

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TIBBİ GÖRÜNTÜ ANALİZİ VE İŞLEMEDE DERİN ÖĞRENME MODELLERİ

DOKTORA TEZİ

Yasin KIRELLİ

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Doç. Dr. Seher ARSLANKAYA

Haziran 2022

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TIBBİ GÖRÜNTÜ ANALİZİ VE İŞLEMEDE DERİN ÖĞRENME MODELLERİ

DOKTORA TEZİ

Yasin KIRELLİ

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 21/06/2022 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Yasin KIRELLİ

21.06.2022

TEŞEKKÜR

Doktora çalışmam boyunca yakın ilgisini eksik etmeyen, çalışma azmimi perçinleyen saygı değer danışman hocam Doç. Dr. Seher ARSLANKAYA'ya, proje çalışmamda yardım ve katkılarıyla beni yönlendiren Prof. Dr. Havva Belma KOÇER'e ve doktora sürecinde benden desteğini esirgemeyen aileme sonsuz teşekkürlerimi bir borç bilirim.



İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	viii
ÖZET.....	x
SUMMARY	xi

BÖLÜM 1.

GİRİŞ	1
1.1. Tezin Amacı ve Önemi.....	2
1.2. Kanser Tanımı, Tedavi ve Teşhis Yöntemleri	4
1.2.1. Kanser tanımı	4
1.2.2. Meme kanseri ve epidemiyolojisi	6
1.2.2.1. Meme anatomisi.....	7
1.2.2.2. Risk faktörleri	9
1.2.2.3. Tanı yöntemleri ve tarama	12
1.2.3. Tümörde evreleme	14
1.2.4. Radyolojik görüntüleme yöntemleri	17
1.2.4.1. Mamografi	17
1.2.4.2. Ultrasonografi (USG)	19
1.2.4.3. Magnetik rezonans görüntüleme (MRG).....	20
1.2.5. Tedavi yöntemi olarak Neoadjuvan kemoterapi (NAC)	22

BÖLÜM 2.

KAYNAK ARAŞTIRMASI.....	25
-------------------------	----

BÖLÜM 3.

MATERYAL VE YÖNTEM.....	34
3.1. Derin Öğrenme Kavramı.....	34
3.1.1. Yapay zekâ kavramı ve alt alanları	34
3.2. Makine Öğrenmesi.....	37
3.3. Makine Öğrenmesi Türleri.....	40
3.3.1. Denetimli öğrenme.....	41
3.3.2. Denetimsiz öğrenme	41
3.3.3. Yarı denetimli öğrenme	42
3.3.4. Pekiştirmeli öğrenme	42
3.4. Yapay sinir ağları ve derin öğrenme	43
3.5. Yapay Sinir Ağı Yapısı	44
3.5.1. Sapma (bias).....	45
3.5.2. Aktivasyon (etkinleştirme) fonksiyonu.....	46
3.5.2.1. Sigmoid / Lojistik aktivasyon fonksiyonu	47
3.5.2.2. Rectified linear (Relu) aktivasyon fonksiyonu	48
3.5.2.3. Tanh aktivasyon fonksiyonu	49
3.5.2.4. Softmax aktivasyon fonksiyonu	50
3.5.2.5. Exponential linear unit (ELU) aktivasyon fonksiyonu ..	52
3.5.3. Aktivasyon fonksiyonu seçim kriterleri	53
3.6. Yapay Sinir Ağı Öğrenmesi.....	54
3.6.1. İleri yayılım.....	55
3.6.1.1. İleri yayılımda maliyet (lost) ölçümü	57
3.6.2. Geri yayılım (Back propagation)	58
3.7. Gradyan ve Gradyan İnişi	58
3.8. Bilgisayarlı Görü.....	63
3.8.1. Evrişimli sinir ağları	65
3.8.1.1. Evrişim katmanı.....	66
3.8.1.2. Konvolüsyonel sinir ağlarında filtreler	67
3.8.1.3. Biriktirme (pooling) katmanı	71
3.8.1.4. Tam bağlık katman	72

3.8.1.5. Sinir ağında seyreltme (dropout) katmanı	73
3.8.2. Evrişimli sinir ağı model mimarileri.....	74
3.8.2.1. Lenet model mimarisi	77
3.8.2.2. AlexNet model mimarisi.....	78
3.8.2.3. ZFNet model mimarisi.....	79
3.8.2.4. Inception (GoogLeNet) model mimarisi	80
3.8.2.5. VGG model mimarisi	82
3.8.2.6. ResNet (Residual Network) model mimarisi.....	84
3.8.3. Bilgisayarlı görüde nesne algılama	84
3.8.3.1. Görüntüde nesne tespiti yaklaşımı.....	86
3.8.3.2. YOLO algoritması ile nesne tespiti	88
 BÖLÜM 4.	
ARAŞTIRMA BULGULARI	91
4.1. Tedaviye Cevabın Tahminlemesinde Patolojik Verilere Göre Analizi...	91
4.1.1. Derin öğrenme çerçeveleri ve seçimi.....	93
4.1.2. Verinin analizi ve önerilen model	95
4.2. Tedaviye Cevabın Tahminlemesinde Radyolojik Verilere Göre Analizi	103
4.2.1. Verilerin toplanması ve analizi.....	106
4.2.2. Önerilen model mimarisi ve sonuçların değerlendirilmesi.....	109
4.3. YOLO ile Nesne Tespiti ve Önerilen Model Mimarisi	113
4.3.1. Veri analizi ve önerilen model	114
4.4. Sonuç ve Öneriler	120
 KAYNAKLAR.....	126
ÖZGEÇMİŞ	136

SİMGELER VE KISALTMALAR LİSTESİ

ACR	: Amerikan radyoloji koleji / American college of radiology
AI	: Yapay zeka / Artificial intelligence
AUC	: Eğri altı kalan alan
BI-RADS	: Meme görüntüleme raporlama ve veri sistemi /Breast imaging reporting and data system
CAD	: Bilgisayar destekli tasarım / Computer aided design
CNN	: Evrişimli sinir ağları / Convolutional neural networks
DL	: Derin öğrenme / Deep learning
ELU	: Üstel doğrusal birim / Exponential linear unit
GPU	: Genel amaçlı grafik işleme birimleri /General purpose graphics processing units
IOU	: Birlik üzerinde kesişme / Intersection over union
LİEMK	: Lokal ileri evre meme kanseri
MRG	: Manyetik rezonans görüntüleme
MRI	: Manyetik rezonans görüntüleme / Magnetic resonance imaging
NAKT	: Neoadjuvan kemoterapi
PCA	: Temel bileşenler analizi / Principal component analysis
PET	: Pozitron emisyon tomografisi
PTY	: Patolojik tam yanıt
R-CNN	: Bölgesel sinir ağları / Regional convolutional neural network
RGB	: Kırmızı yeşil mavi / Red green blue
SSD	: Tek atış dedektörü / Single shot detector
WHO	: Dünya sağlık örgütü / World health organization
YOLO	: Bir kez bakma / You look only once

