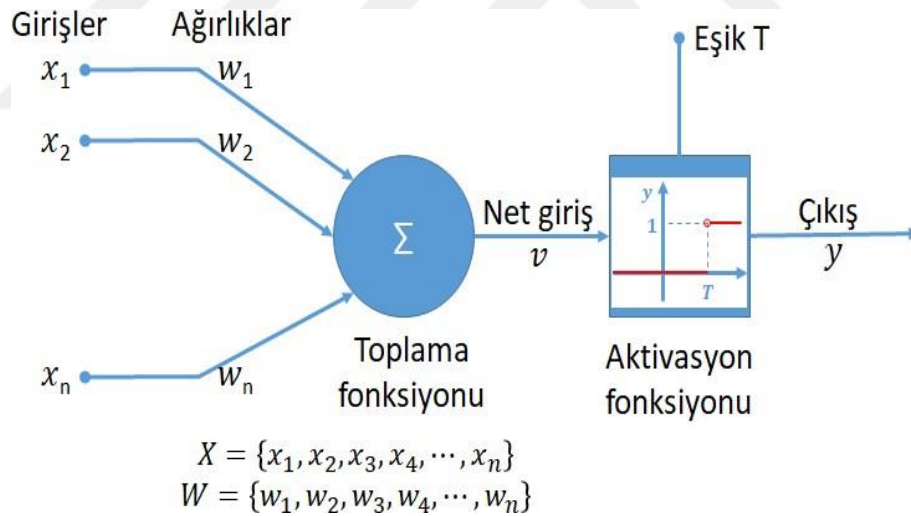
Tarih boyunca insan beyninin çalışma yöntemi ve kapasitesi insanların ilgisini çekmiştir. İnsan beyninin yetenekleri, bilimsel çalışmaların konusu olmuş ve beynin nörofiziksel yapısının matematiksel bir ifadeye dökülmesi önem arz etmiştir. Beynin nörofiziksel yapısının matematiksel olarak ifadesi, beynin karmaşık davranışlarının doğru bir şekilde yansıtılması ve fiziksel bileşenlerinin modellenmesi açısından önemli bir temel taşıdır. Beynin nöral olarak modellenmesi, geleneksel bilgisayar biliminde kullanılan algoritmik hesaplama yöntemlerinden farklı olarak YSA olarak bilinen apayrı bir bilimsel disiplinin ortaya çıkmasını sağlamıştır. Genel anlamda bir YSA, beynin işlevsel süreçlerini taklit etmek için tasarlanmış bir sistemdir. YSA'lar katmanlar halinde tasarlanıp organize edilmektedir. Katmanlar birbirine bađlı yapay sinir hücreleri, elektronik devreleri kullanan donanım veya bilgisayar sistemlerine entegre edilmiş bir yazılım olarak ortaya çıkabilmektedir. Beyinde var olan bilgi işleme yöntemlerine uygun olarak YSA, bir öğrenme sürecinin ardından bilgiyi elde etme, saklama ve gerektiđi durumlarda genelleştirme yeteneđine sahip bir işlem birimi olarak işlev görmektedir (Yapay Sinir Ağları Hakkında, 2024).

Yapay zeka arařtırmalarının temelinde, kapsamlı bir řekilde incelenen YSA alanı bulunmaktadır ve arařtırmaların kkleri Turing makinesine kadar gitmektedir. YSA, ncelikle insan beynini taklit etme amacını gderek geliřtirilmiřtir ve insan beynine iki temel aıdan benzemektedir:

1. Bilgi asimilasyonu ađ iindeki đrenme sreci yoluyla gerekleřir.
2. Bilgi, sinaptik ađrılıklar olarak adlandırılan, nronlar arasındaki bađlantı gleri kullanılarak depolanır (Haykin, 1999; Ergezer ve ark., 2003).

2.3.1. Yapay sinir ađlarının genel zellikleri

İster bir algoritma ister fiziksel bir varlık olarak kavramsallařtırılınsın yapay nron, biyolojik bir nronun temel davranıřını rnek alan bir matematiksel modele sahiptir. Biyolojik sinir hcresi gibi davranacak řekilde diđer sinir hcrelerinden sinyal alan bir birimdir. Kmlatif sinyal belirli bir eřik noktasını ařtıđında yapay nron kendi sinyalini bařka bir sinir hcresine iletir (Fahey, 2024).



řekil 2.1. Yapay Sinir Hcresinin Yapısı

Yapay sinir ađları, biyolojik benzerleri gibi, mhendislik biliminde de iřleme elemanları olarak adlandırılan yapay nronlara sahiptir. Her iřlem elemanı beř temel elemandan oluřur: giriřler, ađrılıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve ıkıřlar (ztemel, 2006).

Veri odaklı sistemler olarak oluřturulan yapay sinir ađları, nronları katmanlar halinde birbirine bađlayarak, basitleřtirilmiř modeller aracılıđıyla insan beyninin farklı

koşullar altında öğrenme, hızlı karar verme gibi yeteneklerini geliştirmeyi amaçlamaktadır (Koç ve ark., 2004).

Yapay sinir ağlarındaki yapay nöronlar kümeler halinde gruplanır ve birbirine bağlı katmanlar halinde düzenlenir. Kümelenme yalnızca sonuç olarak birbiriyle bağlantılı olan katmanlarda meydana gelir. Bazı nöronlar dış dünyayla bağlantı kurarak girdiyi kabul ederken, diğerleri onu çıktıya dönüştürür. Gizli katmanlar daha sonra ağın geri kalanını birbirine bağlayan ve böylece bir bütün oluşturan ara nöronlardan oluşur. İyi tasarlanmış bazı ağlar tek bir nörondan oluşabilirken bazıları yüzlerce nörondan oluşabilir. Genellikle giriş, gizli katman veya katmanlar ve çıkış olmak üzere üç temel katman yapısı üzerinden mimari geliştirilmektedir (Anderson ve McNeill, 1992).

Harici girdi alan nöronları içeren bir katman olarak bilinen giriş katmanı, önemli bir farklılık taşır; bu farklılık, giriş katmanındaki nöronların sadece girdi değerlerini diğer katmana iletmeleridir ve bu değerler üzerinde Çıkış katmanı, sorumlu nöronların çıktılarının iletilmesini içerir. Gizli katmanlar, birbirine bağlı çok sayıda nöron içerebilir ve giriş ile çıkış katmanları arasında bulunabilir. Bir nöron tipik olarak gizli katmandan, önceki katmandaki tüm nöronlardan sinyaller alır ve çıktısını sonraki katmandaki tüm nöronlara ileten bir yapıya sahiptir. Mimari, ileri beslemeli bir yol oluşturarak ağın çıkışını sağlar ve nöronlar arasındaki iletişim hattı sinir ağlarının önemli bir parçasıdır (Anderson ve McNeill, 1992).

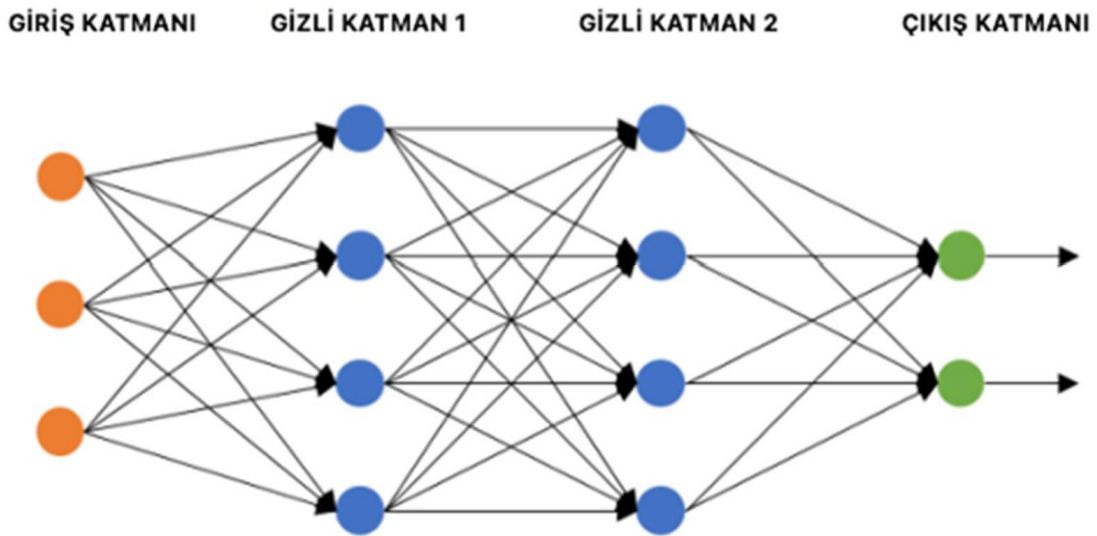
Yapay sinir ağlarının oluşumunu belirleyen evrensel olarak kabul edilmiş farklı yapı ve nöron sayısı göstermesine rağmen kuralları bulunmamaktadır. Ağlar, karmaşık fonksiyonları çözmekte güçlük yaşayabilirken gizli katman sayısı yetersizse, fazla gizli katmana sahip ağlar istenmeyen kararsızlıklarla karşılaşabilir. Zorluk, her katmandaki nöron sayısına karar vermek, gizli katmanların sayısı belirlendikten sonra ortaya çıkmaktadır. Giriş ve çıkış katmanlarından farklı olarak, gizli katmanlardaki nöron sayısını belirlemek daha karmaşık bir sorundur. Bu işlem kolaylıkla yapılamaz. Matris boyutları, girdi sayısı veya çıktı sayısı ile eşleşmelidir. Gizli katmandaki en verimli nöron sayısını belirlemek için matematiksel bir kriter bulunmamaktadır. Bu nedenle nöron sayısı belirlenmesi genellikle deneme yanılma yöntemiyle karar verilmesini gerektirmektedir (Detienne ve ark., 2003).

2.3.2. Derin öğrenme yöntemleri ile sınıflandırma

Geleneksel öğrenme yöntemleri, yüksek boyutlu verilerle uğraşırken kapsamlı girdi ve çıktılara bağlı sınırlamalarla karşı karşıya kalmaktadır. Bu tür verilerin işlenmesi,

sorunun karmaşıklığı arttıkça hem performans açısından hem de doğruluk bakımından giderek zorlaşmaktadır. Derin öğrenme, zorlukların üstesinden gelmek için bir çözüm olarak ortaya çıkmaktadır, bu sayede karmaşık gerçek dünya sorunlarıyla başa çıkılabilmektedir. Nöronlar, görevlerin karmaşıklığı arttıkça daha karmaşık bir ağ yapısı oluşturmak için bilgiyi verimli bir şekilde iletmek üzere işbirliği yapar.

YSA, verilerdeki nitelikleri ve ilişkileri tanımlamada oldukça etkilidir, çünkü bu ağlar, verilen verilerden öğrenmeye odaklanır. YSA'lar, giriş verilerini matematiksel olarak dönüştürme becerisi sayesinde karmaşık modelleri öğrenebilir. Temel bir YSA modeli, bir giriş katmanı, bir çıkış katmanı ve bu iki katman arasındaki bilgi akışını yönlendiren bir veya daha fazla gizli katmandan oluşur. Bu ağlar, genellikle makine öğrenmesinin bir parçası olarak kullanılır ve her bir katman, öğrenilen özellikleri daha soyut bir düzeyde temsil eder. Şekil 2.2.'de gösterilen her daire, bir nöronu temsil eder ve her nöron, ağırlıklar, sapmalar ve bir aktivasyon fonksiyonu ile donatılmıştır. Nöronlar, bilginin giriş katmanından gizli katmanlara iletilmesine yardımcı olan bir veya daha fazla bağlantıya sahiptir. Gizli katmanlar bu bilgiyi işler ve işlenen veriyi çıkış katmanına ileterek nihai sonucu elde eder.



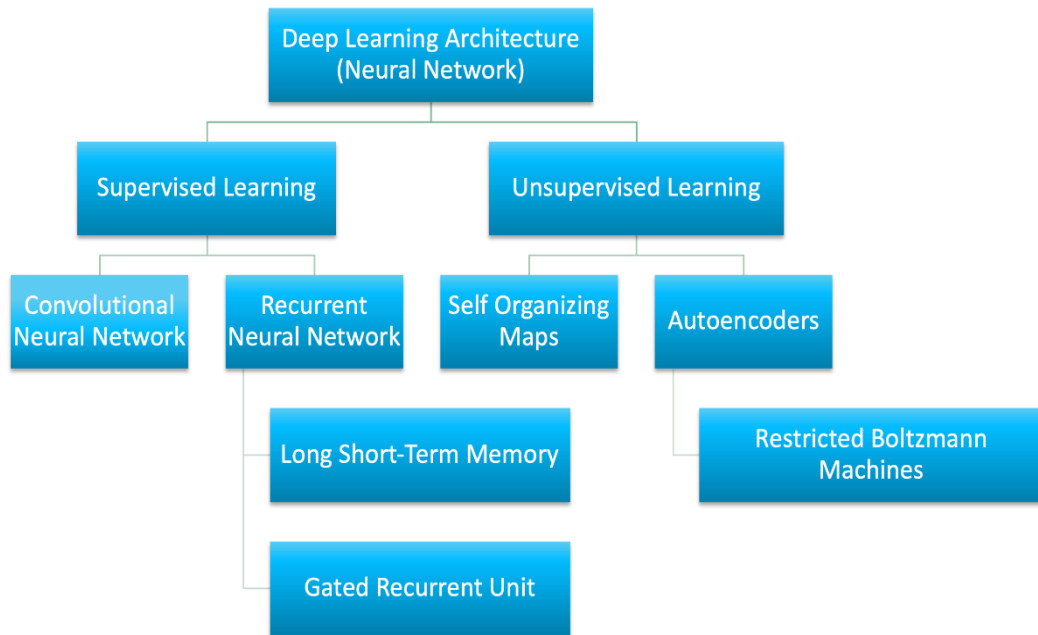
2.4. Derin Öğrenme Mimarileri

Bağlantıcı mimariler, yapay zeka ve bilişsel bilimlerde insan beyninin sinirsel yapısını ve işleyişini modelleyen hesaplama yöntemleridir. Bu mimariler yetmiş yılı aşkın bir süredir mevcuttur, ancak mimarilerdeki son gelişmeler ve grafiksel işlem birimlerinin kullanımı, onları yapay zekanın ön sıralarına itmiştir. Derin öğrenme tekil bir yaklaşımı

değil, çok çeşitli problemlere uygulanabilen bir algoritma ve topoloji kategorisini temsil etmektedir.

Derin öğrenme kavramı yeni olmasa da mevcut yükselişi, derin katmanlı sinir ağlarının yakınsamasına ve bunların yürütülmesini hızlandırmak için GPU'ların kullanılmasına bağlanabilir. Önemli miktarda büyük veri akışı bu büyümeyi daha da artırmaktadır. Derin öğrenme, sinir ağlarının örnek verilerle eğitilmesinden yararlanır ve onları başarılarına göre ödüllendirir. Bu nedenle veri fazlası, bu karmaşık derin öğrenme yapılarının yapısını geliştirmektedir.

Derin öğrenmede kullanılan mimari ve algoritma dizisi kapsamlı ve çeşitlidir. Bu bölümde son yirmi yılda gelişen altı derin öğrenme mimarisi ele alınmaktadır. Bunların arasında dikkate değer olanlar, bu listedeki daha eski yaklaşımlar arasında olmasına rağmen çeşitli uygulamalarda en yaygın olarak kullanılanlar arasında kalmaya devam eden uzun kısa süreli bellek ve evrişimli sinir ağlarıdır.



Şekil 2.3. Derin Öğrenme Mimarileri

2.4.1. Derin denetimli öğrenme

Derin denetimli öğrenme (ing - Deep supervised learning), etiketlenmiş verilerle çalışan bir yöntemdir ve bu veriler ortama bir dizi girdiyle karşılık gelen çıktı sağlar. Bu yöntemde, bir akıllı ajan x_t girişi ile sunulduğunda tahminler yapar ve bir L kaybı değeri elde eder. Ağ parametrelerini düzenli aralıklarla güncelleyerek, daha sonra modelin

tahmin yeteneklerini geliřtirmeyi ve istenen ıktıları elde etmeyi hedefler. Eđitim sayesinde başarılı bir řekilde, etmen evrenin sorduđu sorulara dođru cevaplar verebilecek yeteneđi kazanmaktadır.