ŞEKİLLER LİSTESİ

Şekil 3.1. Yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi	36
Şekil 3.2. Klasik programlam ve makine öğrenmesi	38
Şekil 3.3. Geleneksel programlama ile problem değerlendirme şeması	39
Şekil 3.4. Makine öğrenme yöntemiyle problem değerlendirme şeması	39
Şekil 3.5. Makine öğrenmesi alt grubları ve çıktı türleri	40
Şekil 3.6. Denetimsiz öğrenmede PCA algoritması ile boyut azaltımı	42
Şekil 3.7. Derin öğrenme modelinde kayıp değeri ve ağırlık güncellemesi	44
Şekil 3.8. Yapay sinir ağı yapısı ve bileşenleri.....	45
Şekil 3.9. Sapma (Bias) bileşeni	46
Şekil 3.10. Aktivasyon (Etkinleştirme) fonksiyonu	47
Şekil 3.11. Sigmoid ve Relu aktivasyon fonksiyonları	49
Şekil 3.12. Softmax aktivasyon fonksiyon implementasyon örneği	52
Şekil 3.13. Elu aktivasyon fonksiyon ve türev grafiği	53
Şekil 3.14. Aktivasyon seçiminde problem tipi kriterleri	54
Şekil 3.15. Giriş katmanı ile g1 gizli katman düğüm arasındaki ilişki	56
Şekil 3.16. Gizli katmandan gelen bilgiye göre y1 çıkış değeri.....	57
Şekil 3.17. Geri yayılım ile ağırlığın güncellenmesi	59
Şekil 3.18. Gradyan inişi ve öğrenme oranı	61
Şekil 3.19. Bir görüntüdeki piksellerin sinir ağına dönüştürülmesi.....	64
Şekil 3.20. Evrişim Katmanı (CNN Katmanları)	65
Şekil 3.21. Görüntü matrisi üzerinde filtreleme işlemi	68
Şekil 3.22. Filtrelemede padding işlemi.....	69
Şekil 3.23. Biriktirme katman yöntemleri.....	72
Şekil 3.24. Tam bağlı katman ile ağı düzleştirilmesi	73
Şekil 3.25. Yapay sinir ağında dropout modeli	74
Şekil 3.26. CNN mimarilerinde ölçeklendirme.....	75

Şekil 3.27. Yıllara göre ImageNet’te raporlanan model hata oranları	76
Şekil 3.28. GoogLenet model mimarisi	81
Şekil 3.29. Temel sınıflandırma modellerinden nesne tespitine geçiş modelleri	85
Şekil 3.30. Bilgisayarlı görüde görüntü sınıflandırma alt türevleri	87
Şekil 3.31. Yolo ile nesne tespitinde ızgara modeli	89
Şekil 3.32. Kesişim alan skoru	90
Şekil 3.33. Sınırlayıcı kutu konum ve şeklin temsil örneği	90
Şekil 4.1. MillerKat değişkeninin veri setindeki değer ve dağılımı.....	96
Şekil 4.2. Tamkomplet değişkeninin veri setindeki değer ve dağılımı	96
Şekil 4.3. Lnreg değişkeninin veri setindeki değer ve dağılımı	96
Şekil 4.4. Değişkenler arası korelasyon haritası	97
Şekil 4.5. Önerilen katmanlı model yapısı	99
Şekil 4.6. Senaryo 1 epoch doğruluk grafiği.....	100
Şekil 4.7. Senaryo 1 kayıp değer (Loss) grafiği.....	101
Şekil 4.8. Senaryo 2 epoch doğruluk grafiği.....	101
Şekil 4.9. Senaryo 2 kayıp değer (Loss) grafiği.....	102
Şekil 4.10. Senaryo 3 epoch doğruluk grafiği.....	102
Şekil 4.11. Senaryo 3 kayıp değer (Loss) grafiği.....	103
Şekil 4.12. Görüntü ön işleme adımları	106
Şekil 4.13. NAC tedavisi uygulanan hasta MR görüntü seti örneği	108
Şekil 4.14. Sunulan model mimari ve akışı.....	109
Şekil 4.15. CNN temel model yapısı.....	110
Şekil 4.16. Önerilen evrişimli sinir ağı modeli boyut matris yapısı	111
Şekil 4.17. YOLO model mimarisi	114
Şekil 4.18. Yolo v4 evrişimli sinir ağı modeli.....	117
Şekil 4.19. Epoch, hata oranı grafiği.....	118
Şekil 4.20. Test görüntü setinde nesne tespiti	118
Şekil 4.21. Radyologlar için oluşturulan arayüz uygulama akışı.....	119
Şekil 4.22. Model ağırlık dosyası ile oluşturulan son kullanıcı arayüzü	119
Şekil 4.23. Sunulan model akış şeması	120

TABLolar LİSTESİ

Tablo 1.1. Kanser hastalık insidansı (“Global Cancer Observatory”, 2020).	5
Tablo 1.2. Kadın kanser hastalık insidansı (“Global Cancer Observatory”, 2020)..	6
Tablo 1.3. Erkek kanser hastalık insidansı (“Global Cancer Observatory”, 2020)..	6
Tablo 1.4. Meme kanseri tanı değeriendirme	13
Tablo 1.5. Primer tümör everlemele sınıflandırma değerieleri	15
Tablo 1.6. Klinik lenf dodu tutulumu evrelemeleri sınıflandırma değerieleri	16
Tablo 1.7. Patolojik bölgesel lenf nodu tutulumu sınıflandırma değerieleri.....	16
Tablo 1.8. Uzak metastaz sınıflandırma değerieleri.....	16
Tablo 1.9. Kanser mamografi sınıflandırma değerieleri (Tescic ve ark., 2013)	19
Tablo 1.10. Kanser USG sınıflandırma değerieleri (McLelland ve ark., 1991).....	20
Tablo 1.11. MRG tekniğı kullanım alanları	21
Tablo 1.12. Kanser MRG sınıflandırma değerieleri.....	22
Tablo 1.13. WHO ve RECIST değeriendirme kriterleri.....	24
Tablo 3.1. Sigmoid / Lojistik aktivasyon fonksiyonu	48
Tablo 3.2. Tanh grafik ve python örnek kullanımı	50
Tablo 3.3. Softmax fonksiyonu implemente edilmesi.....	51
Tablo 3.4. Kayıp fonksiyonu maliyet ölçüm türleri	58
Tablo 3.5. Same Padding ve Standart Model’de vektör boyutu.....	70
Tablo 3.6. Rastgele filtreleme sonucu gri tonlamada katman çıktısı.....	70
Tablo 3.7. LeNet CNN model mimarisi	77
Tablo 3.8. AlexNet model mimarisi	78
Tablo 3.9. ZFNet model mimarisi	80
Tablo 3.10. GoogleNet katman mimarisi	82
Tablo 3.11. VGG evrişimsel sinir ağı modeli.....	83
Tablo 4.1. Veri seti değerişkenleri ve açıklamalar.....	92
Tablo 4.2. Derin öğrenme için çatıların karşılaştırılması (Pathak ve ark., 2018)	94

Tablo 4.3. Senaryo özet metrikleri	103
Tablo 4.4. Sunulan evrişimsel yapay sinir ağı modeli	112
Tablo 4.5. VGG bazlı evrişimsel sinir ağı modeli.....	112
Tablo 4.6. Model doğruluk ve kayıp değeri oranları.....	113
Tablo 4.7. Hassaslık ve geri çağırma değeri	113
Tablo 4.8. MRI eğitim görsellerinin etiketlenmesi	116