Derin renme, farklı denetimli renme tekniklerini ieren bir alan olup bunlar arasında tekrarlayan sinir ađları, evriřimli sinir ađları ve derin sinir ađları (DNN) bulun RNN kategorisi, geitli tekrarlayan birimler (GRU) ve uzun kısa sreli bellek gibi zgl yaklařımları da iermektedir.

Derin denetimli renmenin nemli bir avantajı, veri giriři tabanlı olarak ıktı toplama veya oluřturma yeteneđiyle iliřkilidir. Karar sınırının geređinden fazla uyma riski (overfitting), eđitim setinde belirli bir sınıfa ait olması gereken rneklerin bulunmaması durumunda potansiyel bir dezavantajdır. Teknik, diđer yaklařımlara gre daha basit kabul edilmesine rađmen, bu sınırlama gz nne alındıđında bile renme srecinde yksek performans sergileyebilmektedir.

2.4.2. Yarı denetimli renme

Yarı denetimli renme (ing - Deep semi-supervised learning), renme srecinde kısmen etiketlenmiř veri kmelerine dayanan yarı denetimli renmeyi kullanır. Zaman zaman, GAN (Dođan ve ark., 2020) ve derin takviyeli renme (DRL) gibi teknikler bu ynteme dahil edilir. Ayrıca, RNN iinde yer alan GRU ve uzun-kısa sreli bellek ađları da kısmen denetimli renme senaryolarında kullanılır.

Yarı denetimli renmenin nemli bir avantajı, byk miktarda etiketlenmiř veriye olan ihtiyacın en aza indirilmesidir. Ancak, dikkate deđer bir dezavantaj ise eđitim verilerindeki gereksiz giriř zelliklerinin yanlış kararlara yol ama riskidir. Yarı denetimli renmenin belirgin bir uygulaması, metin belgesi sınıflandırmasında -nemli sayıda etiketli metin belgesinin elde edilmesinin zor olduđu durumlarda- aıka grlmektedir. Bu nedenle, yarı denetimli renmenin metin belgesi sınıflandırması gibi grevler iin olduka uygun olduđu kanıtlanmıřtır nk geniř etiketlenmiř veri kmelerini elde etme zorluklarını zebilme yeteneđi vardır.

2.4.3. Deep unsupervised learning

Bu yntemde denetimsiz renme, etiketli verilere dayanmadan renme srecinin ilerlemesine izin verir ve bu da nceden belirlenmiř etiketlere olan ihtiyacı ortadan kaldırır. Gerekli olan kritik zellikleri veya dahili temsilleri ıkarmak iin, aracı girdi verilerindeki gizli yapıları veya iliřkileri ortaya ıkarma amacıyla bu bađlamda

kullanılır. Üretken ağlar, genellikle denetimsiz öğrenme şemsiyesi altında bulunan boyut azaltma ve kümeleme gibi yaklaşımları içerir.

Kısıtlı Boltzmann makineleri, otomatik kodlayıcılar ve üretken çekişmeli ağlar gibi daha yakın zamanda geliştirilen teknikleri içeren derin öğrenme ailesinin üyeleri, doğrusal olmayan boyut azaltma ve kümeleme görevlerinde yeterlilik göstermişlerdir. Ek olarak, geçitli tekrarlayan birimler ve uzun kısa süreli bellek ağlarını içeren tekrarlayan sinir ağları, çeşitli denetimsiz öğrenme senaryolarında uygulama alanı bulur.

Veri kategorizasyonu ve hesaplama karmaşıklığı hakkında kesin bilgi sağlayamaması gibi dezavantajlara sahip olmakla birlikte, denetimsiz öğrenme gizli yapıların ortaya çıkarılmasında etkilidir. Kümeleme, benzer veri noktalarının bir araya gruplandırılmasıyla ilgili olarak öne çıkan denetimsiz öğrenmenin bir örneğidir.

2.4.4. Deep reinforcement learning

Takviyeli öğrenme (Reinforcement Learning - RL), denetimli öğrenmeden farklı bir paradigma olan karar verme süreçlerini optimize etmek için ortamla yinelemeli olarak etkileşim kurarak çalışır ve önceden belirlenmiş örnek verilere dayanmaktadır. Bu tekniğin kökeni, Google DeepMind'in geliştirilmesine kadar uzanan 2013 yılına dayanır ve daha sonra takviyeli öğrenmeye dayalı birçok yeni metodolojinin formüle edilmesine yol açar (Mnih ve ark., 2015).

Aracıya giriş ortamı örnekleri RL bağlamında sunulduğunda, aracı a olarak gösterilen bir eylemi tahmin eder ve ilişkili maliyet c alır. P bir olasılık dağılımını temsil etmektedir ve bilinmemektedir. Bu süreç aynı zamanda yarı denetimli öğrenme olarak da adlandırılabilir ve temsilcinin ortama bir soru sormasını ve gürültülü bir puan almasını içerir. Çeşitli denetimli ve denetimsiz teknikler, bu prensibe dayanarak geliştirilmiştir.

Geleneksel denetimli yaklaşımların aksine, takviyeli öğrenmenin uygulanması, basit bir kayıp fonksiyonunun bulunmaması nedeniyle artan zorluklara yol açmaktadır. Optimizasyon, denetimli öğrenmenin iki ana noktasını takviyeli öğrenmeden ayıran işleve tam erişime sahip değildir ve ortama bağlı x girişiyle ilgili etkileşimli sorgular gerektirir (Mnih ve ark., 2015; Alom ve ark., 2019).

Belirli bir görevin karmaşıklığı ve kapsamı, uygun takviyeli öğrenme türünün seçilmesine bağlıdır. Derin Takviyeli Öğrenme (Deep Reinforcement Learning - DRL), özellikle çok sayıda parametreyi içeren problemler için iyidir, ancak türevsiz takviyeli öğrenme, sınırlı parametrelere sahip durumlarda iyidir. İş stratejisi planlaması ve robot bilimi endüstriyel otomasyon için takviyeli öğrenme uygulamaları arasındadır. Ancak

RL'nin önemli bir dezavantajı, parametrelerin öğrenme hızı üzerindeki potansiyel etkisi. Takviyeli öğrenmenin temel motivasyonları, eylem gerektiren durumların ayırt edilmesini, uzun vadede en uygun ödülleri sağlayan eylemlerin belirlenmesini, önemli ödüller elde etmek için en uygun yöntemlerin belirlenmesini ve öğrenme aracına bir ödül işlevi sağlamayı içerir.

Takviyeli öğrenme avantajlarına rağmen, denetimli öğrenme tekniklerinin bol miktarda veri ile sorunları çözebildiği durumlarda uygun olmayabilir. Ek olarak, RL, özellikle geniş çalışma alanlarında hesaplama açısından karmaşıktır ve zaman alıcıdır.

2.4.5. Derin öğrenme ağlarının türleri

Derin öğrenme ağlarının en ünlü türleri bu alt başlıkta tartışılmaktadır: bunlar özzyinelemeli sinir ağlarını, RNN'leri ve CNN'leri içerir. Bu bölümde RvNN'ler ve RNN'ler kısaca açıklanırken, CNN'ler bu türün önemi nedeniyle derinlemesine anlatılmıştır. Ayrıca diğer ağlar arasında birçok uygulamada en çok kullanılanıdır.


2.4.6. Özzyinelemeli sinir ağları

Özzyinelemeli Sinir Ağı, bileşimsel vektörlerin kullanılması yoluyla hiyerarşik tahminler yapmak ve çıktıları sınıflandırmak için yetenekli bir ağıdır (Arulkumaran, vd., 2017). Özzyinelemeli Otomatik İlişkisel Bellek (RAAM) (Alzubaidi, ve ark., 2020), grafikler veya ağaçlar gibi farklı şekilli yapılara sahip nesnelere işlemek için RvNN mimarisini geliştirmiştir. Yapı yoluyla geri yayılım (BTS) öğrenme sistemi, değişken boyutlu yinelemeli veri yapısından sabit genişlikte dağıtılmış bir temsil elde etmek için bu yöntemi kullanır (Socher ve ark., 2013). Ağaç benzeri yapıları içeren genel geri yayılım algoritması, BTS sistemini destekler. Ağ, otomatik ilişkilendirme sayesinde giriş katmanı modelini çıkış katmanına yeniden yapılandırabilir. Socher ve ark., özellikle Doğal Dil İşleme (NLP) konusunda etkili olan (Goller ve Kuchler, 1996) girdileri işlemek için bir RvNN tasarımı tanıtmıştır. Doğal dil cümlelerinin sınıflandırılmasında araştırmacılar, her cümlenin kelimelere ve doğa görüntülerine bölündüğü ve her görüntünün birden fazla ilgi alanına bölündüğü senaryolarda bunun uygulamasını göstermiştir. Birim çiftleri için birleştirme olasılık puanlarını ve birleştirme puanlarını hesaplamak için RvNN sözdizimsel bir ağaç oluşturmaktadır. Daha sonra, en yüksek puana sahip birim çifti bir bileşim vektöründe birleştirilir. RvNN, her birleştirmeden sonra (a) birden fazla birimden oluşan daha büyük bir alan, (b) alan için bir bileşim vektörü ve (c) yeni alan için bir sınıf etiketi oluşturur. RvNN ağaç yapısı, tüm alanın

bileşim vektörü tarafından oluşturulmaktadır (Socher ve Lin, 2011; Urban ve ark., 2018; Louppe ve ark., 2019; Sadr ve ark., 2019).

2.4.7. Yinelemeli sinir ağları (RNN)

Derin Öğrenme alanında yaygın olarak kullanılan ve bilinen bir algoritma, yineleme sinir ağları olarak bilinir (Urban ve ark., 2018; Hewamalage ve ark., 2020; John, ve ark., 2020). Konuşma işleme ve Doğal Dil İşleme alanlarında yaygın olarak kullanılan RNN'ler, sıralı verileri ağa dahil etme yetenekleriyle diğerlerinden ayrılırlar (Jagannatha, 2016; Batur Dinler ve Aydın, 2020). Sıralı verilerin kullanımı, çeşitli uygulamalarda değerli bilgiler sağlayan doğal yapıları kapsadığı için çok önemlidir. Örneğin, bir cümlenin bağlamsal özelliklerini anlamak, içindeki kelimelerin ne kadar önemli olduğunu anlamak için çok önemlidir. Bu durumda, RNN'ler kısa süreli belleğe sahip varlıklar olarak düşünülebilir. Bu durumda, "x" giriş katmanı, "y" çıkış katmanı ve "s" durum (gizli) katmanı vardır. Belirli bir giriş dizisi için tipik bir açık RNN diyagramı Şekil 2.4.'de gösterilmiştir. Pascanu ve ark. (2014) üç farklı derin RNN tekniği türünü tanıtmıştır: Bu tanıtilen teknikler, derin bir RNN'nin tanıtılmasına, derin ağlardaki öğrenme karmaşıklıklarının hafifletilmesine ve daha derin bir RNN mimarisinin avantajlarından yararlanılmasına katkıda bulunmaktadır.



Şekil.2.4. RNN Diagram

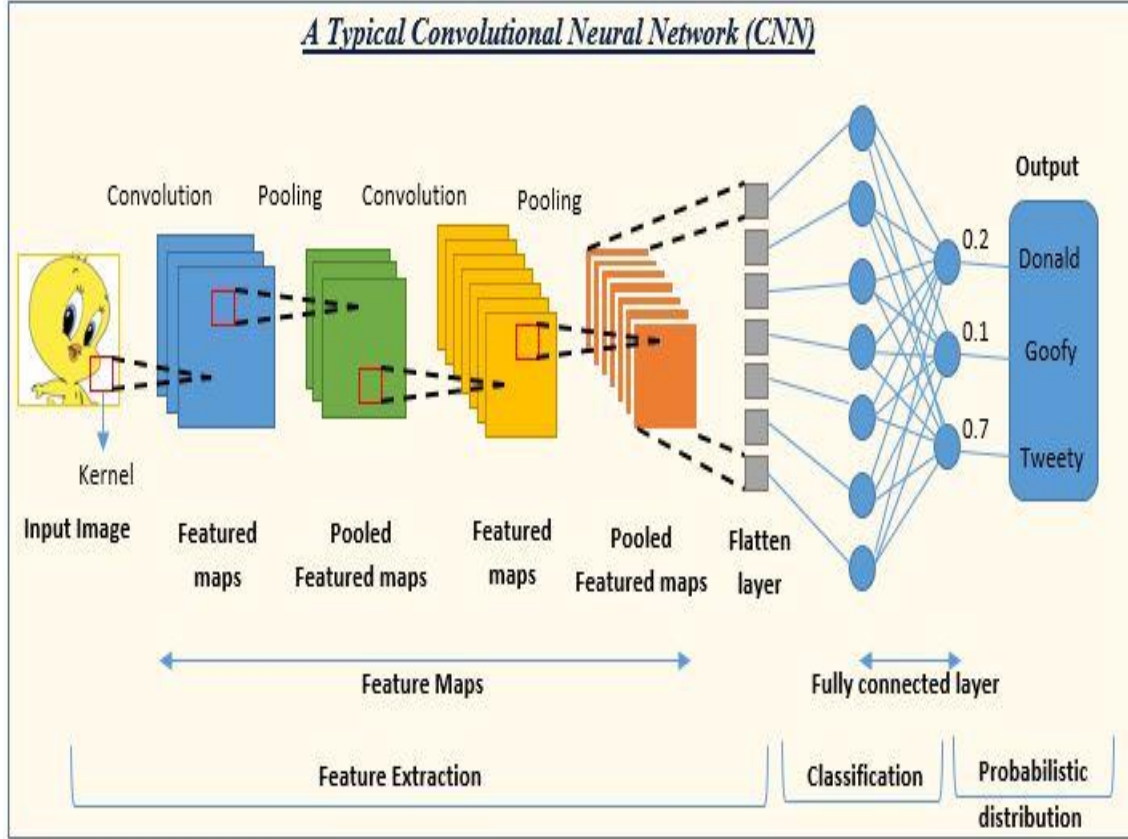
Yinelemeli Sinir Ağları, aynı zamanda kaybolan gradyan ve patlayan gradyan sorunlarına karşı hassastır (Glorot ve Bengio, 2010). Spesifik olarak, eğitim aşamasında birkaç büyük veya küçük türevin tekrarlanan çarpımı, gradyanların üstel olarak patlamasına veya azalmasına neden olabilir. Yeni girdiler eklendikçe ağ eski girdileri unutuyor, bu da ağın hassasiyetini azaltıyor. Bu sorunu çözmek için Uzun Kısa Süreli Bellek mimarileri geliştirilmiştir (Gao ve ark., 2019). LSTM'ler, ağ bellek bloklarına tekrarlayan bağlantılar sağlar. Her bellek bloğu, bilgi akışını yönetmek için kapılı birimler ve zamansal durumları tutmak için birkaç bellek hücresinden oluşur. Ek olarak, daha sonraki bölümlerde açıklanacağı gibi, artık bağlantıların entegrasyonunun, çok derin ağlarda, yok olan gradyan sorununun etkisini önemli ölçüde azalttığı gösterilmiştir (He ve ark., 2016). Karşılaştırıldığında, Evrişimli Sinir Ağlarının genellikle RNN'lerden daha güçlü olduğu kabul edilir. RNN'ler, CNN'lere kıyasla daha düşük özellik uyumluluğu sergiler.

2.4.8. Evrişimsel sinir ağları

Evrişimsel Sinir Ağları, Derin Öğrenme (DL) alanında en yaygın olarak kullanılan algoritma olarak öne çıkmaktadır (Krizhevsky ve ark., 2017; Gu ve ark., 2018; Zhou, 2020; Jhongve Tseng, 2020; Al-Azzawi ve ark., 2020; Li ve ark., 2021). İnsan denetimine ihtiyaç duymadan ilgili özellikleri otonom olarak tanımlayan CNN'ler, öncüllerine göre çok daha iyidir (Palaz, 2019). Bilgisayar görüşü, konuşma işleme ve Yüz Tanıma gibi çeşitli alanlar için uygulamaları vardır (Hubel ve ark., 1962; Goodfellow, 2016; Li, 2020). Geleneksel sinir ağları gibi, CNN'ler de insan ve hayvanların beyinlerindeki nöronlardan ilham almıştır. CNN'lerin yapısı, özellikle bir kedinin beynindeki görsel korteksi oluşturan hücrelerin karmaşık kombinasyonuna benzer (Hubel, 1962). Goodfellow ve ark. (2016) CNN, eşdeğer temsiller, seyrek etkileşimler ve parametre paylaşımı olarak üç önemli avantajı tanımlamıştır.