ÖZET

Anahtar kelimeler: Derin öğrenme, sağlıkta yapay zekâ, CNN, VGG, YOLO

Sağlık hizmeti sağlayan kurumlar günlük olarak farklı yapılarda ve kaynaklarda heterojen bir büyük veri üretmektedir bu duruma bağlı olarak geleneksel yöntemler ile bu yapıdaki verileri anlamlandırabilmek ve yönetilebilme öngörüsü azalabilmektedir. Makine öğrenmesi ve derin öğrenme yöntemleriyle bu tür verilerin yönetilebilmesi ve yorumlanabilmesi ve analiz edilebilmesinde güçlü bir araç olarak ortaya çıkmaktadır. Hastalığın doğru teşhisi ve görüntü verilerinde analizin doğru yapılabilmesi ve öngöründe uygun görsel verinin elde edilmesi ve yorumlanmasına bağlıdır. Radyolojik görüntü alma cihazları son yıllarda önemli ölçüde iyileşmiştir. Çalışmada ele alınan meme kanseri vakalarında tedavi amaçlı kullanılan bir tedavi yöntemi olan NAC kemoterapi ile hastalardaki tedaviye yanıtın, patolojik ve radyolojik alanlarda hastalığın gelişim sürecinin tahminlenmesi hedeflenmiştir. Gelişen X-Ray teknolojisiyle ve MRI taramaları ile yüksek çözünürlüklü radyolojik görüntüler elde edilebilmektedir fakat görüntü yorumlamanın otomatize edilmesi ve faydaları henüz yeni elde edilmeye başlanmıştır. Sağlık sektöründe sıklıkla kullanılan MRI görüntüleri aracılığıyla NAC tedavi sonrası tümör durumu için CNN ve VGG tabanlı önerilen modellerin sınıflandırma performansları detaylı olarak değerlendirilmiştir. Evrişimli katman sayısı, veri seti kalitesi, eğitim sırasında modelin başarısını etkileyebilecek ana kriterler değerlendirilmiştir. Güçlü özellik temsili gücü sunabildiğinden derin sinir ağlarından CNN modelleri temel alınarak oluşturulan nesne algılama metotlarında çalışmada önerilen YOLO modeli ile algılama hızı daha yüksek bir sonuç elde edilmiştir. Radyolojik görüntü analizi için sunulan arayüz ile, hastanın prognoz takibi ile doğru teşhis ve tedavi yönteminin belirlenmesinde patolojik test sonuçları, radyolojik görüntülerin derin öğrenme yöntemleriyle yorumlanması klinisyenlere büyük ölçüde çözüm sağlamaktadır.

DEEP LEARNING MODELS ON MEDICAL IMAGE ANALYSIS AND PROCESSING

SUMMARY

Keywords: Deep learning, artificial intelligence in health, CNN, VGG, YOLO

Health care institutions produce extensive heterogeneous data in different structures and sources daily; depending on this situation, with traditional methods, the foresight of interpreting and managing data in this structure can be reduced. It emerges as a powerful tool for managing, interpreting, and analyzing such data with machine learning and deep learning methods. The correct diagnosis of the disease depends on the correct analysis of the image data and the acquisition and interpretation of the appropriate visual data in the prediction. Radiological imaging devices have improved significantly in recent years. NAC chemotherapy, a treatment method for breast cancer cases discussed in the study, aims to predict patients' response to treatment and the disease's development process in pathological and radiological areas. With the developing X-Ray technology and MRI scans, high-resolution radiological images can be obtained. However, the automation and benefits of image interpretation have only just begun to be obtained. Classification performances of CNN and VGG-based proposed models for tumor status after NAC treatment has been evaluated in detail through MRI images, which are frequently used in the healthcare industry. The number of convolutional layers, data set quality, and the main criteria affecting the model's success during training have been evaluated. Since it can provide strong feature representation power, a higher detection rate has obtained with the YOLO model proposed in the study in object detection methods based on CNN models from deep neural networks. A user interface provided for radiological image analysis, pathological test results and interpretation of radiological images with deep learning methods provide clinicians with a solution in determining the correct diagnosis and treatment method with the prognosis follow-up of the patient.

BÖLÜM 1. GİRİŞ

Günümüzde yani bilgi çağı olarak adlandırılan dönemde dijitalleşmenin de artmasıyla üretilen büyük verinin anlamlandırılabilmesi için şirketlerin ve devletlerin en önemli stratejilerinden biri yapay zekâ olmuştur. Bilgisayar destekli algılamada (CAD) ve buna bağlı olarak da bilgisayar destekli tanı sistemlerinde tıbbi görüntülerin yoğunlukla kullanıldığı radyoloji alanında dijital görüntünün analizinde makine öğreniminin kullanımı giderek artmakta ve yaygınlaşmaktadır (Thrall ve ark., 2018).

Tıbbi radyomik görüntülerin analizinde organlar veya lezyon gibi nesneler basit bir şekilde modellemek veya temsil etmek her durumda mümkün olamamaktadır, örneğin bir akciğer nodülü ele alındığında matematiksel olarak katı bir küre şeklinde ele alınabilir ancak farklı tiplerde ve boyutlarda ve homojen olarak dağılmayan buzlu görüntülere sahip bir lezyon tipi olması da mümkündür (Suzuki, 2017). Radyolojik görüntüde yer alan karmaşık nesnelerin temsil edilmesi ve modellenmesi için de çok sayıda parametreye ihtiyaç duyulmaktadır. Bu yüksek karmaşıklığa sahip işlemlerin manuel olarak belirlenebilmesi ve modellenmesi mümkün değildir ve ancak verilerden çıkartılabilmektedir. Bu nedenle radyolojik görüntülerin analizi gibi problemlerde fazla sayıda parametrenin modellenmesi için örnek veriler temel alınarak belirlenir ve derin öğrenme yöntemleri bu alanda önemli bir noktada yer almaktadır.

Tıbbi görüntü analizinde yapay zeka araştırmalarının geneli incelendiğinde temel hedef ve ortak nokta olarak sağlık sisteminde tanı yönteminin iyileştirilmesi olmuştur ve buna bağlı olarak da çeşitli klinik vakaların tanı aşaması için entegrasyon sağlanarak başarılı sonuçlar alınmıştır. Günümüzde kullanılan teknolojik aygıtların donanımsal kapasitelerinin de geliştiği varsayılırsa veri işleme ve veriden öğrenme olanakları giderek artmakta buna bağlı olarak da yapay zekanın kullanımı sadece tanı

aşamasından öte vakalara öncelik verme, hasta listelerinde optimizasyon ve önceliklendirilme, insan faktörü olarak klinisyen yorgunluğu da göz önüne alınırsa çıplak gözle tespit edilemeyen faktörlerin belirlenmesinde ve teşhis sürecinde anlık çözümler insan yaşamını tehdit eden vakalar için daha da önem kazanmaktadır. Radyolojide yapay zekanın entegrasyonu ile belirtilen amaçlara bağlı olarak verimli iş süreçleri kurulabilmekte ve hastalar bakımında da düşük maliyette daha etkili sonuçlar alınabilmektedir.

1.1. Tezin Amacı ve Önemi

Klinisyenler tarafından hastalığın doğru teşhis edilmesi radyolojik görüntüleri elde edilmesi ve bununla ilgili olarak doğru yorumlanması bağlıdır. X-Ray teknolojileri günümüzde vakaların yorumlanmasına yüksek çözünürlükte radyolojik görüntüler sunabilmektedir ancak henüz dijital olarak depolanan görüntü verileri henüz otomatikleştirilmiş bir sistemle entegrasyon faydalarına sahip değildir. Makine öğrenimi uygulamaları ile görüntüleri analizi mümkündür ancak uzman klinisyenler yardımıyla belirlenmeye çalışılan özelliklere bağlıdır. Hastadan hastaya değişen bu yapısal özellikler ve örneklem verilerinde yer alan büyük çeşitlilik güvenilir bir sonuç vermemektedir. Makine öğrenme yöntemlerinde yaşanan gelişmelere bağlı olarak derin öğrenme tıbbi verilerin analizinde öncemli bir rol oynamıştır, bu özelleşmiş yaklaşım ile klasik yapay sinir ağına göre daha gelişmiş derin sinir ağı yapısı kullanılır.

Derin öğrenme, makine öğreniminin bir alt dalı olan çok katmanlı yapısıyla klasik yapay sinir ağına göre özelleşmiştir. Derin öğrenme algoritmalarına dayalı olarak sunulan otomatik radyolojik görüntü analiz araçları ile verimli tanıyı kolaylaştırarak görüntü tanılamamanın kalitesini ve yorumlanmasını iyileştirmenin temel sağlayıcısı olması temel hedeftir ve buna bağlı olarak en gelişmiş doğruluğu sağlamak için kapsamlı bir şekilde uygulanan bir yaklaşımdır. 1980'lerden bu günümüze kadar radyolojik verilerin analizinde temelde sınıflandırma problemlerinin çözümünü gerçekleştirmek için farklı modellerde uygulanan fazla sayıda makine öğrenmesi yaklaşımları sunulmuştur. 2000'li yıllardan itibaren bilgisayar destekli tespit (CAD) sistemleri klinik süreçlere dahil edilmiştir ancak birçok durumda uzun değerlendirme

süreleri ve ek biyopsi maliyetleriyle sonuçlanmıştır. Derin öğrenme teknolojileri ile belirtilen CAD sistemlerinin kısıtlarını önlemek, yüksek doğruluk ve hızlı sonuçlar ile tekrarlayan radyolojik analiz süreçleri daha verimli olması beklenmektedir.

Geleneksel yöntemlerde araştırmacılar inceleme için ele alınan hedef alan hakkındaki bilgi ve tecrübelerle dayalı olarak manuel yöntemlerle özellikleri çıkararak tıbbi görüntüleri sayısal olarak tanımlamayı önermektedirler, ancak bu bilgi odaklı yaklaşım her durumda geçerli olmamaktadır. Birincil sebep olarak profesyonel olmayan kişiler olması gereken bir öznitelik çıkarma yöntemi tasarlamak için gerekli tıbbi donanım ve bilgilere sahip olmayabilir, ikinci durum olarak çıkarılan manuel özellikler çoğunlukla yalnızca sınırlı durumlarda çalışırlar ve karmaşık senaryolara karşısında doğru sonuç verme eğilimi düşüktür. Bu durumları önlemek adına muhtemel geçici çözüm olarak hedef alanla ilgili gizli öznitelikleri doğrudan kullanılan tıbbi verilerden öğrenmektir. Bu tür bir veriye dayalı yaklaşım ile manuel özellik çıkarım mühendisliği olmadan verilerden spesifik alan bilgisini doğal olarak öğrenebilmesi mümkün olmaktadır. Bununla birlikte otomatik veri çıkarım ile optimizasyon zorluğu ortaya çıkmakta ve büyük verinin yorumlanmasında donanım kısıtları problemleri sebebiyle ilkel veri odaklı yaklaşımlar yalnızca istenen alan bilgisini saptamak için yeterli model kapasitesine sahip olmayan sığ mimarileri kullanmaktadır (Gonbadi ve ark., 2019; Vinoth & Venkatesh, 2018).

Ele alınan çalışmada sağlık profesyonelleri ve klinisyenler tarafından çoğunlukla kullanılan radyolojik yöntem olarak tercih edilen uzman radyologlar eşliğinde MRI (Magnetic Resonance Imaging) görüntü kesitleri kullanılarak bir sınıflandırma modeli oluşturulmuştur. Bu model sayesinde meme kanseri hastalarındaki neoadjuvant kemoterapi sonrası tümör boyutunun izlenmesi ve buna bağlı karar vermede bilgisayarlı görme yöntemleri ile tespit edilebilmesi hedeflenmiştir, patolojik ve radyolojik veriler hasta veri kaynağı olarak kullanılmış ve yorumlanmıştır. Görüntülerin manuel değerlendirilmesinde uzman kişilerin bilgi seviyelerine bağlı olarak öznel çıktılar üretilebilmektedir, sunulan model ile nesnel değerlendirme yapılabilmesi temel çıktılar arasındadır. Klinisyenlere sunulan uygulama arayüzü ile radyolojik sisteme entegre, nesnel bir değerlendirme aracı olarak zaman ve süreç

avantajı sağlamaktadır. Geliştirilen farklı evrişim modeller ile uygulanan problem türüne göre yapısal avantajları sunulmuştur ve gelecek çalışmalara destek olması hedeflenmiştir. Uzman klinisyenler ile oluşturulan radyolojik ve patolojik özgün veri seti ile literatüre katkı sağlamaktadır.

1.2. Kanser Tanımı, Tedavi ve Teşhis Yöntemleri

Bu bölümde çalışmada ele alınan kanser türünün tanımı, tedavi ve teşhis aşamalarında kullanılan radyolojik yöntemler ve vakaya uygulanan tedavi yöntemleri detaylı olarak sunulmuştur. Multidisipliner bir çalışma olması nedeniyle ele alınan problemin tıbbi alanda karşılığı netleştirilmesi hedeflenmiştir.

1.2.1. Kanser tanımı

Kanser hücreleri çoğunlukla kontrolsüz bir şekilde bölünme ile ifade edilir. Normal olmayan bir şekilde büyümeye devam etme eğilimindedir. Dokuya kontrolsüz büyüme ile kaplamaları insan yaşamını tehdit eder ve farklı türde dokulara etki etmesiyle sonucu ölüme neden olabilmektedir (Harbeck ve ark., 2019).


Kanser, günümüzde artış beklentisi içerisinde olunan ömür süresine karşın bir engel olarak durmakta ve dünyanın her ülkesinde en ciddi ölüm nedeni olarak karşımıza çıkmaktadır. Dünya Sağlık Örgütü (WHO) ‘nın yayınladığı rapora göre yetmiş yaş öncesinde birinci sırada veya ikinci sırada yer alan büyük orana sahip ölüm nedeni arasında yer almaktadır (“WHO | World Health Organization”, 2022). Önde gelen bir ölüm nedeni olan kanseri izleyen diğer önemli faktör olarak felç ve kalp hastalıkları yer almaktadır. Kansere yakalanma riski ve mortalite (ölüm riski) dünya genelinde hızla artış göstermektedir. Risk faktörleri arasında nüfusun yaşlanması ve farklı sosyoekonomik koşullar oluşturmaktadır.

Küresel Kansere Gözlemevi (Globocan) ‘nin 2020’de yayınladığı rapora göre Tablo 1.1.’da dünyada genelinde karşılaşılan ilk on kanser türü için vakalar ve ölümler olarak gösterilmiştir. Tabloda gösterilen on kanser türü her iki cinsiyet için teşhis edilen kanser vakalarının %60’ını ve kansere bağlı ölümlerin %70’ini oluşturmaktadır. Tablo


1.2.’de yer alan verilere göre cinsiyet bazında kontrol edildiğinde kadınlarda en çok görülen kanser türü meme kanseridir ve toplam kanser türlerine göre vakaların %11,7’sini oluşturmaktadır. Sonraki kanser türleri sırasıyla akciğer, kolorektal, prostat ve mide oluşturmaktadır. Tablo 1.3.’te yer alan cinsiyetlere göre kanser türlerinin yer aldığı tablo incelendiğinde erkeklerde en sık görülen kanser türü olarak ilk sırada akciğer kanseri yer almaktadır ve bu oran toplam kanser türlerinde %18’i oluşturmaktadır. Bunu izleyen erkeklerde en çok görülen kanser türleri sırasıyla prostat, kolorektal, karaciğer kanser hastalıkları yer almaktadır.