Geleneksel tam bağlantılı (FC) ağların aksine, CNN'ler paylaşılan ağırlıklardan ve yerel bağlantılardan yararlanır, bu da onları görüntü sinyalleri gibi 2 boyutlu verilerin işlenmesi için ideal hale getirir. Bu yöntem, eğitim sürecini basitleştirir ve ağ verimliliğini artırır. Bu tasarım ilkesi, girdi üzerindeki yerel filtrelere benzer şekilde girdiden yerel korelasyonları mekansal olarak çıkararak, bir sahnenin yalnızca küçük bölgelerinin algılandığı görsel korteksteki hücrelerin işleyişiyle aynı hizadadır.

Çok katmanlı algılayıcıların (MLP'ler) yapısına benzeyen CNN'ler, Şekil 2.5.'de görüldüğü üzere, ağı tamamlayan tamamen bağlı katmanlarla birlikte birden fazla evrişim katmanı ve alt örnekleme (havuzlama) katmanlarından oluşur.



Şekil 2.5. Evrişimsel Sinir Ağları Sınıflandırma Mimarisi

Bir CNN modelinde, her katmanın girişi x üç boyutta yapılandırılmıştır: $m*m*r$, burada m genişliğe eşittir. Derinlik, kanal numarasıyla eş anlamlıdır; örneğin, bir RGB görüntüsünde r üçe eşittir. Giriş görüntüsüne benzer şekilde, her bir evrişim katmanındaki çekirdekler (filtreler), üç boyuta sahip olan k ile gösterilir. Bu durumda, n m 'den küçük olmalıdır ve q r 'ye eşit veya ondan küçük olmalıdır. Yerel bağlantıların temelini oluşturan çizgiler, aynı parametreleri (sapma b ve ağırlık w) paylaşarak özellik haritaları oluşturur, her biri $m*m$ boyutunda. Bu özellik haritaları, girdi ile evrilir. Doğal dil işlemeye benzer şekilde, evrişim katmanı girdi ve ağırlıkları arasında bir nokta çarpımı hesaplar, ancak girdiler ilk görüntünün küçük boyutlu alanlarını temsil eder.

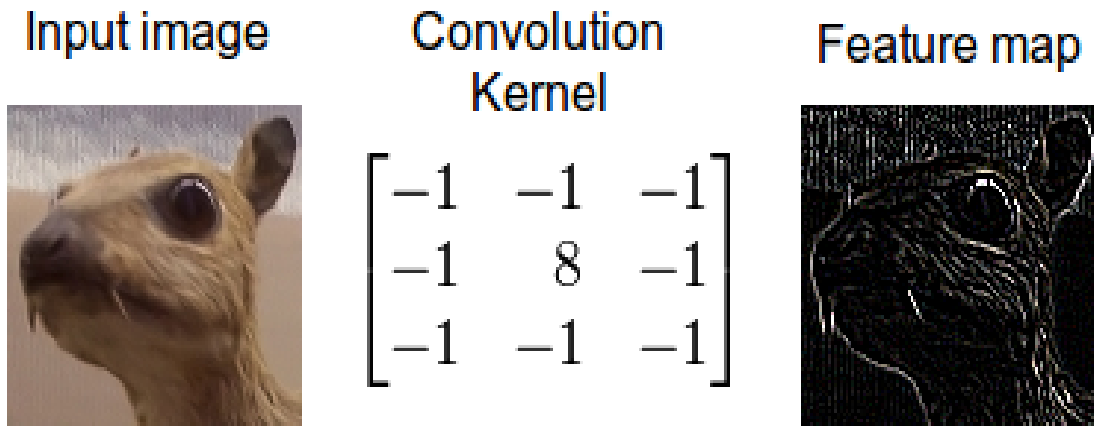
Evrişim katmanı çıktısı doğrusal olmama veya aktivasyon fonksiyonuna maruz kalır ve bu da şu ifadeyle sonuçlanır:

$$h^k = f(W^k * x + b^k)$$

Daha sonra, alt örnekleme katmanları her özellik haritasını alt örnekleyerek hızlandırılmış eğitim için ağ parametrelerini azaltır ve aşırı uyumu giderir. Bir havuzlama işlevi (örneğin, maksimum veya ortalama), $p * p$ boyutundaki bitişik alanlara uygulanır; burada p , çekirdek boyutudur. Son olarak, Tam Bağlantılı (FC) katmanlar orta ve düşük seviyeli özellikler olarak tipik bir sinir ağına benzer şekilde yüksek seviyeli soyutlamalar oluşturur. Sınıflandırma puanları, her puanın belirli bir örnek için belirli bir sınıfın olasılığını temsil ettiği son katmanda (örneğin, destek vektör makineleri veya softmax) oluşturulur.

2.4.9. Evrişim katmanı (Convolution)

CNN'nin mimarisinde evrişim çok önemlidir. Evrişim, önceki katmandan alınan fotoğraflar üzerinde tipik olarak 3x3, 5x5 ve 7x7 gibi boyutlara sahip belirli bir filtrenin sistematik dolaşımını içerir. Bu, filtrenin matris çarpımı yoluyla ilgili değerlere tabi tutulmasını ve ardından bu değerlere sahip olan değerleri toplamasını gerektirir. Görüntünün tamamında kapsamlı filtreleme işlemi tamamlandıktan sonra sonuçlar özellik haritalarında gösterilir. Özellik haritaları, her filtrenin özel özelliklerini gösterdiği alanlardır. Bu filtrelerle ilgili katsayılar, ESA'nın eğitim yinelemeleri boyunca ağa verilerin önemli yönlerini göstererek değiştirilir. Bu çalışmada kullanılan görüntüler üç kanallı (RGB) olduğundan, filtre katsayıları her kanal için ayrı ayrı matris çarpımına ve toplama işlemine tabi tutulur. Bu üç kanal süreci tamamlandıktan sonra, her üç kanalın toplanması özellik haritası oluşturur (Özkan ve Ülker, 2017).



Şekil 2.6. Bir Resmin Convolution Kernel İle Kenarlarının Bulunması

f ve x olmak üzere iki fonksiyonun t aralığındaki evrişiminin matematiksel tanımı şöyledir:

$$y(t) = f \otimes x = \int_{-\infty}^{\infty} f(k) \cdot x(t - k) dk$$

Burada \otimes sembolü evrişimi ifade eder.

Doğrusal zaman-değişmez (LTI) sistemler, sinyal işlemeyle ilgili uygulamalarda yaygın olarak kullanılır. LTI sistemleri hem doğrusaldır (girişlerin bir kombinasyonu için çıktı, tek tek girişlerin çıktılarının bir kombinasyonu ile aynıdır) hem de zaman-değişmezdir (çıkışı, bir giriş uygulandığında zamana bağlı değildir). Bir LTI sistemi için, çıkış sinyali, giriş sinyalinin sistemin dürtü tepki fonksiyonuyla evrişimidir.

Evrişimin uygulamaları arasında dijital sinyal işleme, görüntü işleme, dil modelleme ve doğal dil işleme, olasılık teorisi, istatistik, fizik ve elektrik mühendisliği yer alır. Evrişimsel sinir ağı, girdileri yararlı bilgiler için filtrelemek üzere evrişimsel katmanlar kullanan bir yapay sinir ağı sınıfıdır ve çok sayıda görüntü ve konuşma işleme sisteminde uygulamaları vardır.

2.4.10. Doğrusal olmayan katman (Non-Linearity Layer)

"Etkinleştirme Katmanı" olarak da adlandırılan bu katman, çeşitli etkinleştirme fonksiyonlarından birini içerir. Geçmişte yapılan çalışmalarda sıklıkla sigmoid ve tahn gibi doğrusal nitelikte olmayan aktivasyon türlerinin kullanıldığı görülmektedir. Ancak günümüzde verimliliği nedeniyle sıklıkla Düzeltilmiş Doğrusal Birim aktivasyonu kullanılmaktadır. ReLU, $[0, +\infty]$ aralığındaki değerleri varsaymaktadır.

2.4.11. Havuzlama katmanı (Pooling Layer)

CNN'ler, havuzlama katmanı, özellik çıkarımında kritik bir bileşen olarak hizmet eder. Temel amacı, giriş hacminin uzamsal boyutlarını aşamalı olarak azaltmak, böylece temel özellikleri korurken ağırlık hesaplaması karmaşıklığında azalmaya yol açmaktır.

Havuzlama genellikle bir CNN'deki evrişimli katmanlardan sonra uygulanır. En yaygın havuzlama türü, belirli bir pencere veya filtre içindeki bir dizi değerden

maksimum değerin seçilmesini içeren Maksimum Havuzlamadır. Ortalama Havuzlama, maksimum değer yerine ortalama değerin hesaplandığı başka bir değişkendir.

Havuzlama işlemi, bir pencerenin veya filtrenin giriş hacmi üzerinde kaydırılmasını ve her yerel bölgeden maksimum (veya ortalama) değerin seçilmesini içerir. Bu süreç, özellik haritalarının boyutunu küçülterek uzamsal boyutları etkili bir şekilde altörnekler. Aynı zamanda bir dereceye kadar çeviri değişmezliği sunarak ağı, girdi içindeki özelliklerin konumundaki değişikliklere karşı daha dayanıklı hale getirir.

Maksimum havuzlama işleminin genel formülü aşağıdaki gibidir:

$$\text{Max Pooling}(x)=\max(x)$$

Burada x , havuzlama penceresindeki değerleri temsil eder.

Havuzlama katmanının rolü boyut azaltmanın ötesine uzanır; giriş verilerinin en belirgin yönlerini yakalayarak özelliklerin hiyerarşik bir temsilini oluşturmaya yardımcı olur. Bu hiyerarşik temsil, ağı daha derin katmanlarda ilerledikçe giderek daha soyut özellikleri öğrenmesi için çok önemlidir.

Bir CNN'deki havuzlama katmanı, uzamsal boyutların altörneklenmesinde, hesaplama karmaşıklığının azaltılmasında, çeviri değişmezliğinin getirilmesinde ve girdi verilerinden hiyerarşik ve soyut özelliklerin çıkarılmasının kolaylaştırılmasında çok önemli bir rol oynar.

2.4.12. Düzleştirme katmanı (Flattening Layer)

Düzleştirme katmanı, CNN'lerin mimarisinde çok önemli bir bileşendir ve tipik olarak evrişim ve havuzlama katmanlarının çıktısından tamamen bağlı katmanlara geçiş için kullanılır. Birincil işlevi, çok boyutlu verileri tek boyutlu bir dizi halinde yeniden şekillendirmektir; bu dizi daha sonra daha ileri işleme ve sınıflandırma için tamamen bağlı bir sinir ağına beslenebilmektedir.

Evrişim ve havuzlama katmanları giriş verilerini işledikten sonra, özellik haritası veya tensör olarak bilinen üç boyutlu bir dizi üretirler. Bu dizinin boyutları, özellik haritalarının uzamsal boyutlarını (genişlik, yükseklik) ve kanal sayısını (derinlik) temsil eder. Düzleştirme katmanı bu çok boyutlu diziyi alır ve onu tek boyutlu bir vektöre dönüştürerek verileri etkili bir şekilde "düzleştirir".

Düzleştirme işlemi, özellik haritalarındaki değerlerin çözülmesini ve bunların tek bir satırda düzenlenmesini içerir. Örneğin, son özellik haritasının boyutu $5*5*64$ ise, düzleştirme katmanı onu $1*1600$ (5 çarpı 5 çarpı 64) vektörüne dönüştürecektir. .

Matematiksel olarak düzleştirme işlemi şu şekilde temsil edilebilir:

$\text{Flatten}(\text{feature_map})=[x_1, x_2, \dots, x_n]$

Burada x_i düzleştirilmiş vektördeki bireysel değerleri temsil eder.

Düzleştirilmiş vektör daha sonra nihai tahminlerin yapılmasından sorumlu olan tamamen bağlı katmanlar için girdi olarak kullanılır. Bu tamamen bağlantılı katmanlar, özelliklerin düzleştirilmiş gösteriminde mevcut olan karmaşık ilişkileri ve modelleri öğrenebilir.

Düzleştirme katmanı, çok boyutlu özellik haritalarını tek boyutlu bir vektöre dönüştürme temel amacına hizmet ederek, son sınıflandırma veya regresyon görevleri için evrişimli ve havuzlama katmanlarından tamamen bağlantılı katmanlara geçişi kolaylaştırır.

2.4.13. Sınıflandırma katmanı (Classification Layer)

Önceki katmanlar tarafından çıkarılan özelliklere dayalı olarak tahminlerde bulunmada CNN'lerin önemli bir parçasıdır. Bu katman genellikle tamamen bağlı bir katmandır ve evrişim ve havuzlama katmanlarından elde edilen üst düzey özelliklerin sınıf puanlarına veya olasılıklara dönüştürülmesinden sorumludur.

Bir CNN'nin giriş verilerinin hiyerarşik temsillerini yakalamak için evrişim ve havuzlama katmanları kullanılır. Bu katmanlar, üst düzey bir özellik haritasıyla sonuçlanır. Bu özellikleri tahmin etmek için sınıflandırma katmanı uygun bir şekilde birleştirir. Sınıflandırma katmanı genellikle tamamen bağlı nöronlardan oluşur. Bu katmanda, her nöron önceki katmanlardan elde edilen düzleştirilmiş özellik vektöründeki her öğeye bağlanır.

Sınıflandırma katmanının çıktısına son bir aktivasyon fonksiyonu uygulanır, bu da doğrusal olmamayı garanti eder. Softmax işlevi, çok sınıflı sınıflandırma görevleri için yaygın seçenekler arasındadır. Softmax, sınıf puanlarını bir olasılık dağılımı olarak normalleştirerek girdinin her sınıfa ait olma olasılığı olarak yorumlanabilir hale getirir.

Temel doğruluk etiketlerini karşılaştırmak için kayıp (loss) fonksiyonu kullanılır. Sınıflandırma görevleri için çapraz entropi kaybı gibi kayıp fonksiyonu seçmek, görevin özelliğine bağlıdır. Eğitim, geri yayılım ve optimizasyon algoritmalarını kullanarak ağırlıkları ve sapmaları değiştirerek bu kaybı en aza indirmektir.

Sınıflandırma katmanı yalnızca sınıf etiketlerini tahmin etmekle sınırlı değildir; karmaşık model tanıma görevlerinde derin öğrenmenin gücünü ortaya koyarak, modelin ham girdi verilerinden hiyerarşik temsilleri otomatik olarak öğrenme ve genelleştirme yeteneğinin önemli bir bileşenidir.

2.4.14. Öğrenme aktarımı

Öğrenme aktarımı (transfer learning), bir görevde öğrenilen bir modelin başka bir görevi çözmek için kullanılmasını sağlayan etkili bir yaklaşımdır. Bu yöntem, bir öğrenme problemi için eğitilen modelin, farklı bir problemde yeniden eğitilmesi yerine, mevcut modelin doğrudan hedef problem için kullanılmasına olanak tanır. Transfer öğrenme, özellikle sınırlı veri durumlarında veya zaman, kaynak ve bilgi kısıtlamaları olan yapay zeka sistemlerinde oldukça faydalıdır (Zhuang ve ark., 2021). Derin öğrenme yöntemleri, genellikle büyük veri ve yüksek hesaplama kaynakları gerektirdiğinden, transfer öğrenme bu tür kısıtlamalar altında çözüm sunarak oldukça verimli hale gelir.

Bu yöntem, önceden eğitilmiş bir modelin hedef göreve uyarlanmasıyla gerçekleştirilir. Genellikle, bir modelin ilk katmanlarının başka bir modelin eğitimine temel oluşturması veya önceden eğitilmiş bir modelin çıktısının yeni bir modelin girdisi olarak kullanılması şeklinde uygulanır. Yaygın olarak kullanılan transfer öğrenme modelleri arasında Xception, VGG16, ResNet101V2, ResNet152V2, InceptionV3, InceptionResNetV2, MobileNetV2, DenseNet201, NASNetMobile, EfficientNetB1 ve EfficientNetV2B1 gibi derin öğrenme mimarileri yer almaktadır. Bu modeller, görüntü sınıflandırma, nesne tanıma ve tıbbi görüntü analizi gibi alanlarda yüksek başarıyla uygulanmaktadır. Özellikle benzer görevler arasında öğrenme aktarımı yapıldığında, bu yöntem verimli ve hızlı öğrenmeyi destekler, ayrıca veri miktarının sınırlı olduğu durumlarda büyük avantajlar sağlar.

2.4.15. Squeeze ve excitation bloğu

Squeeze-ve-Excitation (SE) bloğu, Convolutional Neural Networks yapılarında kullanılan bir modüldür ve ağın performansını artırmak için geliştirilmiştir. SE bloğu, kanallararası ilişkileri modelleyerek ağın özelliklerini dinamik olarak yeniden ölçeklendirir. Bu işlem, özellikle görüntü sınıflandırma gibi görevlerde, ağın daha dikkatli ve duyarlı özellik haritaları öğrenmesini sağlamaktadır (Patacchiola, 2022).

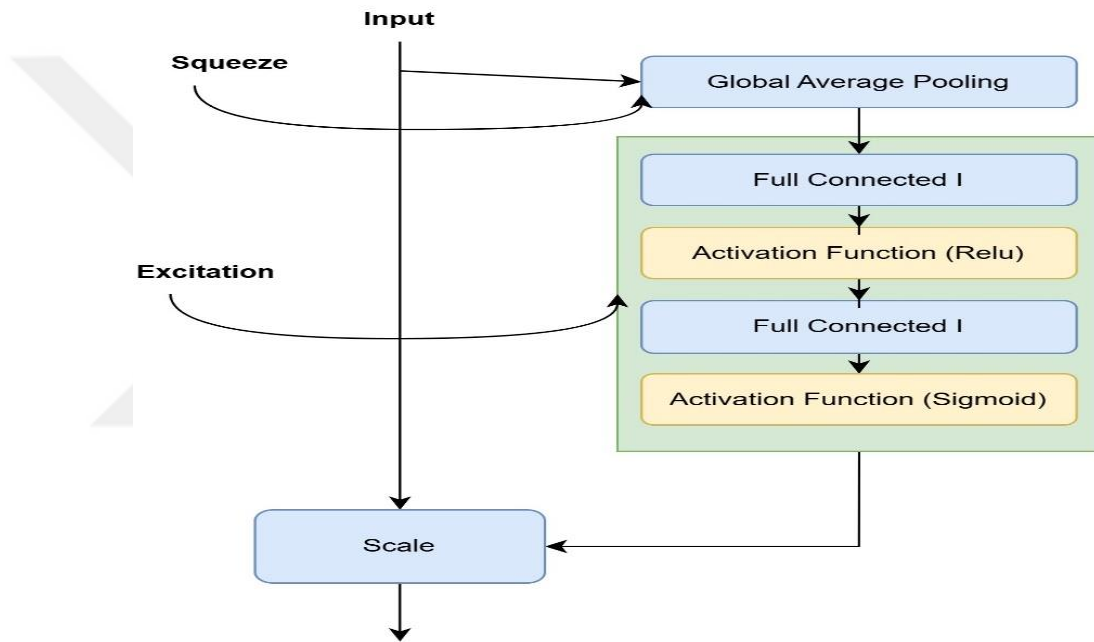
SE bloğunun çalışma prensibi üç ana aşamadan oluşur:

İlk aşama olan Squeeze (Sıkıştırma) aşaması, global average pooling (ortalama havuzlama) kullanılarak her kanal için tek bir değere indirgeme yapılır. Böylece, her kanalın uzaysal boyutları ortadan kaldırılarak sadece kanal bazında bir özet bilgi elde edilir. Bu özet bilgi, her kanalın genel özelliklerini temsil eder (Kumar, 2023).

Bir sonraki aşama olan excite (Uyarmak) aşamasında elde edilen sıkıştırılmış bilgiler tam bağlantılı (fully connected) katmanlardan geçirilir. Bu katmanlar, kanal bazlı bağıntıları öğrenmek için kullanılır ve sigmoid aktivasyon fonksiyonu ile her kanal için bir ağırlık katsayısı hesaplanır (Hu ve ark., 2018).

Son aşama olan Reweight (Yeniden Ağırlıklandırma) aşamasında, her kanalın özgün özellik haritası, yukarıda hesaplanan ağırlık katsayıları ile çarpılarak yeniden ölçeklendirilir. Böylece, her kanalın önemi dinamik olarak ayarlanmış olur (Wang ve ark., 2020).

SE bloğu mimarisi şekil 2.7.'de gösterilmiştir.



Şekil 2.7. Squeeze ve Excitation Mimarisi

2.4.16. Performans kriterleri ve hesaplanması

Bu çalışmada, meme histopatolojik görüntülerin kanser türü açısından sınıflandırılması için elde edilen sonuçların performans değerlendirmesi yapılmıştır.

Performans kriterleri, bir sistemin, sürecin veya modelin etkinliğini ve başarısını değerlendirmek amacıyla kullanılan spesifik ölçütler ve değerlendirme parametreleridir. Bu kriterler, sistemin belirlenen hedeflere ne derece ulaştığını, performansını nasıl sergilediğini ve olası iyileştirme alanlarını tespit etmek için kritik bir rol oynar. Performans kriterleri, genellikle belirli bir bağlam veya çalışma ortamı içinde tanımlanır ve bu bağlamda ölçülür. Bu ölçütler, sistemin genel verimliliğini, doğruluğunu,

sürdürülebilirliğini ve hedeflere ulaşma kapasitesini anlamak ve geliştirmek amacıyla sistematik bir şekilde ele alınır.

Performans kriterlerinin etkili bir şekilde belirlenmesi ve uygulanması, hem mevcut durumun kapsamlı bir analizini gerektirir hem de uzun vadeli hedeflerin gerçekleştirilmesine yönelik stratejik planların yapılmasını sağlar. Bu bağlamda, performans kriterleri, sistemlerin karar alma süreçlerinde hayati bir öneme sahiptir, çünkü elde edilen veriler doğrultusunda sistemin iyileştirilmesi ve optimize edilmesi mümkündür.

Bu kriterlerin matematiksel temelleri de oldukça önemlidir ve değerlendirme süreçlerinde yaygın olarak kullanılan metrikler aracılığıyla ifade edilir. Özellikle doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru gibi metrikler, bir modelin performansını nicel olarak değerlendirmekte kullanılan temel ölçütlerdir. Aşağıda bu metriklerin formülleri sunulmuştur:

Doğruluk (Accuracy): Bir modelin doğru tahminlerinin, toplam tahminler içindeki oranını ifade eder ve genellikle aşağıdaki formül ile hesaplanır:

$$\text{Doğruluk} = \frac{\text{Doğru Pozitifler} + \text{Doğru Negatifler}}{\text{Toplam Pozitifler} + \text{Toplam Negatifler}}$$

Kesinlik (Precision): Modelin doğru pozitif tahminlerinin, tüm pozitif tahminler içindeki oranını belirler ve şu şekilde formüle edilir:

$$\text{Kesinlik} = \frac{\text{Doğru Pozitifler}}{\text{Doğru Pozitifler} + \text{Yanlış Pozitifler}}$$

Duyarlılık (Recall): Modelin doğru pozitif tahminlerinin, gerçek pozitifler içindeki oranını ifade eder ve aşağıdaki şekilde hesaplanır:

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitifler}}{\text{Doğru Pozitifler} + \text{Yanlış Negatifler}}$$

F1 Skoru: Kesinlik ve duyarlılığın harmonik ortalaması olarak tanımlanan bu metrik, özellikle dengesiz veri kümelerinde model performansını değerlendirmede kullanılır:

$$\text{F1 Skoru} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

Bu metrikler, performans değerlendirmesi süreçlerinde, modelin genel başarısını ve hatalarını anlamak için kritik öneme sahiptir. Bu sayede, modelin güçlü ve zayıf yönleri belirlenebilir ve gerekli iyileştirmeler yapılabilir.

3. MATERYAL VE METOT


3.1 Araştırma Modeli

Bu tez çalışması kapsamında yeni bir CNN modeli önerilmiştir. Önerilen CNN modeli bulgular ve tartışma başlığının altında yer alan Önerilen CNN Modelinin Yapısı başlığında detaylı olarak açıklanmıştır.

3.2. Veri Toplama Süreci ve Veri Toplama Araçları

Meme Kanseri Histopatolojik Görüntü Sınıflandırması (BreakHis) veri seti, Brezilya'nın Parana şehrinde bulunan ve <http://www.prevencaodiagnose.com.br> web sitesinden erişilebilen Patolojik Anatomi ve Sitopatoloji Laboratuvarı (P&D) ile ortaklaşa geliştirilmiştir.

Meme Kanseri Histopatolojik Görüntü Sınıflandırması (BreakHis) veri seti, meme kanserine yönelik histopatolojik görüntülerin sınıflandırılmasında araştırmacılara katkı sunan kapsamlı bir veri kümesidir. Bu veri seti, Brezilya'nın Parana şehrinde bulunan Patolojik Anatomi ve Sitopatoloji Laboratuvarı (P&D) ile ortaklaşa geliştirilmiş ve araştırmacıların kullanımına sunulmuştur. Veri seti, farklı büyütme seviyelerinden (40X, 100X, 200X, 400X) elde edilen 7,909 histopatolojik görüntüyü içermekte ve hem iyi huylu (benign) hem de kötü huylu (malignant) tümör sınıfları için alt kategorilere ayrılmaktadır (Spanhol ve ark., 2016).



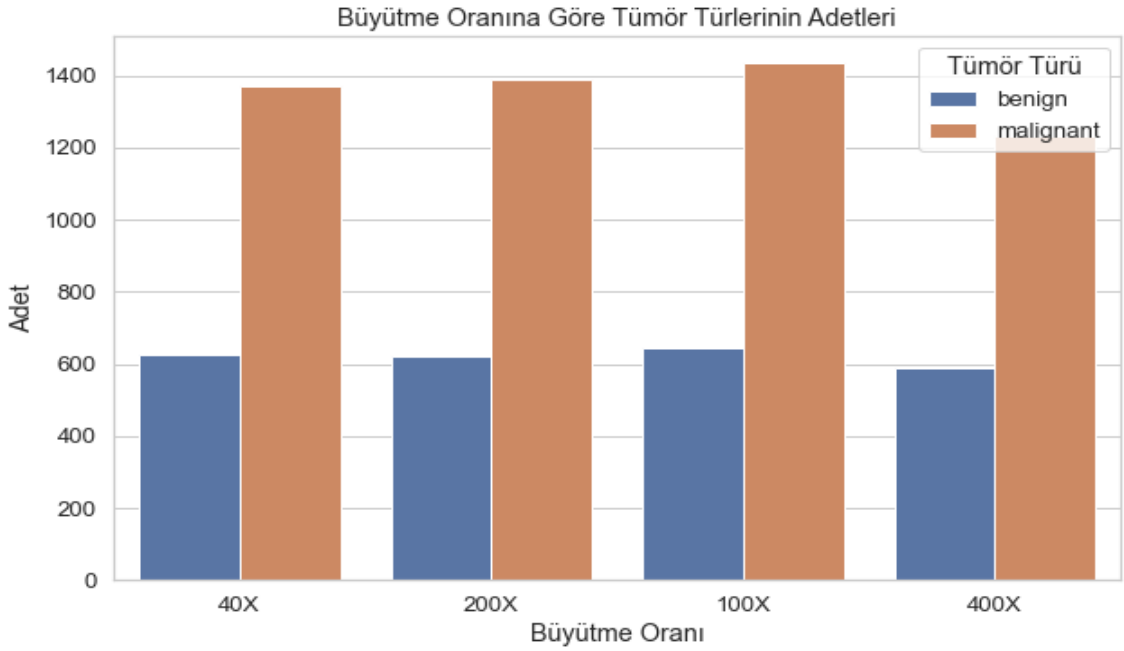
Şekil 3.1. Meme Kanseri Görüntülemeleri

Meme tümörü dokusunun toplam 7,909 mikroskopik görüntüsünden oluşan bu veri seti, 82 hastadan titizlikle derlenmiştir. Bu görüntüler, özellikle 40X, 100X, 200X ve 400X olmak üzere çeşitli büyütme faktörleri kullanılarak çekilmiştir. Veri setinin



Şekil 3.2. Meme Kanserinde Histopatolojik Görüntüler

bileşenleri arasında 24 hastaya ait 2,480 görüntü, iyi huylu örnekleri sergiliyor. Buna karşılık, geri kalan 5,429 görüntü 58 hastaya atfediliyor ve kötü huylu numuneleri kapsıyor. İyi huylu veya kötü huylu olarak sınıflandırılan görüntülerin dağılımı, Şekil 3.3.'de değişen büyütme oranlarına göre gösterilmektedir.



Şekil 3.3. Büyütme Oranlarına Görüntü Dağılımı

Meme tümörü örnekleri İmmünohistokimya (IHC) yoluyla değerlendirmeye tabi tutuldu. Veri seti içindeki örnekler, alternatif olarak kısmi mastektomi veya eksizyonel biyopsi olarak da bilinen Cerrahi Açık Biyopsi yöntemi kullanılarak yaklaşık 3 µm kalınlığında kesitler elde edilerek elde edildi. Bu özel yöntem, iğne biyopsisi tekniklerine kıyasla daha önemli bir doku örneğinin çıkarılmasını içerir ve genel anestezi altında hastane ortamında gerçekleştirilir.

Meme dokusu biyopsi slaytlarının hazırlanmasının ardından hematoxilen ve eozin (HE) ile boyamaya tabi tutuldu. Bu hazırlık adımı, numuneleri histolojik incelemeye uygun hale getirmek için gerçekleştirildi ve P&D Laboratuvarı'ndan patologlar tarafından denetlendi.

Görüntüleme, SCC-131AN Samsung dijital renkli kamerayla tamamlanan, 3,3X büyütme röleli lens içeren bir Olympus BX-50 sistem mikroskobu kullanılarak gerçekleştirildi. Görüntüler 40X, 100X, 200X ve 400X büyütme oranlarında çekildi. Kamera 6,5 µm piksel boyutuna sahipti. Veri kümesindeki görüntülerin ham PNG formatında olması, normalizasyon veya renk standardizasyonundan yoksun olması, 700x460 piksel boyutlarında, 3 kanallı (RGB) ve her kanalda 8 bit derinlik sergilemesi dikkat çekicidir.

Veri seti iki ana gruba ayrılmıştır: iyi huylu tümörler ve kötü huylu tümörler. Histolojik olarak iyi huylu, malignite kriterlerinden yoksun, tipik olarak nispeten yavaş bir büyüme modeli ve lokalize özellikler sergileyen lezyonları belirtir. Tersine, kanserle eşanlamlı olan kötü huylu tümörler, komşu yapılara sızma ve bunları tehlikeye atma (lokal olarak istilacı) ve uzak bölgelere yayılma (metastaz yapma) ve sıklıkla ölümle sonuçlanan bir eğilime sahiptir.

Meme tümörleri, iyi huylu veya kötü huylu doğalarına bakılmaksızın, mikroskobik inceleme altında farklı hücresel görünüm sergiler ve bu da farklı tiplere göre sınıflandırılmasına yol açar. Veri seti şu anda dört farklı iyi huylu meme tümörü kategorisini kapsamaktadır: Adenosis (A), Fibroadenoma (F), Phyllodes Tümörü (PT) ve Tubular Adenoma (TA). Ayrıca meme kanserini oluşturan dört tip kötü huylu tümör de dahildir: Duktal Karsinom (DC), Lobüler Karsinom (LC), Müsinöz Karsinom (MC) ve Papiller Karsinom (PC).

1.3.1. Tümör türleri ve özellikleri

Adenoz (A): Adenoz, memedeki süt üreten keseler olan belirli lobüllerin normal iyi huylu boyutun ötesinde genişlemesi ile karakterize edilir. Bu durum, artan sayıda bez mevcut olduğunda ortaya çıkar ve iyi huylu meme tümörleriyle sonuçlanır.