Global ölçekte tüm kanser türleri insan yaşamına ciddi zararlar vermekte ve yükü giderek artmaktadır. Buna karşın günümüzde klinik ve teknolojik imkanlarla birçok kanser türü tedavisi mümkün olmaktadır. Tedavide kanser türüne bağlı olarak tedavi teknikleri geliştirilmiştir bu yöntemler tekli veya birlikte olmak üzere çeşitlendirilebilmektedirler (Yurtsever, 2000). Bu yöntemler arasında sıklıkla kullanılan radyoterapi, cerrahi yöntemler, kemoterapi, gen tedavisi, hormon terapi gibi vakaya göre özelleştirilebilmektedirler.


Tablo 1.1. Kanser hastalık insidansı (“Global Cancer Observatory”, 2020).



Tablo 1.2. Kadın kanser hastalık insidansı ("Global Cancer Observatory", 2020)



Tablo 1.3. Erkek kanser hastalık insidansı ("Global Cancer Observatory", 2020)



1.2.2. Meme kanseri ve epidemiyolojisi

Global Cancer Observatory tarafından yayınlanan verilere göre meme kanseri, akciğer kanser vakalarından sonra gelmektedir ve ölümölölük oranının %4,6'sını oluşturmaktadır. Vakaların ölümöl sonuçlanma açısından beşinci sırada yer almaktadır. Meme kanseri mortalitesi kadınlarda öncelikle kanser durumundadır ve bu durum sadece kadınlarda görölmektedir. Erkeklerde bu durum gözlemlendiğinde meme kanseri insidansı nadir görölen bir vaka olarak %1 olarak gözlemlenmektedir (Giordano ve ark., 2002). Dünyada kadınlar arasında kanser türleri arasında en çok görölen hastalıklardan biri de meme kanseri olmaktadır ve bu hastalık tedavisi için günümüzde ve geçtiğimiz yıllarda büyük ölçüde aşama kaydedilmiştir. Meme kanseri tıp literatüründe malign tümör olarak en sık görölen türlerin başında gelmektedir.

Günümüzde teknolojinin de hızla gelişmesiyle birlikte meme kanseri tedavisinde geleneksel tedavi yöntemlerinden olan genel cerrahi süreçleriyle olduğu gibi kemoterapik tedavi ve radyolojik tedavi yöntemleriyle de alan araştırması genişlemiştir.

Kansere bağlı ölümlerde meme kanseri tüm dünyada akciğer kanserinden sonra ikinci sırada gelmektedir. Kırk elli beş yaş arası kadınlarda ise kansere bağlı olarak oranlarda akciğer kanserinin de önüne geçerek ilk sırada yer alan ciddi bir hastalık olarak karşımıza çıkmaktadır. Lokal ileri evre meme kanseri (LİEMK) en krtitik düzeydeki meme kanserini simgelemektedir. Gelişmişlik seviyelerine göre ülkelerde de farkındalık ve erken tedavi ve farklı etkenlere bağlı olarak da kanser evrelerinde oransal olarak farklılıklar yer almaktadır. Kanser evrelerine göre LİEMK gelişmiş seviyelerdeki ülkelerde %5-20 olarak kaydedilirken, daha az gelişmiş ve gelişmekte olan ülkelerde ise bu oran daha fazla olmakta ve %73'lere kadar gözlemlenebilmektedir (Valero ve ark., 1996). Sağlık bakanlığı tarafından son yıllarda yayınlanan veriler bu bulguyu doğrulamaktadır ve meme kanseri ülkede kadınlarda akciğer kanserinden sonra en sık görülen kanser türü olarak teşhis edilmektedir. Sağlık Bakanlığı'na göre, ülkede her dört kadından birinde meme kanseri tanısı koyulmakta ve yıl içerisinde yaklaşık on altı bine kadar varan vaka gözlemlenmektedir (Ak, 2016; Geçer, 2014; İpci, 2014; Karataş, 2017).

Kanserde geleneksel tanı ve tedavi yöntemleri hızla gelişmesine rağmen gelişmişlik düzeyi düşük olan toplumlarda ileri evrelerde LİEMK çoğunlukla görülmektedir, bu sebeple lokal ileri seviye metastazik hastaların tedavisinin daha zor olduğu gözlemlenmektedir .

1.2.2.1. Meme anatomisi

Anatomik olarak incelendiğinde meme dört bölüme ayrılmıştır. Herhangi bir lezyon veya konumsal değerlendirme yapalabilmek amacıyla literatürde standartlaşma amacıyla bölümlenme tanımlamaları mevcuttur. Meme ucu merkez alınmak koşuluyla yatay ve dikey olarak dörde bölünmesiyle iç, dış olmak üzere alt ve üst kadran

tariflemesiyle lezyon veya bulgunun olduđu bölüm tarifi yapılabilir (Belhaouari ve Islam, 2021; Doughty ve ark., 2005; Tabár ve ark., 2000). Önden bakış sabit alınarak lezyonun yerinin tespitinde farklı bir tarfileme olarak saat yönü de baz alınabilmektedir. Konumsal olarak üst dış kadranda en çok meme dokusu gözlemlenmektedir ve buna bağılı olarak da lezyon görülme sıklığı en çok üst dış kadranda klinik araştırmalarda farkedilmektedir.

Dokulardaki yağ oranı, benign ve malign lezyon yapılarına göre her iki memede asimetri bozukluğu gözlemlenebilir. Bu nedenle simetri bozukluğu bir risk sinyali olabilmekte, erken tanı ve kontrol için incelenmesi gerektiğı durumlarla karşılaşılabilir. Meme dokusunun ana etken kontrolü hormonal olarak östrojen ve progesteron hormonlarının dengesinde belirlenmektedir. Meme dokusu çoğunlukla yağ dokusu, parankim ve stroma komponentlerinden meydana gelmekte, asinüs tabakası ise kübik yapıdaki epitel hücre dokularından oluşmaktadır (Doughty ve ark., 2005). Bu doku da annelik döneminde süt salınımını tetiklemektedir. Gebelik döneminde kadınlarda östrojen ve progesteron hormonları en üst seviyeye yükselmektedir buna bağılı olarak laktasyonu engellemektedir. Doğum sonrası östrojen ve progesteron hormonlarının ani düşüşüyle birlikte laktasyon başlamaktadır. Hamilelik sürecinde hormonların etkisiyle meme bezlerinin gelişmesiyle birlikte, doğum sonrası süt üretimi laktasyon olarak ifade edilmektedir.

Meme dokusu ve yoğunluğu erkek ve kadınlarda fizyolojik olarak gelişime göre farklılık göstermektedir. Erkeklerde ergenlik sonrası meme dokusu ve yoğunluğu sabit kalmakta ve hayat boyunca değişmemektedir, kadınlarda ise bu durum yaşam boyu farklılık göstermektedir ve buna bağılı olarak çoğunlukla ergenlik dönemi sonrasında hacimsel olarak daha çok gelişme oluşmaktadır (Sırma, 2019; Storm ve ark., 1992). Kişiden kişiye değişen duruma bağılı olmak üzere erişkin bir bireyde doku büyüklüğüne göre meme dansitesi ve yağ oranı farklılıklar gösterebilmektedir. Bu sebeple patolojik olarak meme hastalıklarının kadınlarda görülme riskini de beraberinde getirebilmektedir.