Fibroadenom (F): Yaygın olarak görülen iyi huylu meme tümörleri olan fibroadenomlar, hem glandüler hem de stromal (bağ) dokudan oluşur.

Filloid Tümör (PT): Filloides Tümörü, memenin stromal dokusundan kaynaklanan, farklı özelliklere sahip tümörler oluşturan, nadir görülen iyi huylu bir meme hastalığıdır.

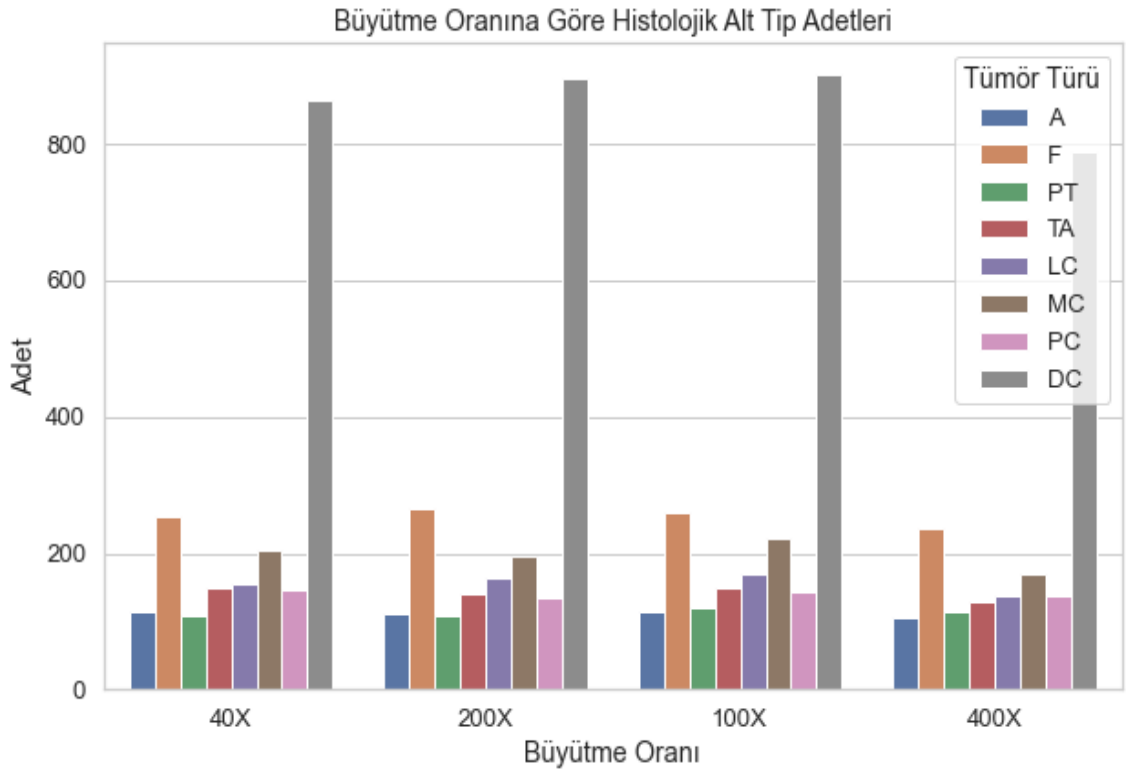
Tübüler Adenom (TA): Tübüler Adenom, adenom ve tübüllerden oluşan, yoğun şekilde paketlenmiş, düzenli sınırlı bir kitle olarak ortaya çıkan, iyi huylu bir meme lezyonu olarak tanımlanır.

Duktal Karsinom (DC): Duktal Karsinom, memenin süt kanallarında anormal hücrelerin varlığıyla karakterize edilen bir malignitedir.

Lobüler Karsinom (LC): Lobüler Karsinom, memenin süt üreten bezlerinden (lobüller) kaynaklanan bir kanser türüdür.

Müsinöz Karsinom (MC): Müsinöz Karsinom, kanser hücrelerinin müsin olarak bilinen bir madde tarafından sarıldığı nadir bir meme kanseri türüdür.

Papiller Karsinom (PC): Tüm meme kanserlerinin %1'inden azını oluşturan Papiller Karsinom, mikroskop altında görülebilen parmak benzeri çıkıntılarla karakterize, nadir görülen bir kanser türüdür.



Şekil 3.4. Büyütme Oranı ve Histolojik Alt Tiplere Göre Dağılımı

4. BULGULAR VE TARTIŞMA

Bu bölümde, yapılan çalışma doğrultusunda transfer öğrenme ve önerilen derin öğrenme mimarisi ile elde edilen sonuçlar sunulmakta ve bu sonuçların analizi yapılmaktadır. Aşağıda, meme kanseri histopatolojik görüntülerinin sınıflandırılmasında kullanılan derin öğrenme yöntemlerinin başarısı ve bu yöntemlerin sağladığı veriler detaylı olarak tartışılacaktır.

4.1. Meme Kanseri Histopatolojik Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması

Bu tez kapsamında, meme kanseri histopatolojik görüntülerinin sınıflandırılmasında derin öğrenme yöntemlerinin etkinliği araştırılmıştır. Deneysel çalışmaların ilk aşamasında, transfer öğrenme modelleri değerlendirilmiş ve bu modellerin sınıflandırma performansı incelenmiştir. Transfer öğrenme, büyük veri kümeleri üzerinde eğitilmiş önceden var olan modellerin kullanılmasıyla daha küçük veri kümelerinde başarılı sonuçlar elde etmemizi sağlar. Bu bağlamda, literatürde yaygın olarak kullanılan Xception, VGG16, ResNet101V2, ResNet152V2, InceptionV3, InceptionResNetV2, MobileNetV2, DenseNet201, NASNetMobile, EfficientNetB1 ve EfficientNetV2B1 gibi çeşitli transfer öğrenme modelleri deneysel çalışmalarda kullanılmıştır.

Deneysel çalışmalar süresince kullanılan modelin genel yapısı tablo 4.1'de gösterilmektedir. İlk aşamada, özellik çıkarımı için önceden eğitilmiş transfer öğrenme modelleri temel alınmıştır. Bu yapı üzerinde, ilk olarak bir global ortalama havuzlama katmanı eklenmiş, ardından sınıflandırma işlemleri için iki tam bağlantılı katman kullanılmıştır. Birinci tam bağlantılı katman 256 birime, ikinci katman ise 128 birime sahiptir ve her iki katmanda da Relu aktivasyon fonksiyonu uygulanmıştır. Sınıflandırma işlemi için son katman, iki çıkış birimine sahip softmax fonksiyonu ile yapılandırılmıştır. Bu katman, sınıflandırılacak sınıf sayısına göre özelleştirilmiştir. Her bir model, sınıflandırma performansını optimize etmek amacıyla belirli hiperparametrelerle yapılandırılmış olup, deneysel çalışmalarda kullanılan hiperparametreler Tablo 4.1.'de detaylandırılmıştır.

Tablo 4.1. Modellerin eğitimi sırasında kullanılan hiperparametreler

Hiperparametre	Değer
Learning Rate Azaltma	
- Monitor	val_loss
- Factor	0.2
- Patience	5
- Min Learning Rate	0.001
Erken Durdurma	
- Monitor	val_loss
- Patience	5
Model Derleme	
- Optimizer	adam
- Loss Function	categorical_crossentropy
- Metrics	accuracy
Eğitim Süresi	200 epoch
Giriş Görüntü Boyutu	128 x 128
Aktivasyon Fonksiyonu	relu

Hiperparametreler belirlendikten sonra, görüntüler modele verilmeden önce kapsamlı bir veri ön işleme sürecine tabi tutulmuştur. Bu süreçte en önemli adım, görüntülerin normalize edilmesidir. Normalize işlemi, modelin daha tutarlı sonuçlar üretmesi ve hızlı öğrenmesi açısından büyük önem taşır. Tüm görüntüler 1./255 ölçeklendirme ile normalize edilmiştir.

Görüntülerin hazırlanmasının ardından, modelin genelleme kabiliyetini artırmak ve overfitting'i azaltmak amacıyla veri artırma (data augmentation) işlemi uygulanmıştır. Bu işlem, TensorFlow kütüphanesinin ImageDataGenerator yöntemi kullanılarak gerçekleştirilmiştir. Veri artırma sürecinde kullanılan parametreler şunlardır:

- Rotation Range: 15 derece
- Horizontal Flip: True
- Shear Range: 0.1
- Fill Mode: 'nearest'
- Zoom Range: 0.1

Bu parametreler, veri setine çeşitli dönüşümler uygulayarak modelin daha çeşitli ve kapsamlı bir veri kümesiyle eğitilmesini sağlamıştır. Bu sayede modelin farklı durumlara karşı dayanıklılığı ve genel performansı artırılmıştır. Tüm bu ön işleme ve veri

artırma adımlarından sonra, deneysel çalışmalarda transfer öğrenme modelleri kullanılarak sonuçlar elde edilmiştir. Transfer öğrenme modelleri ile yapılan deneysel çalışmanın sonuçları Tablo 4.2'de sunulmuştur.

Tablo 4.2. Transfer öğrenme modelleri performans sonuçları

Model	Doğruluk(%)	Hassasiyet(%)	Geri Çağırma(%)	F1 Score(%)
Xception	89,8905	91,1600	89,8905	90,1038
VGG16	80,4549	80,2839	80,4549	80,3573
ResNet101V2	71,7776	77,8722	71,7776	63,6512
ResNet152V2	75,4844	83,3402	75,4844	76,2543
InceptionV3	92,1651	92,1502	92,1651	92,1570
InceptionResNetV2	84,9200	89,1306	84,9200	85,3941
MobileNetV2	54,5072	66,1422	54,5072	55,3305
DenseNet201	82,8138	83,7568	82,8138	81,4287
NASNetMobile	61,5838	61,8993	61,5838	61,7357
EfficientNetB1	25,5265	29,5405	25,5265	19,7398
EfficientNetV2B1	58.3825	47.0670	58.3825	51.5666

Tablo 4.2.'de, transfer öğrenme modellerinin performans sonuçları çeşitli metrikler açısından karşılaştırılmıştır. Bu metrikler; doğruluk (accuracy), hassasiyet (precision), geri çağırma (recall) ve F1 skoru olarak belirlenmiştir. Her modelin farklı veri setlerinde gösterdiği performans, modelin genel yeteneği hakkında önemli bilgiler sunmaktadır.

- ✓ Xception ve InceptionV3 modelleri en yüksek performansı göstermiştir. Xception modeli %89,89 doğruluk, %91,16 hassasiyet, %89,89 geri çağırma ve %90,10 F1 skoru ile öne çıkarken, InceptionV3 modeli %92,17 doğruluk, %92,15 hassasiyet, %92,17 geri çağırma ve %92,16 F1 skoru ile en yüksek değerlere ulaşmıştır.
- ✓ DenseNet201 ve InceptionResNetV2 modelleri de yüksek performans göstermiştir. DenseNet201, %82,81 doğruluk ile yüksek bir performans sergilerken, hassasiyet ve geri çağırma değerleri de oldukça iyidir. InceptionResNetV2 modeli ise %84,92 doğruluk ve %89,13 hassasiyet ile dikkat çekmektedir.
- ✓ VGG16 ve ResNet152V2 modelleri orta seviyede performans göstermiştir. VGG16 modeli %80,45 doğruluk ile ortalama bir performans sergilemiştir. ResNet152V2 modeli ise %75,48 doğruluk ile benzer bir performans göstermiştir.

- ✓ ResNet101V2 ve MobileNetV2 modelleri daha düşük performans sergilemiştir. ResNet101V2 %71,78 doğruluk ile nispeten düşük kalırken, NASNetMobile %61,58 doğruluk ile daha da düşük bir performans göstermiştir.
- ✓ MobileNetV2 ve EfficientNetV2B1 modelleri düşük performans göstermiştir. MobileNetV2 %54,51 doğruluk ile nispeten düşük kalırken, EfficientNetV2B1 %58.38 doğruluk ile benzer seviyelerde kalmıştır.
- ✓ EfficientNetB1 modeli en düşük performansı göstermiştir. %25,53 doğruluk, %29,54 hassasiyet, %25,53 geri çağırma ve %19.74 F1 skoru ile diğer modellere kıyasla çok daha düşük performans sergilemiştir.

Genel olarak, InceptionV3 ve Xception modelleri en iyi performansı sergilemiş olup, bu modellerin diğerlerine kıyasla daha iyi genelleme ve doğruluk sağladığı görülmektedir. Diğer modeller ise farklı derecelerde başarı göstermiştir ve belirli uygulamalara göre uygunluğu değerlendirilebilir.

Önceki transfer öğrenme modelleri ile yapılan deneysel çalışmaların ardından, bu veri setine özgü yeni özel bir CNN modeli geliştirilmiştir. Bu model, çeşitli katmanlar ve sıkıştırma-uyarı (squeeze-excite) mekanizmaları kullanarak geliştirilmiş ve optimize edilmiştir.

4.2. Önerilen CNN Modelinin Yapısı

4.2.1. Özel convolutional neural network modeli

Önceki transfer öğrenme modelleri ile yapılan deneysel çalışmaların ardından, özel bir CNN modeli geliştirilmiştir. Bu model, çeşitli katmanlar ve sıkıştırma-uyarı (squeeze-excite) mekanizmaları kullanılarak optimize edilmiştir. Şekil 12'de önerilen model gösterilmiştir. Aşağıda, modelin yapısı ve her bir katmanın işlevi detaylı bir şekilde açıklanmıştır.

4.2.1.1. Katman: ilk konvolüsyon katmanı

- **Conv2D (64, (1, 1)):** İlk katmanda 64 filtre ve (1, 1) boyutunda bir çekirdek kullanılarak, giriş verisinin özellikleri çıkarılmaktadır. Bu katmanda bias kullanılmamaktadır ve çekirdek düzenleyici olarak L2 normu kullanılmıştır. Çekirdek başlangıcı 'he_normal' olarak ayarlanmıştır.

- **BatchNormalization**: Konvolüsyon katmanının ardından, modelin eğitim sürecini hızlandırmak ve kararlılığı artırmak amacıyla Batch Normalization uygulanmıştır.
- **Activation**: Aktivasyon fonksiyonu olarak ReLU kullanılmıştır.
- **SqueezeExcite**: Sıkıştırma-uyarı mekanizması, kanalların önem derecesini belirleyerek daha etkili özellik çıkarımı sağlamaktadır.
- **MaxPooling2D (2, 2)**: Maksimum havuzlama işlemi, uzaysal boyutları küçülterek hesaplama yükünü azaltmakta ve önemli özellikleri öne çıkarmaktadır.

4.2.1.2. Katman: ikinci konvolüsyon katmanı

- **Conv2D (96, (3, 3))**: İkinci katmanda 96 filtre ve (3, 3) boyutunda bir çekirdek kullanılmaktadır. Bu katman da bias kullanılmadan ve L2 normu ile düzenlenmiştir.
- **BatchNormalization**
- **ReLU**
- **SqueezeExcite**
- **MaxPooling2D (2, 2)**

4.2.1.3. Katman: üçüncü konvolüsyon katmanı

- **Conv2D (128, (3, 3))**: Üçüncü katmanda 128 filtre ve (3, 3) boyutunda bir çekirdek kullanılmaktadır.
- **BatchNormalization**
- **ReLU**
- **SqueezeExcite**
- **MaxPooling2D (2, 2)**

4.2.1.4. Katman: dördüncü konvolüsyon katmanı

- **Conv2D (256, (3, 3))**: Dördüncü katmanda 256 filtre ve (3, 3) boyutunda bir çekirdek kullanılmaktadır.
- **BatchNormalization**
- **ReLU**
- **SqueezeExcite**
- **MaxPooling2D (2, 2)**

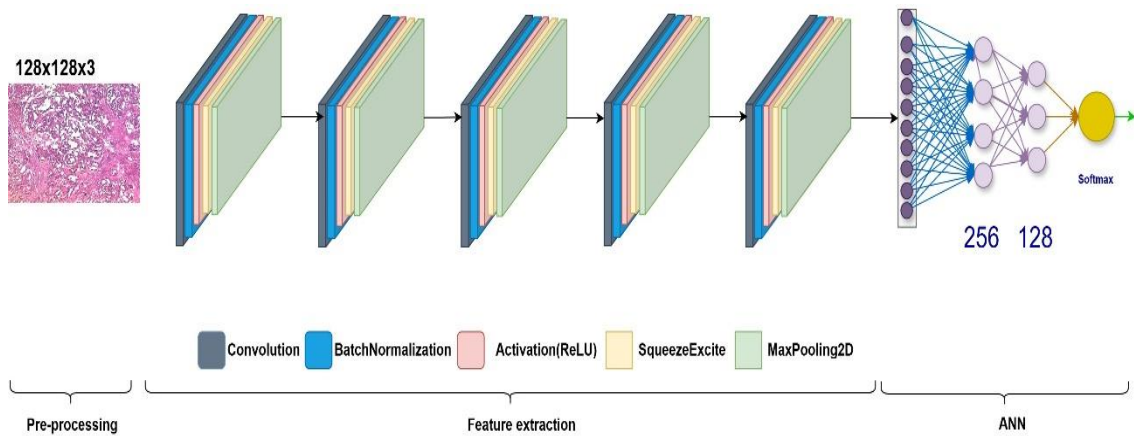
4.2.1.5. Katman: beşinci konvolüsyon katmanı

- **Conv2D (256, (3, 3))**: Beşinci katmanda 256 filtre ve (3, 3) boyutunda bir çekirdek kullanılmaktadır.
- **BatchNormalization**
- **ReLU**
- **SqueezeExcite**
- **MaxPooling2D (2, 2)**

4.2.1.6. Son Katmanlar:

- **Flatten**: Tüm konvolüsyonel katmanların çıktıları düzleştirilir ve yoğun katmanlara (dense layers) aktarılır.
- **Dense (256, ReLU)**: 256 nöronlu ve ReLU aktivasyon fonksiyonuna sahip yoğun katman.
- **Dropout (0.1)**: Aşırı öğrenmeyi (overfitting) önlemek için %10 dropout uygulanır.
- **Dense (128, ReLU)**: 128 nöronlu ve ReLU aktivasyon fonksiyonuna sahip ikinci yoğun katman.
- **Dense (2, Softmax)**: İki sınıflı çıktılar için softmax aktivasyon fonksiyonu kullanılarak son yoğun katman.

Yukarıda detaylı olarak anlatılan ve bu tez çalışmasında önerilen Model şekil 12.1.'de gösterilmiştir.



Şekil 4.1. Önerilen Model

4.2.2. Modelin optimizasyonu ve performansı

Modelin optimizasyonu için çeşitli hiperparametreler ve düzenleyiciler (regülasyonlar) kullanılmıştır. Her bir konvolüsyon katmanında kullanılan Batch Normalization ve SqueezeExcite mekanizmaları, modelin genel performansını artırmakta ve eğitim sürecini hızlandırmaktadır. Ayrıca, MaxPooling2D katmanları ile modelin karmaşıklığı ve hesaplama maliyeti azaltılmıştır. Yoğun katmanlar (dense layers) arasındaki Dropout katmanı ise aşırı öğrenmeyi engelleyerek modelin genelleme yeteneğini artırmaktadır.

Bu özel CNN modelinin performansı, transfer öğrenme modelleri ile yapılan deneysel çalışmalardan daha üstün çıkmıştır. Önerilen model, doğruluk (accuracy), hassasiyet (precision), geri çağırma (recall) ve F1 skoru metriklerinde transfer öğrenme modellerine kıyasla daha yüksek sonuçlar elde etmiştir. Bu durum, önerilen modelin belirli veri kümeleri ve görevler için daha uygun ve verimli olduğunu göstermektedir. Modelin performans sonuçları, tez çalışmasının önemli bir katkısı olarak gelecekteki araştırmalar için güçlü bir referans oluşturmaktadır.

Bu evrişim katmanlarının ardından, düzleştirme (flattening) katmanı ve üç tam bağlantılı (dense) katman eklenmiştir. Tam bağlantılı katmanlar sırasıyla 256 ve 128 nöronlu olup, ReLU aktivasyon fonksiyonları kullanılmıştır. Çıkış katmanında ise 2 nöron ve softmax aktivasyon fonksiyonu kullanılmıştır.

Yukarıda bahsedilen model ile yapılan deneysel çalışmalarda, önerilen modelin çeşitli parametreleri ile farklı denemeler yapılmıştır. Önerilen model ile elde edilen sonuçlar, transfer öğrenme modelleri arasında en iyi skorları elde eden modellerle karşılaştırılmıştır. Bu sonuçlar, Tablo 4.3'te gösterilmiştir. Bu çalışmalar sonucunda, önerilen modelin, transfer öğrenme modellerinden daha iyi performans gösterdiği belirlenmiştir.

Tablo 4.3. Model Performans Sonuçları

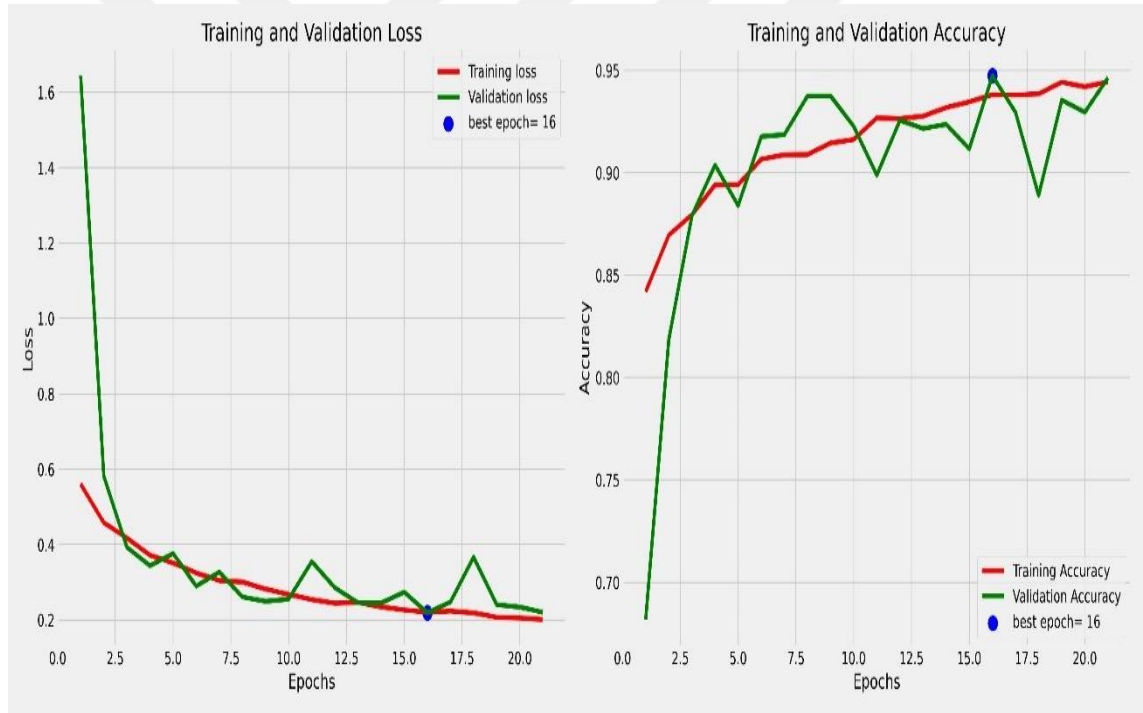
Model	Doğruluk (%)	Hassasiyet(%)	Geri Çağırma(%)	F1 Score(%)
Xception	89,89	91,1600	89,8905	90,1038
InceptionV3	92,16	92,1502	92,1651	92,1570
Önerilen Model	93,93	94,1583	93,9343	93,9892

Tablo 3'te görüldüğü üzere, önerilen model, bir önceki deneysel çalışmalarda en iyi performansı gösteren transfer öğrenme modellerinden Xception ve InceptionV3'ten

daha yüksek performans sergilemiştir. Önerilen model, doğruluk (accuracy), hassasiyet (precision), recall ve F1 skoru metriklerinde en yüksek değerlere ulaşarak diğer modellerden üstün olduğunu göstermektedir.

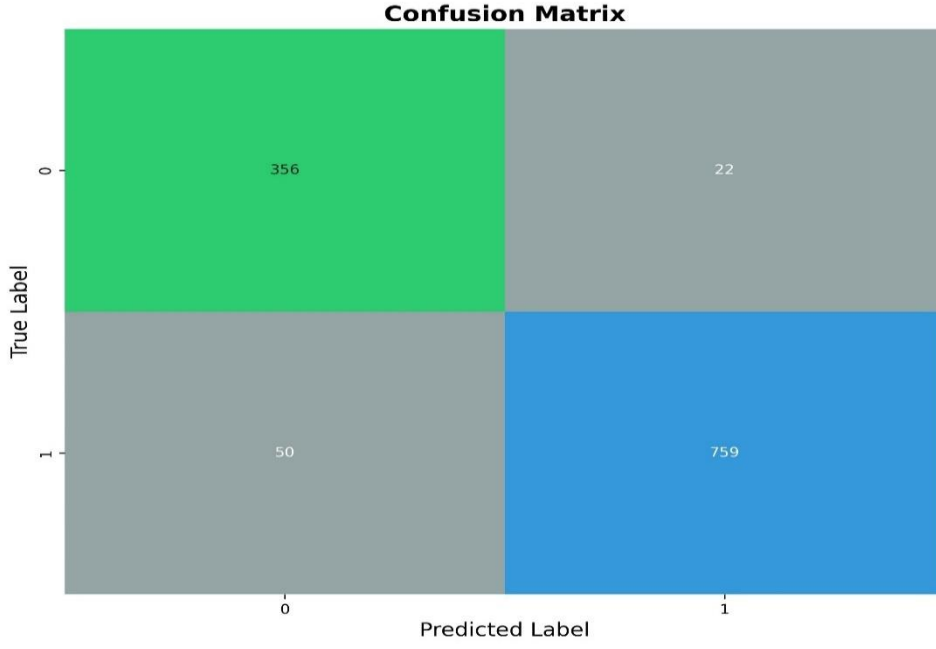
Önerilen model, %93.93 doğruluk oranı ile diğer modellerden daha iyi sonuçlar elde etmiştir. Bu, modelin genel olarak doğru tahminlerde bulunma oranının yüksek olduğunu ifade etmektedir. Ayrıca, %94.15 hassasiyet değeri, modelin pozitif sınıfları doğru bir şekilde tanımlama başarısını ortaya koymaktadır. Modelin %93.93 recall değeri, gerçek pozitifleri doğru bir şekilde tanıma oranını yansıtmaktadır. F1 skoru ise %93.98 olup, bu değer, modelin hem hassasiyet hem de geri çağırma oranlarının dengeli olduğunu göstermektedir.

Önerilen model ile yapılan deneysel sonuçlarda modelin accuracy ve loss grafiği şekil 4.2’de gösterilmiştir.



Şekil 4.2. Önerilen Modelin Loss Ve Accuracy Grafiği

Önerilen modelin karmaşıklık matrisi Şekil 4.3.’de gösterilmiştir.



Şekil 4.3. Önerilen Modelin Karmaşıklık Matrisi

Önerilen özel CNN modelinin performansı, transfer öğrenme modelleri ile yapılan deneysel çalışmalarla karşılaştırıldığında önemli ölçüde üstün bulunmuştur. Özellikle, modelin sıkıştırma-uyarı (squeeze-excite) mekanizmaları ve optimize edilmiş katman yapısı, sınıflandırma doğruluğunu artırarak daha başarılı sonuçlar elde edilmesine katkı sağlamıştır. Model, sadece doğruluk metriğinde değil, aynı zamanda F1 skoru, hassasiyet (precision) ve duyarlılık (recall) gibi diğer önemli performans göstergelerinde de transfer öğrenme modellerini geride bırakmıştır. Bu başarı, önerilen CNN modelinin veri kümesi üzerinde daha güçlü bir genelleme kabiliyeti sergilediğini ve daha karmaşık özellikleri etkin bir şekilde öğrenebildiğini göstermektedir. Elde edilen bu bulgular, tez çalışmasının literatüre yaptığı katkıyı pekiştirmekte ve önerilen modelin belirli görevler için oldukça verimli olduğunu kanıtlamaktadır.

5. SONUÇ

Bu çalışmada, meme kanseri histopatolojik görüntülerinin sınıflandırılması için özel olarak tasarlanmış bir CNN modeli geliştirilmiş ve bu modelin performansı, çeşitli transfer öğrenme teknikleri ile karşılaştırılmıştır. Araştırmanın ana amacı, meme kanseri tespitinde en etkili model mimarisini ve hiperparametreleri belirlemektir. Deneysel sonuçlar, Xception, VGG16, ResNet101V2, ResNet152V2, InceptionV3, InceptionResNetV2, MobileNetV2, DenseNet201, NASNetMobile, EfficientNetB1 ve EfficientNetV2B1 gibi transfer öğrenme modellerinin performansını detaylı bir şekilde değerlendirmiştir.

Resim sınıflandırma görevleri için önceden eğitilmiş transfer öğrenme modelleri, ilk deneysel aşamada kullanılmıştır. Bu modeller, büyük ölçekli veri kümeleri üzerinde önceden eğitilmiş olup, model performansını optimize etmek amacıyla öğrenme oranı, kayıp fonksiyonu, optimizasyon algoritması ve veri artırma teknikleri titizlikle belirlenmiştir. Veri artırma işlemleri, modelin genelleme kapasitesini artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla rotasyon, genişletme, kırpma ve yatay çevirme gibi tekniklerle gerçekleştirilmiştir.

Modeller, doğruluk, hassasiyet, geri çağırma ve F1 puanı gibi önemli performans ölçütlerine göre değerlendirilmiştir. Xception ve InceptionV3 modelleri sırasıyla %89,89 ve %92,17 doğruluk oranları ile en yüksek performansı göstermiş, bu modeller aynı zamanda diğer metriklerde de yüksek başarı göstermiştir. Öte yandan, MobileNetV2 ve EfficientNetV2B1 modelleri, %54,51 ve %58,38 gibi nispeten daha düşük doğruluk oranlarına sahip olmuştur.

Transfer öğrenme modellerinin değerlendirilmesinin ardından, sınıflandırma performansını daha da iyileştirmek amacıyla özel bir CNN modeli geliştirilmiştir. Bu model, özellik çıkarımını ve model istikrarını artırmak için sıkıştırma-uyarı (squeeze-excite) mekanizmaları ve grup normalleştirme tekniklerini içermektedir. Model mimarisi, batch normalizasyonu ve ReLU etkinleştirme fonksiyonları ile desteklenen çoklu konvolüsyon katmanlarından oluşmaktadır. Önerilen CNN modeli, %93,93 doğruluk, %93,93 hassasiyet ve %93,98 F1 puanı ile transfer öğrenme modellerini geride bırakarak üstün performans göstermiştir. Bu sonuçlar, önerilen modelin mimarisinin ve optimizasyon tekniklerinin meme kanseri görüntü sınıflandırma görevlerinde yüksek etkinlik sağladığını ortaya koymaktadır.

Bu çalışmanın bulguları, otomatik meme kanseri tespiti sistemlerinin geliştirilmesinde önemli etkiler yaratmaktadır. Önerilen CNN modelinin üstün performansı, tıbbi görüntü analizinde yüksek doğruluk ve güvenilirlik elde etmek için özel derin öğrenme mimarilerinin potansiyelini vurgulamaktadır. Gelecekteki araştırmalar, daha karmaşık model mimarilerini inceleyerek ve ek veri artırma tekniklerini entegre ederek bu sonuçları daha da geliştirebilir. Ayrıca, bu modellerin klinik ortamlarda uygulanması, meme kanseri teşhisinde sağlık uzmanlarına güçlü araçlar sağlayarak erken teşhis ve tedavi planlamasını iyileştirebilir. Bu modellerin mevcut teşhis iş akışlarıyla entegrasyonu, daha doğru ve zamanında teşhislere yol açarak hastaların sonuçlarını iyileştirebilir. Sonuç olarak, bu çalışma, özellikle önerilen CNN mimarilerinin meme kanseri resim sınıflandırmasını ilerletmek için derin öğrenme modellerinin potansiyelini ortaya koymakta ve bu alandaki gelecekteki araştırma ve geliştirmeler için yeni bir kıstas oluşturmaktadır.