1.2.2.2. Risk faktörleri

Araştırmalara göre meme kanseri görülme riski kadınlar arasında ilk sırada yer almaktadır, kansere bağlı olarak ölümlerde ise ikinci sırada gözlemlenmektedir. Dünya üzerindeki kıtalara ve bölgelere göre de bu kanser türünün görülme riski değişiklikler olabilmektedir. Özellikle kuzey Amerika ve Avusturalya'da çok sık vakalar gözlemlenebilmişken Asya ve Afrika ülkelerinde bu oran daha düşük olarak kalmıştır. Teknoloji ve tıbbın ve sosyal imkanların gelişmesiyle birlikte son zamanlarda Kuzey Amerika'da düşüş ve tam tersi şekilde sosyal ve ekonomik gelişmişlik düzeyi düşük olan Afrika gibi ülkelerde bu oran artış göstermektedir. Günümüzde ve özellikle 1975 yılındaki erken tanı ve tedavi tetkiklerindeki gelişmelerle birlikte kansere bağlı ölümlerde düşüş gözlemlenmiştir. Özellikle mamografi gibi teknolojik görüntüleme sistemlerinin de klinik sistemlere dahil edilmesi ve neoadjuvant kemoterapi tedavi yöntemleriyle ölüm riskleri daha aza indirgenmesiyle sonuçlanmıştır (Martin ve Weber, 2000).

Meme kanserinin oluşumunda farklı ana başlıklarda risk faktörleri etken olabilmektedir. Yüzde yetmiş ve seksen oranında belirli bir risk sebebinden meydana geldiği tam olarak belirlenebilmiş olmasa da önemli risk faktörlerinin meme kanserini tetiklediği tahmin edilmektedir. Bu risk faktörleri ana başlık altında incelendiğinde genetik, hormonal ve çevresel bağımlılıklara göre sınıflandırılabilirler (Madigan ve ark. 1995; Uyan, 2013).

Riskler çoğunlukla yaşın ilerlemesine bağlı olarak çoğunluk gösterdiği bilinmektedir. Hormonal etkilerin fazla etkisi tetikleyici ana risk faktörleri arasında olmaktadır, özellikle östrojen hormonun dönemsel etkileri kanser riskinde ana etken olarak düşünülmektedir. On iki yaş öncesi menarş ve elli beş yaş sonrası menapoz sürelerinde östrojen hormonuna mağruz kalma süreleri artmakta ve buna bağlı olarak hormonal risk seviyeleri artış gözlemlenebilmektedir. Geç canlı doğum veya hiç doğum yapılmamış olması da risk artışında etken durumlar olarak düşünülmektedir (Yılmaz, 2019). Genetik mutasyonlar sebebiyle veya genetik yatkınlık riskleri genel kanser oranlarında oldukça düşük ve ortalama yüzde beşini oluşturmaktadır. Bu risk

faktörlerinin ortaya çıkarılması erken tanı ve tedavi için bir yol gösterici olma konumundadır. Bu faktörleri kendi içerisinde genel olarak aşağıdaki gibi sınıflandırmak mümkündür.

- Değiştirilemez risk faktörleri: Yaş, cinsiyet, ırk, ailede yer alan kanser öyküsü, geç menapoz, erken menarş.
- Değiştirilebilir risk faktörleri: Obezite, alkol ve sigara kullanımı, hormon tedavisi, emzirme.

Ailede meme kanseri öyküsü: İlk derece akrabalıkta meme kanser varlığı genetik yatkınlıkla ilgili olarak bu risk iki kat artış olabileceği, ilk derece akrabalıkta iki kişide gözlenen kanser vakasında ise bu risk altı kata kadar çıkabilmektedir ek olarak bu kişilerde vakanın olma yaşı elli yaş altı ise risk hayat boyunca yüzde elli olduğunu gösteren araştırmalar mevcuttur. İlk ailesel yatkınlık gözlemlenmesi Paul Broca tarafından gözlemlenmiştir ve araştırmasında vakaya yakalanan eşinin dört nesil süresince yirmi dört kadından on tanesinde vaka tespiti yapılmıştır (Ak, 2016).

Cinsiyet: Kadınlara göre oranla erkeklerde vaka görülme ihtimali yüz kırk altı kat daha az olarak saptanmıştır ve bu oran yüzde birden daha az olarak görünmektedir.

BMI indeksi: Araştırmalara göre menapoz sonrası süreçte obeziteye bağlı olarak hareketsiz yaşam ve yüksek alkol kullanımı riski arttırdığı yönündedir (Sakallı, 2011). Yağdan zengin besinler hayvanlar üzerinde deneylerde tümör oluşumuna sebep olduğu varsayılmaktadır, ancak insanlar üzerinde birebir net bir bağlantı kuralamamıştır. Alkol alımının orta yaştan sonra hormonal olarak östrojen salınımını arttırdığı ve risk faktörü olarak değerlendirilmiştir.

Hormon tedavisi: Güncel çalışmalara göre menapoz sonrası semptomlara bağlı olarak kadınlarda tedavi amaçlı hormon tedavilerinin risk faktörünü artırdığı tartışmaya açık bir konudur. Beş yıldan fazla hormon tedavisi görmüş hastalarda yaygın olarak risk faktörünün yüksek olduğu belirlenmiştir.

Beslenme alışkanlığı: Son çalışmalara göre yağ içeriği yüksek olan beslenme ve uzun süreli bu alışkanlıkta beslenme kanser riski artışında önemli etken olarak gösterilmiştir. Hafta içi her gün kırmızı et tüketiminin doğrusal bir artış sağlayabileceği de araştırmalar arasındadır. D vitamininin vakaya yakalanma riskini azalttığı ve bağlı olarak anti oksidan içerikli besinlerin bu riskin azaltımını desteklediği tartışılmıştır (İpci, 2014). Sigara kullanımının riski arttırdığı alandaki çalışmalarda farklı sonuçlar elde edildiğinden tetikleyici unsurlardan olduğu varsayılmaktadır. Kafeinle birebir ilişkinin gösterildiği çalışmalar olmasa da östrojen hormonunu arttırdığı sebebiyle riski arttırıcı sebepler arasında yer almaktadır.

Sosyo ekonomik düzey: Kendi başına bir risk faktörü olarak alınmasa da sosyal ve ekonomik anlamda iki daha riskli araştırmalarca gözlemlenmiştir.

Egzersiz: Hareketsiz yaşam standardından göre düzenli egzersizler riski daha aza indirdiği düşünülmektedir.

Radyasyona maruz kalma: Menarş öncesi meme gelişiminin olduğu iki yıl ve menopoz sonrası radyasyon kanser riskini arttırdığı ve radyolojik testlerin de bu anlamda riski arttırdığı tartışılmaktadır.

Alkol tüketimi: Güncel çalışmalara göre süreklilik ve zamana bağlı olarak tüketilen alkol oranı östradiol serum düzeyini arttırdığı bilinmektedir, buna bağlı olarak kanser riskini en az %30 oranında arttırdığı güncel çalışmalarca ortak görüşür.

Yaş ve genetik: Diğer risk faktörlerinden farklı olarak yaş bağımsız olarak en önemli bir faktör olarak belirlenmektedir, menarş sonrası her on yaşta risk iki katına çıkıp elli yaşında pik yaptığı öngörülmektedir. Aile bireylerindeki yakın derecesine göre ilk derece yakınlıkta vaka görüldüğü durumda iki katına kadar riskin arttığı gözlemlenmiştir. Breast Cancer Susceptibility Gene (BRCA), BRCA1 ve BRCA2 olarak kansere yatkınlık olarak adlandırılan genler 30 yaşından sonra %30 etki faktörü olarak ortaya çıkmaktadır. Güncel araştırmalara göre genetik anlamda siyahi ırk beyaz ırka göre oranla daha fazla riskli vakalar gözlemlenmiştir.