6. KAYNAKLAR

- Agfarap, A. F., 2019. Deep learning using rectified linear units (ReLU), *arxiv preprint arxiv*, 1803-08375.
- Akademi Yapay Zekâ, 2024. *Yapay Sinir Ağları Hakkında*, Retrieved from.
- Al-Azzawi, A., Ouadou, A., Max, H., Duan, Y., Tanner, J. J., Cheng, J. 2020. Deepcryopicker, Fully automated deep neural network for single protein particle picking in cryo-EM. *BMC Bioinformatics*, 21 (1), 1-38.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Hasan, M., Van Essen, B. C., Awwal, A. A., Asari, V. K., 2019. A state-of-the-art survey on deep learning theory and architectures, *Electronics*, 8 (3), 292.
- Alom, M. Z., Yakopcic, C., Nasrin, M. S., Taha, T. M., Asari, V. K., 2019. Breast cancer classification from histopathological images with inception recurrent residual convolutional neural network, *Journal of Digital Imaging*, 32 (4), 605–617.
- Alzubaidi, L., Al-Shamma, O., Fadhel, M. A., Farhan, L., Zhang, J., Duan, Y., 2020. Optimizing the performance of breast cancer classification by employing the same domain transfer learning from hybrid deep convolutional neural network model, *Electronics*, 9 (3), 445.
- Anderson, D. and McNeill, G., 1992. Artificial neural networks technology, *Kaman Sciences Corporation*, 258 (6), 1–83.
- Ara, S., Das, A., Dey, A., 2021. Malignant and benign breast cancer classification using machine learning algorithms, In *International Conference on Artificial Intelligence (ICAI)*, pp. 97–101, IEEE.
- Arnold, M., Pandeya, N., Byrnes, G., Renehan, A. G., Stevens, G. A., Ezzati, M., Ferlay, J., Miranda, J. J., Romieu, I., Dikshit, R., Forman, D., Soerjomataram, I., 2015. Global burden of cancer attributable to high body-mass index in 2012, A population-based study, *The Lancet Oncology*, 16 (1), 36–46.
- Arulkumaran, K., Deisenroth, M. P., Brundage, M., Bharath, A. A., 2017. Deep reinforcement learning, A brief survey, *IEEE Signal Processing Magazine*, 34 (6), 26-38.
- Bacanin, N., Bezdán, T., Tuba, E., Strumberger, I., Tuba, M., 2020. Optimizing convolutional neural network hyperparameters by enhanced swarm intelligence metaheuristics, *Algorithms*, 13 (3), 67.
- Bacha, S., and Taouali, O., 2022. A novel machine learning approach for breast cancer diagnosis, *Measurement*, 187, 110233.

- 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.
- Barisoni, L., Lafata, K. J., Hewitt, S. M., Madabhushi, A., Balis, U. G., 2020. Digital pathology and computational image analysis in nephropathology, *Nature Reviews Nephrology*, 16 (11), 669–685.
- Batur Dinler, Ö., and Aydın, N., 2020. An optimal feature parameter set based on gated recurrent unit recurrent neural networks for speech segment detection, *Applied Sciences*, 10 (4), 1273.
- Calhoun, K. E., and Anderson, B. O., 2014. Needle biopsy for breast cancer diagnosis, A quality metric for breast surgical practice, *Journal of Clinical Oncology*, 32 (21), 2191–2192.
- Chowdhury, D., Das, A., Dey, A., Sarkar, S., Dwivedi, A. D., Rao Mukkamala, R., Murmu, L., 2022. ABCanDroid: A cloud-integrated android app for non-invasive early breast cancer detection using transfer learning, *Sensors*, 22 (3), 832.
- Collaborative Group on Hormonal Factors in Breast Cancer, 2012. Menarche, menopause, and breast cancer risk: Individual participant meta-analysis, including 118,964 women with breast cancer from 117 epidemiological studies, *The Lancet Oncology*, 13 (11), 1141–1151.
- Cortes, J., Perez-García, J. M., Llombart-Cussac, A., Curigliano, G., El Saghir, N. S., Cardoso, F., Arribas, J., 2020. Enhancing global access to cancer medicines. *CA, A Cancer Journal for Clinicians*, 70 (2), 105–124.
- Dai, B., Chen, R. C., Zhu, S. Z., Zhang, W. W., 2018. Using random forest algorithm for breast cancer diagnosis, In *2018 International Symposium on Computer, Consumer and Control (IS3C)*, pp. 449–452, IEEE.
- Deniz, E., Şengür, A., Kadiroğlu, Z., Guo, Y., Bajaj, V., Budak, Ü., 2018. Transfer learning-based histopathologic image classification for breast cancer detection, *Health Information Science and Systems*, 6 (1), 1–7.
- Detienne, K. B., Detienne, D. H., Joshi, S. A., 2003. Neural networks as statistical tools for business researchers, *Organizational Research Methods*, 6 (2), 236–265.
- Lecun, Y., Bottou, L., Bengio, Y., Haffner, P., 1998. Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278-2324.
- Lehman, C. D. And Schnall, M. D., 2005. Imaging in breast cancer, Magnetic resonance imaging, *Breast Cancer Research*, 7 (5).
- Li, G., Zhang, M., Li, J., Lv, F., Tong, G., 2021. Efficient densely connected convolutional neural networks, *Pattern Recognition*, 109, 107610.

- Li, H. C., Deng, Z. Y., Chiang, H. H., 2020. Lightweight and resource-constrained learning network for face recognition with performance optimization, *Sensors*, 20 (21), 6114.
- Li, S., Yi, M., Dong, B., Tan, X., Luo, S., Wu, K., 2021. The role of exosomes in liquid biopsy for cancer diagnosis and prognosis prediction, *International Journal of Cancer*, 148 (11), 2640-2651.
- Liu, L., Wang, Y., Zhang, P., Qiao, H., Sun, T., Zhang, H., Shang, H., 2023. Collaborative transfer network for multi-classification of breast cancer histopathological images, *IEEE Journal of Biomedical and Health Informatics*.
- Loupe, G., Cho, K., Becot, C., Cranmer, K., 2019. QCD-aware recursive neural networks for jet physics, *Journal of High Energy Physics*, (1), 57.
- Majeed, W., Aslam, B., Javed, I., Khaliq, T., Muhammad, F., Ali, A., Raza, A., 2014. Breast cancer: Major risk factors and recent developments in treatment, *Asian Pacific Journal of Cancer Prevention*, 15 (8), 3353-3358.
- Man, R., Yang, P., Xu, B., 2020. Classification of breast cancer histopathological images using discriminative patches screened by generative adversarial networks, *IEEE Access*, 8, 155362-155377.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Hassabis, D., 2015. Human-level control through deep reinforcement learning. *Nature*, 518 (7540), 529-533.
- Mukkamala, R., Neeraja, P. S., Pamidi, S., Babu, T., Singh, T., 2018. Deep PCANet framework for the binary categorization of breast histopathology images, In *International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pp. 105-110, IEEE.
- Naji, M. A., El Filali, S., Aarika, K., Benlahmar, E. H., Abdelouhahid, R. A., Debauche, O., 2021. Machine learning algorithms for breast cancer prediction and diagnosis, *Procedia Computer Science*, 191, 487-492.
- Otálora, S., Marini, N., Müller, H., Atzori, M., 2021. Combining weakly and strongly supervised learning improves strong supervision in Gleason pattern classification, *BMC Medical Imaging*, 21 (1), 77.
- Özkan, İ., ve Ülker, E., 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- Öztemel, E., 2006. Yapay sinir ağları (2nd ed.), İstanbul, Papatya Yayıncılık.
- Palaz, D., Magimai-Doss, M., and Collobert, R., 2019. End-to-end acoustic modeling using convolutional neural networks for HMM-based automatic speech recognition, *Speech Communication*, 108, 15-32.

- Park, H. L., and Hong, J., 2014. Vacuum-assisted breast biopsy for breast cancer, *Gland Surgery*, 3 (2), 120-127.
- Park, H. L., and Kim, L. S., 2011. The current role of vacuum-assisted breast biopsy system in breast disease, *Journal of Breast Cancer*, 14 (1), 1.
- Pascanu, R., Gulcehre, C., Cho, K., Bengio, Y., 2014. How to construct deep recurrent neural networks, In *Proceedings of the second international conference on learning representations (ICLR)*.
- Patacchiola, M., Bronskill, J., Shysheya, A., Hofmann, K., Nowozin, S., Turner, R., 2022. Contextual squeeze-and-excitation for efficient few-shot image classification, *Advances in Neural Information Processing Systems*, 35, 36680-36692.
- Pratiher, S., Chatteraj, S., Agarwal, S., Bhattacharya, S., 2018. Grading tumor malignancy via deep bidirectional LSTM on graph manifold encoded histopathological image, In *2018 IEEE International Conference on Data Mining Workshops (ICDMW)*, pp. 674-681, IEEE.
- Rojas, K., and Stuckey, A., 2016. Breast cancer epidemiology and risk factors, *Clinical Obstetrics and Gynecology*, 59 (4), 651-672.
- Rumelhart, D. E., Hinton, G. E., Williams, R. J., 1986. Learning representations by back-propagating errors, *Nature*, 323 (6088), 533-536.
- Sadr, H., Pedram, M. M., Teshnehlab, M., 2019. A robust sentiment analysis method based on sequential combination of convolutional and recursive neural networks, *Neural Processing Letters*, 50 (3), 2745-2761.
- Salvi, M., Michielli, N., Molinari, F., 2020. Stain Color Adaptive Normalization (SCAN) algorithm: Separation and standardization of histological stains in digital pathology, *Computer Methods and Programs in Biomedicine*, 193, 105506.
- Schölkopf, B., and Smola, A. J., 2002. Learning with kernels: Support vector machines, regularization, optimization, and beyond, Cambridge, MA: MIT Press.
- Seely, J. M., and Alhassan, T., 2018. Screening for breast cancer in What should we be doing today? *Current Oncology*, 25 (1), 115.
- Shukla, K. K., Tiwari, A., Sharma, S., 2017. Classification of histopathological images of breast cancerous and non-cancerous cells based on morphological features, *Biomedical and Pharmacology Journal*, 10 (1), 353-366.
- Socher, R., Lin, C. C. Y., Ng, A. Y., Manning, C. D., 2011. Parsing natural scenes and natural language with recursive neural networks, In *Proceedings of the 28th International Conference on Machine Learning (ICML)*.
- Socher, R., Perelygin, A., Wu, J., Chuang, J., Manning, C. D., Ng, A. Y., Potts, C., 2013. Recursive deep models for semantic compositionality over a sentiment treebank, In

- Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1631-1642.
- Song, Y., Zou, J. J., Chang, H., Cai, W., 2017. Adapting fisher vectors for histopathology image classification, In *IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*, pp. 600-603, IEEE.
- Srivastava, N., Hinton, G., Krizhevsky, A., Salakhutdinov, R., 2014. Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, 15, 1929-1958.
- Sun, Y. S., Zhao, Z., Yang, Z. N., Xu, F., Lu, H. J., Zhu, Z. Y., Zhu, H. P., 2017. Risk factors and preventions of breast cancer, *International Journal of Biological Sciences*, 13 (11), 1387-1397.
- 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.
- Urban, G., Subrahmanya, N., Baldi, P., 2018. Inner and outer recursive neural networks for chemoinformatics applications, *Journal of Chemical Information and Modeling*, 58 (2), 207-211.
- Veta, M., Pluim, J. P., Van Diest, P. J., Viergever, M. A., 2014. Breast cancer histopathology image analysis: A review, *IEEE Transactions on Biomedical Engineering*, 61 (5), 1400-1411.
- Wang, Q., Wu, B., Zhu, P., Li, P., Zuo, W., Hu, Q., 2020. ECA-Net: Efficient channel attention for deep convolutional neural networks, In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 11534–11542.
- Wang, T., Lu, C., Yang, M., Hong, F., Liu, C., 2020. A hybrid method for heartbeat classification via convolutional neural networks, multilayer perceptrons and focal loss, *PeerJ Computer Science*, 6, 324.
- Zgajnar, J., 2017. Clinical presentation, diagnosis and staging of breast cancer, In *Breast Cancer Management for Surgeons*, 159-176.
- Zhang, W., Xu, C., Li, R., Cui, G., Wang, M., Wang, M., 2019. Correlation analysis between ultrasonography and mammography with other risk factors related to breast cancer, *Oncology Letters*.
- Zhou, D. X., 2020. Theory of deep convolutional neural networks: Downsampling, *Neural Networks*, 124, 319-327.

EKLER

EK 1. Alan Yazında Çalışmalar

Çalışma	Metodoloji	Başarı oranları	Notlar
F. A. Spanhol, L. S. Oliveira, C. Petitjean and L. Heutte, "Breast cancer histopathological image classification using Convolutional Neural Networks," <i>2016 International Joint Conference on Neural Networks (IJCNN)</i> , Vancouver, BC, Canada, 2016, pp. 2560-2567, doi: 10.1109/IJCNN.2016.7727519. keywords: {Neural networks},	CNN	% 80,8-% 85,6	
Song, Y., Zou, J. J., Chang, H., & Cai, W. (2017, April). Adapting fisher vectors for histopathology image classification. In <i>2017 IEEE 14th international symposium on biomedical imaging (ISBI 2017)</i> (pp. 600-603). IEEE.	CNN	82,9-87	VGG modeline transfer learning kullanılarak ve Fisher vektörlerinin adapte edilmesi kullanılmıştır.
Das, K., Karri, S. P. K., Roy, A. G., Chatterjee, J., & Sheet, D. (2017, April). Classifying histopathology whole-slides using fusion of decisions from deep convolutional network on a collection of random multi-views at multi-magnification.	CNN	94,67	

<p>In 2017 <i>IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)</i> (pp. 1024-1027). IEEE.</p>			
<p>Han, Z., Wei, B., Zheng, Y., Yin, Y., Li, K., & Li, S. (2017). Breast cancer multi-classification from histopathological images with structured deep learning model. <i>Scientific reports</i>, 7(1), 4172.</p>	CSDCNN	93,2	
<p>Wei, B., Han, Z., He, X., & Yin, Y. (2017, April). Deep learning model based breast cancer histopathological image classification. In <i>2017 IEEE 2nd international conference on cloud computing and big data analysis (ICCCBDA)</i> (pp. 348-353). IEEE.</p>	BiCNN	97	
<p>Garud, H., Karri, S. P. K., Sheet, D., Chatterjee, J., Mahadevappa, M., Ray, A. K., ... & Maity, A. K. (2017). High-magnification multi-views based classification of breast fine needle aspiration cytology cell samples using fusion of decisions from deep convolutional networks. In <i>Proceedings of the IEEE conference on computer vision</i></p>	CNN	89,7	GoogLeNet architecture

<i>and pattern recognition workshops</i> (pp. 76-81).			
Jamaluddin, M. F., Fauzi, M. F. A., & Abas, F. S. (2017, September). Tumor detection and whole slide classification of H&E lymph node images using convolutional neural network. In <i>2017 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)</i> (pp. 90-95). IEEE.	CNN	94	
Chang, J., Yu, J., Han, T., Chang, H. J., & Park, E. (2017, October). A method for classifying medical images using transfer learning: A pilot study on histopathology of breast cancer. In <i>2017 IEEE 19th international conference on e-health networking, applications and services (Healthcom)</i> (pp. 1-4). IEEE.	CNN	93	Google's Inception v3
Karthiga, R., & Narasimhan, K. (2018, March). Automated diagnosis of breast cancer using wavelet based entropy features. In <i>2018 Second international conference on electronics, communication and aerospace technology (ICECA)</i> (pp. 274-279). IEEE.	SVM	93,3	k-means - Discrete Wavelet Transform

<p>Song, Y., Chang, H., Gao, Y., Liu, S., Zhang, D., Yao, J., ... & Cai, W. (2018, April). Feature learning with component selective encoding for histopathology image classification. In <i>2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)</i> (pp. 257-260). IEEE.</p>	<p>CNN</p>	<p>90,8</p>	<p>Fisher Vector</p>
<p>Bardou, D., Zhang, K., & Ahmad, S. M. (2018). Classification of breast cancer based on histology images using convolutional neural networks. <i>Ieee Access</i>, 6, 24680-24693.</p>	<p>CNN</p>	<p>96,15% - 98,33</p>	<p>handcrafted features (DSIFT ve SURF)</p>
<p>Gupta, V., & Bhavsar, A. (2018). Sequential modeling of deep features for breast cancer histopathological image classification. In <i>Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops</i> (pp. 2254-2261).</p>	<p>CSDCNN</p>	<p>89,1-94,71</p>	<p>class structure-based deep convolution neural network</p>
<p>Mukkamala, R., Neeraja, P. S., Pamidi, S., Babu, T., & Singh, T. (2018, September). Deep PCANet framework for the binary categorization of breast histopathology images. In <i>2018 International Conference on</i></p>	<p>Principal Component Analysis Network (PCANet)</p>	<p>85,4-97,41</p>	

<i>Advances in Computing, Communications and Informatics (ICACCI)</i> (pp. 105-110). IEEE.			
TOĞAÇAR, M., & ERGEN, B. (2018, September). Deep learning approach for classification of breast cancer. In <i>2018 international conference on artificial intelligence and data processing (IDAP)</i> (pp. 1-5). IEEE.	CNN	93,4	AlexNet
Jonnalagedda, P., Schmolze, D., & Bhanu, B. (2018, October). [regular paper] mvpnets: Multi-viewing path deep learning neural networks for magnification invariant diagnosis in breast cancer. In <i>2018 IEEE 18th international conference on bioinformatics and bioengineering (BIBE)</i> (pp. 189-194). IEEE.	MVPNet	92,2	This paper presents a deep learning network, called MVPNet and a customized data augmentation technique, called NuView, for magnification independent diagnosis.
Pratiher, S., Chatteraj, S., Agarwal, S., & Bhattacharya, S. (2018, November). Grading tumor malignancy via deep bidirectional LSTM on graph manifold encoded	Graph Manifold Bi-LSTM	97,2	

<p>histopathological image. In 2018 <i>IEEE International Conference on Data Mining Workshops (ICDMW)</i> (pp. 674-681). IEEE.</p>			
<p>Ganesh, A., Vasanth, N. R., & George, K. (2018, November). Staining of histopathology slides using image style transfer algorithm. In 2018 <i>IEEE Symposium Series on Computational Intelligence (SSCI)</i> (pp. 1254-1260). IEEE.</p>	VGG19	96,2	
<p>Adeshina, S. A., Adedigba, A. P., Adeniyi, A. A., & Aibinu, A. M. (2018, November). Breast cancer histopathology image classification with deep convolutional neural networks. In 2018 <i>14th international conference on electronics computer and computation (ICECCO)</i> (pp. 206-212). Ieee.</p>	DCNN	91,5	
<p>Jannesari, M., Habibzadeh, M., Aboulkheyr, H., Khosravi, P., Elemento, O., Totonchi, M., & Hajirasouliha, I. (2018, December). Breast cancer histopathological image classification: a deep learning approach. In 2018 <i>IEEE international conference on</i></p>	Resnet152	96,4	

<i>bioinformatics and biomedicine (BIBM)</i> (pp. 2405-2412). IEEE.			
Angara, S., Robinson, M., & Guillén-Rondon, P. (2018, December). Convolutional neural networks for breast cancer histopathological image classification. In <i>2018 4th International Conference on Big Data and Information Analytics (BigDIA)</i> (pp. 1-6). IEEE.	CNN	90-91,3	
Elelimy, E., & Mohamed, A. A. (2018, December). Towards automatic classification of breast cancer histopathological image. In <i>2018 13th International Conference on Computer Engineering and Systems (ICCES)</i> (pp. 299-306). IEEE.	SVM	96,63	
Gu, Y., & Yang, J. (2018). Densely-connected multi-magnification hashing for histopathological image retrieval. <i>IEEE journal of biomedical and health informatics</i> , 23(4), 1683-1691.	densely-connected multi-magnification (DCMMH)	95,14-97	
Li, Y., Wu, J., & Wu, Q. (2019). Classification of breast cancer histology images using multi-size and discriminative patches based on deep	CNN	95	

learning. <i>Ieee Access</i> , 7, 21400-21408.			
Xu, B., Liu, J., Hou, X., Liu, B., Garibaldi, J., Ellis, I. O., ... & Qiu, G. (2019, April). Look, investigate, and classify: a deep hybrid attention method for breast cancer classification. In <i>2019 IEEE 16th international symposium on biomedical imaging (ISBI 2019)</i> (pp. 914-918). IEEE.	CNN + Partially Observable Markov Decision Process (POMDP)	96	
Xiang, Z., Ting, Z., Weiyan, F., & Cong, L. (2019, June). Breast cancer diagnosis from histopathological image based on deep learning. In <i>2019 Chinese Control And Decision Conference (CCDC)</i> (pp. 4616-4619). IEEE.	CNN (Inception-V3)	95,7	
Gupta, V., & Bhavsar, A. (2019). Partially-independent framework for breast cancer histopathological image classification. In <i>Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops</i> (pp. 0-0).	CNN	90,85-97	Fine tuned
Nguyen, P. T., Nguyen, T. T., Nguyen, N. C., & Le, T. T. (2019, October). Multiclass breast cancer classification	CNN	91	

using convolutional neural network. In <i>2019 International symposium on electrical and electronics engineering (ISEE)</i> (pp. 130-134). IEEE.			
George, K., Faziludeen, S., Sankaran, P., & Paul, J. K. (2019, October). Deep learned nucleus features for breast cancer histopathological image analysis based on belief theoretical classifier fusion. In <i>TENCON 2019-2019 IEEE Region 10 Conference (TENCON)</i> (pp. 344-349). IEEE.	CNN + LSTM	96,88	AlexNet, ResNet18, ResNet50
Alinsaif, S., & Lang, J. (2019, November). Shearlet-based techniques for histological image classification. In <i>2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)</i> (pp. 1424-1431). IEEE.	SVM	91,28	Our Shearlet feature space consists of Haralick texture features, segmentation-based Fractal Texture Analysis, Local Binary patterns, and Local Oriented Statistic Information Booster.

<p>Tituriya, A., & Sachdeva, S. (2019, November). Breast cancer histopathology image classification using AlexNet. In <i>2019 4th International conference on information systems and computer networks (ISCON)</i> (pp. 708-712). IEEE.</p>	<p>CNN</p>	<p>95,7</p>	<p>AlexNet</p>
<p>Spanhol, F. A. (2018). Automatic breast cancer classification from histopathological images: a hybrid approach. <i>Curitiba: Universidade Federal do Paraná.</i></p>	<p>ResNet Deep Convolution Neural Network (DCNN)</p>	<p>91,7</p>	
<p>Alinsaif, S., & Lang, J. (2020, May). Histological image classification using deep features and transfer learning. In <i>2020 17th Conference on Computer and Robot Vision (CRV)</i> (pp. 101-108). IEEE.</p>	<p>CNN+SVM</p>	<p>95,7</p>	<p>SqueezeNet-v1.1, MobileNet-v2, ResNet-18, and DenseNet-201</p>
<p>Yamlome, P., Akwaboah, A. D., Marz, A., & Deo, M. (2020, July). Convolutional neural network based breast cancer histopathology image classification. In <i>2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)</i> (pp. 1144-1147). IEEE.</p>	<p>CNN</p>	<p>91</p>	

Man, R., Yang, P., & Xu, B. (2020). Classification of breast cancer histopathological images using discriminative patches screened by generative adversarial networks. <i>IEEE access</i> , 8, 155362-155377.	DenseNet121- AnoGAN	85,20 – 99,13	
Yari, Y., Nguyen, T. V., & Nguyen, H. T. (2020). Deep learning applied for histological diagnosis of breast cancer. <i>IEEE Access</i> , 8, 162432-162448.	pre-trained DCNN	98	ResNet50 and DesneNet121
Al-Haija, Q. A., & Adebajo, A. (2020, September). Breast cancer diagnosis in histopathological images using ResNet-50 convolutional neural network. In <i>2020 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)</i> (pp. 1-7). IEEE.	Pre-trained ResNet50 CNN	99,10	
Abdelli, A., Saouli, R., Djemal, K., & Youkana, I. (2020, November). Combined datasets for breast cancer grading based on multi-CNN architectures. In <i>2020 Tenth International Conference on Image Processing Theory, Tools and Applications (IPTA)</i> (pp. 1-7). IEEE.	ResNet50, MobileNet	97,03-94,42	Data Augmentation and Transfer Learning

Sharma, S., & Mehra, R. (2020). Conventional machine learning and deep learning approach for multi-classification of breast cancer histopathology images—a comparative insight. <i>Journal of digital imaging</i> , 33(3), 632-654.	VGG16, VGG19, and ResNet50 + SVM	93,97% for 40×, 92,92% for 100×, 91,23% for 200×, and 91,79% for 400×	
Das, K., Conjeti, S., Chatterjee, J., & Sheet, D. (2020). Detection of breast cancer from whole slide histopathological images using deep multiple instance CNN. <i>IEEE Access</i> , 8, 213502-213511.	CNN	93,04	
Wang, C., Xiao, F., Zhang, W., Huang, S., Zhang, W., & Zou, P. (2021, November). Transfer learning and attention mechanism for breast cancer classification. In <i>2021 17th International Conference on Computational Intelligence and Security (CIS)</i> (pp. 75-79). IEEE.	CNN	94,11	VGG16 and ResNet50
Khairi, S. S. M., Bakar, M. A. A., Alias, M. A., Bakar, S. A., & Liong, C. Y. (2021, December). A Preliminary Study of Convolutional Neural Network Architectures for Breast Cancer Image	CNN	94,80	ResNet 18

Classification. In <i>2021 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)</i> (pp. 1-5). IEEE.			
Zhou, Y., Zhang, C., & Gao, S. (2022). Breast cancer classification from histopathological images using resolution adaptive network. <i>IEEE Access</i> , <i>10</i> , 35977-35991.	CNN	94,43	RANet + Data Balance + ADSVM
Muhammad, B., Özkaynak, F., Varol, A., & Tuncer, T. (2022, June). A novel deep feature extraction engineering for subtypes of breast cancer diagnosis: A transfer learning approach. In <i>2022 10th International Symposium on Digital Forensics and Security (ISDFS)</i> (pp. 1-7). IEEE.	CNN	97,71 – 98,61	ResNet50 ve DenseNet201 ve SVM
Liu, M., Hu, L., Tang, Y., Wang, C., He, Y., Zeng, C., ... & Huo, W. (2022). A deep learning method for breast cancer classification in the pathology images. <i>IEEE Journal of Biomedical and Health Informatics</i> , <i>26</i> (10), 5025-5032.	CNN	98,48	AlexNet + fine tuning + transfer learning
Jadah, Z., Alfitouri, A., Chantar, H., Amarif, M., &	CNN	96	AlexNet

<p>Aeshah, A. A. (2022, July). Breast Cancer Image Classification Using Deep Convolutional Neural Networks. In 2022 <i>International Conference on Engineering & MIS (ICEMIS)</i> (pp. 1-6). IEEE.</p>			
<p>Labrada, A., & Barkana, B. D. (2022, July). Breast cancer diagnosis from histopathology images using supervised algorithms. In 2022 <i>IEEE 35th International Symposium on Computer-Based Medical Systems (CBMS)</i> (pp. 102-107). IEEE.</p>	<p>Narrow Neural Networks (NNN)</p>	<p>96,9</p>	<p>Four machine learning algorithms, including Decision Tree, Support Vector Machines, K-Nearest Neighbor, and Narrow Neural Networks (NNN), are designed to assess the efficiency of the sets</p>
<p>He, F., Zhu, Y., Wang, W., Nanding, A., Kuai, Z., Li, X., & Liu, Z. (2022, October). Multi-Instance Classification of Histopathological Breast Cancer Images with Visual Explanation. In 2022 <i>16th IEEE International Conference on Signal Processing</i></p>	<p>MICNet</p>	<p>94,01</p>	

(<i>ICSP</i>) (Vol. 1, pp. 431-436). IEEE.			
Seo, H., Brand, L., Barco, L. S., & Wang, H. (2022, November). Scalable multi-instance multi- shape support vector machine for whole slide breast histopathology. In <i>2022 IEEE International Conference on Knowledge Graph (ICKG)</i> (pp. 225-232). IEEE.	<i>Multi-Instance Multi-Shape Support Vector Machine (MIMSSVM)</i>	95	
Joseph, N., & Gupta, R. (2022, December). Dual Multi-Scale CNN for Multi-layer Breast Cancer Classification at Multi- Resolution. In <i>2022 4th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)</i> (pp. 613-618). IEEE.	Dual Multi-Scale CNN	96,8	
Rao, S. V., & Raghavendra, K. (2022, December). Breast Cancer Detection on Histopathological Data. In <i>2022 Fourth International Conference on Emerging Research in Electronics, Computer Science and Technology (ICERECT)</i> (pp. 01-05). IEEE.	Resnet50 with sharping	95	
Janney, B., Divakaran, S., Krishnakumar, S., &	AlexNet	100	

<p>Hemalatha, R. J. (2023, January). Automated Detection of Breast Cancer using Artificial Intelligence Systems. In 2023 <i>International Conference on Artificial Intelligence and Knowledge Discovery in Concurrent Engineering (ICECONF)</i> (pp. 1-7). IEEE.</p>			
<p>Alotaibi, A., Alafif, T., Alkhilawi, F., Alatawi, Y., Althobaiti, H., Alrefaei, A., ... & Nguyen, T. (2023, January). Vit-deit: An ensemble model for breast cancer histopathological images classification. In 2023 <i>1st International Conference on Advanced Innovations in Smart Cities (ICAISC)</i> (pp. 1-6). IEEE.</p>	<p>Data-Efficient Image Transformer (DeiT)</p>	<p>98,17</p>	
<p>Ijaz, A., Raza, B., Kiran, I., Waheed, A., Raza, A., Shah, H., & Aftan, S. (2023). Modality specific CBAM-VGGNet model for the classification of breast histopathology images via transfer learning. <i>IEEE Access</i>, 11, 15750-15762.</p>	<p>Modality Specific CBAM-VGGNet</p>	<p>98,96</p>	<p>Convolutional block attention module (CBAM)</p>
<p>Uppada, R., Pedada, S., & Chinni, H. (2023, February).</p>	<p>CNN</p>	<p>99,75</p>	<p>DenseNet201</p>

Novel Neural Network for Breast Cancer Diagnosis. In <i>2023 Fifth International Conference on Electrical, Computer and Communication Technologies (ICECCT)</i> (pp. 1-5). IEEE.			
Singh, U. P., & Sahu, M. (2023, May). A Hybrid Approach for Improving the Classification performance of Imbalanced Breast Cancer data. In <i>2023 International Conference on Communication, Circuits, and Systems (IC3S)</i> (pp. 1-6). IEEE.	KNN	96,3	
Kolhatkar, D., Reddy, G., Raut, T., Jain, O., & Bagade, J. (2023, August). Breast Cancer Classification Using Machine and Deep Learning. In <i>2023 3rd Asian Conference on Innovation in Technology (ASIANCON)</i> (pp. 1-6). IEEE.	ANN	98,7	
Kanber, B. M., Smadi, A. A., Noaman, N. F., Liu, B., Gou, S., & Alsmadi, M. K. (2024). LightGBM: A Leading Force in Breast Cancer Diagnosis Through Machine Learning and Image Processing. <i>IEEE Access</i> .	LightGBM	99,87	
Koshy, S. S., & Anbarasi, L. J. (2024). LMHistNet:	LMHistNet	99	

Levenberg–Marquardt Based Deep Neural Network for Classification of Breast Cancer Histopathological Images. <i>IEEE Access</i> .			
--	--	--	--



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Abdulkerim ÇELİK

EĞİTİM

Derece		Bitirme Yılı
Lise	: Siirt Lisesi	2004
Lisans	: Siirt Üniversitesi	2021

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2006	Güven Hastanesi	Bilgi İşlem Uzmanı
2013-2024	Dicle Elektrik Dağıtım	Yönetici (Siirt)
2024-	Dicle Elektrik Dağıtım	Müdür Yardımcısı (Şanlıurfa)