Hormonal faktörler: Menarş yaşı ve menopoz yaşları hormonal süreçte önemli etkenler başında gelmektedir. Her bir yıl geç yaşanan menarş yaşı yüzde on düzeyinde riski azattığı bilinmektedir (Öner, 2018). Buna bağlı olarak menopoz süresinin uzaması da riski arttırmaktadır. Gebelik yaşının erken yaşlarda olması ve emzirme sürelerinin on iki aya kadar sürmesi riski azaltan hormonal faktörler arasındadır. Östrojen ve progesteron içeren hormonal tedavi yöntemlerinin beş yıldan daha uzun sürelerde uygulandığı durumlarda kanser riski seviyesini iki kata kadar arttırdığı araştırma konusudur.

Meme dansitesi: Meme yağ dokusuna oranla meme dansitesinin yüksek olması kanser riskini arttıran etkenler arasında gösterilmektedir (Kocer, 2021). Dansitenin yüzde yetmişten büyük olan kişilerde bu risk yüzde on beşten küçük olanlara oranla daha yüzde beş oranında daha yüksek olduğu tahmin edilmektedir (Cuzick ve ark., 2004). Buna bağlı olarak mamografide lezyon görülme olasılığını da azalttığı için daha erken safhalarda tespit edilebilme olasılığını azaltmaktadır.

1.2.2.3. Tanı yöntemleri ve tarama

Kanser şüphesi tanıları için günümüzde radyolojik yöntemler önerilmekte ve sıklıkla kullanılmaktadır. Ultrasonografi, manyetik rezonans görüntüleme ve mamografi meme görüntülemede kullanılan radyolojik yöntemler arasında yer alır. Tanısal amaçlı olarak çoğunluklar mamografik görüntüleme tercih edilmektedir. Böylece asemptomatik durumlarda ortaya henüz bir şikâyet ya da bulgu oluşmadan taramalarda ortaya çıkarılabilen ve muhtemel ölüm riskini azaltmada en etkili radyolojik tanısal araçlardan biridir. Tanısal anlamda yapılan mamografik görüntüleme ile %93'lere kadar çıkan bir başarı oranı ile tespit edebilmek mümkündür, bundan dolayı kırk ve elli yaş arası kişilerde bu yöntemle mortalitede %15 azalma ve aynı şekilde elli yaşının üzerinde kişilerde mortalitede %22 azalma olduğu araştırmalarda vurgulanmıştır (Day ve ark., 1989).

Amerika'da tanısal işlemler için yaklaşık yüzde otuzluk kısmı memede ele gelen kitle ile ve yüzde ellilik kısmı da mamografik tanı yöntemleriyle tespit edilmiştir. Memede

meydana gelen ağrı, ciltte meydana gelen değişiklikler, kitle ve meme başındaki şikayetler ve bunlarla birlikte mamografi sonucu pozitif çıkan kişilerin tanısısal anlamda değerlendirme yapılması gereklidir (Lee ve ark., 2003). Gereksiz cerrahi işlemlerin önününe geçebilmek için tanısısal değerlendirme önem arz etmekte ve buna bağlı olarak klinik değerlendirme, radyolojik görüntüleme ve biyopsi sonucuda göre teşhis ortaya koyulmaktadır.

Radyolojik görüntüleme yöntemlerinden MRG (Magnetik Rezonans Görüntüleme) tekniği mamografiye göre daha iyi sonuçlar üretebilmektedir. Lezyonun tespiti konusunda daha duyarlı sonuçlar elde edilebilmektedir. Aile hikayesi olan hastaların yaşam boyu risk oranı %25 olmasından dolayı, özellikle yüksek dansitede olan meme için mamografik sonuçlarda etkin sonuçlar elde edilemezken aile hikayesi olan hastalar yıllık olarak periyodik muayenede MRG yöntemiyle tespit edilebilmektedir. Tanı sonucu tespit edilen lezyon kategorik olarak raporlama sistemine aşağıdaki standartlara bağlı kalarak raporlaması yapılmaktadır (Yılmaz, 2019). Raporlanmadırma değerlendirme sistemi Tablo 1.4.'ye göre uygulaması oluşturulabilir.

Tablo 1.4. Meme kanseri tanı değerlendirme

Kategori	Değerlendirme	Yönetim	Kanser olasılığı
0	Tam olmayan değerlendirme, ek yöntemlere ihtiyaç durumu	Ek görüntüleme ve yeni muayenelerin yapılması	N/A
1	Negatif	Periyodik muayene	Malignite olasılığı %0
2	Benign bulgular saptanmış	Rutin mamografik tarama	Malignite olasılığı %0
3	Olası Benign bulgular	Kısa süreli takip (6 ay)	> 0%, ≤ 2%
4	Şüpheli bulgular	Doku tanısı	>%2, <%95

Rutin kontrolde veya şüpheyeye bağlı olarak kontrollerde tespit edilen lezyonlar için radyolojik yöntemlerle birlikte histopatolojik olarak da desteklenmesi gerekmektedir. Patolojik yöntemler için farklı biyopsi yöntemleri de mevcuttur. Bunlar arasında ince iğne biyopsi, kalın iğne biyopsi, vakumlu aracılığıyla biyopsi ve açık cerrahi biyopsi yöntemleri ile patolojik test için örneklem alınabilmektedir. Biyopsi alınımını mamografik, ultrason veya MRG ile görüntüleme yardımıyla daha etkin biyopsi

örneklemi alınabilir (Tescic ve ark., 2013). Görüntüleme dışında hastaların şikayetleri belli sınıflandırılmış şikayetleri aşağıdaki başlıklarda özetlendiği gibidir:

Memede kitle: Lezyonun olduğu kadrana göre sert, sınırları olan, hareketsiz ve bir kitledir. Bu durum her zaman malign veya benign tümör olarak sınıflandırılmaz (Abbasov, 2019).

Lokal ileri hastalık: Hastaların çoğunlukla ciltte meydana gelen değişiklikler (erime, çukurlaşma, sertleşme) temel bulgular arasında yer almaktadır (Abbasov, 2019).

Metastatik hastalık: En zararlı olan bu sınıfta lezyonun tutunduğu organa göre şikayetler değişmektedir. Eğer karaciğere veya akciğere tutunduğunda bel ağrıları, mide bulantısı, nefes darlığı gibi şikayetler temel bulgular arasındadır (Abbasov, 2019).

Ülkemizde yaygın ve rutin olarak tarama programları yapılmamakta ve çoğunlukla bilinçli hastaların isteklerine göre taramalar gerçekleştirilmektedir. Gelişmiş ülkelerde hastanın tarama ya da mamografi analizlerine göre belirlenirken ülkemizde hastanın %95'e kadar orana göre tanı, hastanın kendi şikayetinden sonraki analizlerde bu teşhis koyulabilmektedir. Hastanın lezyon belirtilerinden olan yüzeyde sert kitlenin farkına varılması, yüzeyin sertleşip şekil değiştirmesi, asimetrik görünüm, meme başında akma ve şekil bozuklukları fiziki şikayetlerin başlıcalarını oluşturmaktadır. Meme kanseri teşhisinin kesin tanısı patolojik değerlendirme sonrasında ortaya koyulmaktadır. Patolojik değerlendirme görüntülemekten tamamen bağımsız bir şekilde sonuçlandırılır.

1.2.3. Tümörde evreleme

Klinik vakalara müdahalede ve saptanmasında tümörün hangi seviyede veya hangi sınıfta yer aldığı müdahalede önemli faktördür. Evreleme belirlemede farklı açılardan değerlendirmeye alınır. Tümörün lenf nodu tutulumu olup olmadığı, çevresindeki organa tutulumu ve tümörün çapı sınıflandırma yapmada etken faktörler arasındadır. Evrelemeler dikkate alınırken patolojik ve klinik açıdan ele alınırlar. Pierre Deroix ilk

defa sınıflandırma çalışmalarında yer almıştır ve 1942’de yukarıda yer verilen risk faktörlerini fiziksel açıdan incelemeyi temel almıştır. 1958 yılında Ulusal Kanser Birliği tarafında Deroix’in sınıflandırma çalışmalarını kullanarak yeni bir sınıflandırma standardı belirlemiştir. Ulusal Kanser Birliğinin ve Amerikan Kanser Birliği ile yapılan çalışma ile 2012’de güncel standart olarak belirlenen sınıflandırmayı yayınlamışlardır. Bu sınıflandırma tedaviye karar verilen yöntemin seçiminde önemli bir etken olarak karşımıza çıkmaktadır. Yayımlanan sınıflandırmaya göre 1, 2A, 2B, 3A, 3B ve 4 olarak evreleme işlemi gerçekleştirilir (Orel ve Schnall, 2001). Bu evrelemelerde beş yıl boyunca sağ kalım oranları farklılaşmaktadır. Evre I’de en yüksek sağ kalım oranı olarak %95 iken Evre IV’te en az sağ kalım oranı olarak %18 olarak araştırmalarda yer almaktadır.

Ulusal kanser birliğinin yayınladığı rapora göre lenf nodu tutulumu olup olmadığı, çevresindeki organa tutulumu ve tümörün çapı esas alınarak sırasıyla “N”, “M” ve “T” olarak adlandırılmaktadır. Evre 1’de kanserin başlangıçtaki aşamasıdır. Bu evrede tümör lenf bezlerine henüz yayılmamıştır ve çapı maksimum 2 cm olarak memede yer almaktadır. Evre 2a’da tümör henüz koltuk altı lenf bezlerindedir. Tümör çapı 2 cm ile 5 cm arasında değişmektedir. Evre 2b’de 5 cm’den büyük ve koltuk altı lenf bezlerine tümör yayılmıştır. Evre 3a’da tümör çapı 5 cm’den büyük ve koltuk altı lenf bezlerine yayılmıştır, ek olarak çevrede yer alan dokulara da yayılmış olabilir. Evre 3b’de tümör boyutu 5 cm’den büyük olabilmektedir. Koltuk altı lenf bezlerine ve meme içi lenflere yayılmış olabilir. Çevre dokulara yayılma ihtimali daha fazla olabilmektedir. Evre 4’te meme, lenf nodu ve çevre organlara tümör yayılmış durumdadır. Bu evrede hastanın sağ kalım süresini arttırabilmek temel hedef olmaktadır (“Global Cancer Observatory”, 2018).

Tablo 1.5. Primer tümör evreleme sınıflandırma değerleri

Primer Tümör- T
TX- Primer tümör değerlendirmesi belirsiz.
T0- Primer tümör bulgusu yok.
T1- Tümörün maksimum çapı 20 mm’den küçük
T2- Tümörün maksimum çapı 50 mm
T3- Tümörün çapı 50 mm’ den büyük
T4- Boyutu değişkenlik gösterebilir. Cilde ve göğüs kafesinde yayılım göstermiştir.

Tablo 1.6. Klinik lenf nodu tutulumu evrelemeleri sınıflandırma değerleri

Klinik Bölgesel Lenf Nodu Tutulumu- N
Cn
Cnx- Bölgesel lenf nodları belirsiz.
Cn0- Bölgesel lenf nodu tutulumu yok.
Cn1- Aksiller seviye I ve II
Cn1mi- Mikrometastazlar (ortalama 200 hücre, 0.2 mm'den büyük ve 2 mm'den küçük)
Cn2- Aksiller seviye I ve II'de hareketsiz lenf nodları veya aksiller lenf nodu metastazı olmadan internal mammarian lenf nodlarında metastaz
Cn2a- İpsilateral aksiller seviye I ve II, lenf nodlarında birbirine veya diğer yapılara yapışık durumda lenf nodları
Cn2b
Cn3
Cn3a- İpsilateral lenf nodu metastazı
Cn3b- İnternal ve aksiller lenf nodu metastazı

Tablo 1.7. Patolojik bölgesel lenf nodu tutulumu sınıflandırma değerleri

Patolojik Bölgesel Lenf Nodu Tutulumu-pN
Pn
Pnx- Bölgesel lenf nodları belirsiz.
Pn0- Bölgesel lenf nodu tutulumu bulunmamakta
Pn1- Mikrometastazlar oluşumu gözlenir veya 1, 3 arası aksiller lenf nodu metastazı veya mikro, makrometastazlar
Pn1mi- Mikrometastazlar (ortalama 200 hücre bulunur, 0.2 mm'den büyük ve 2 mm'den küçük çapa sahiptirler)
Pn1a- En az bir metastazın 2 mm'den büyük olduğu durumlarda lenf nodu metastazı
Pn1b- Lenf nodunda bulunan izole kanser hücrelerinin dahil olmadığı metastaz
Pn1c- pN1a ve pN1b birleşimi
Pn2
Pn2a- Aksiller lenf nodunda bulunan metastaz (en az birinde 2 mm'den büyük bir tümör varlığının gözlemlenmesi)
Pn2b- Patolojik değerlendirmede negatif aksiller lenf nodu ile mikroskopik olarak doğrulama gözetilerek klinik lenf nodu tutulumu
Pn3- On veya üzerinde bir aksiller lenf nodunda metastaz oluşumu
Pn3a- On veya üzerinde bir aksiller lenf nodunda metastaz oluşumu (en az birinde 2 mm'den daha büyük bir tümör varlığı)
Pn3b
Pn3c- Lenf nodu metastazı

Tablo 1.8. Uzak metastaz sınıflandırma değerleri

Uzak Metastaz – M
M0- Klinik veya radyolojik olarak kontrol edildiğinde organ metastazı bulunmaması
Cm0 (i+)- Kontrollerde semptom göstermeyen hastalar için radyolojik ve klinik kontroller sonucunda 0.2 mm'den küçük metastaz varlığının olması ve aynı şekilde radyolojik ve klinik incelemelerde organlara yayılmış bir metastaz olmaması.
M1- Klinik ve radyolojik olarak kontrol edildiğinde organ metastazı ve/veya 0,2 mm'den büyük metastaz gözlemlenmesi

1.2.4. Radyolojik görüntüleme yöntemleri

Bu bölümde çalışmada da görüntü veri seti olarak da kullanılan radyolojik görüntüleme ve kullanım amaçları belirtilmiştir.

1.2.4.1. Mamografi

Mamografi düşük dozda radyasyon içeren radyolojik bir görüntüleme tekniğidir. Meme dokusunu detaylı olarak incelenmesine olanak sağlayan bir tanı yöntemi olarak da sıklıkla tercih edilmektedir. Kırk yaş ve üzerindeki her kadının her yıl düzenli olarak mamografi taraması yapması önerilmekte ve kadınlarda en sık rastlanan meme kanseri için erken tanı ile tedavi süreci erken başlama fırsatı doğabilmektedir.

Mamografi dokunun iki taraflı sıkıştırılması ile X ışınları yardımıyla filminin çekilmesi yöntemidir (Elmore, 2005). Dokunun X ışınlarını tutma veya yansıtma özelliklerine göre görüntünün oluşumu farklılaşmaktadır. Özellikle dokuda yer alan su oranı arttıkça X ışınlarını absorbe kuvveti daha fazla olmaktadır. Meme dokusu kırk yaş öncesi radyasyon yöntemlerine daha duyarlıdır. Kırk yaş sonrası bu durum gittikçe minimum seviye inmektedir ancak kanserojen etkiye ne kadar süre maruz kalındığında etki ettiği net olarak bilinmemekte ve tartışma konusudur.

Çoğunlukla tanı aracı olarak kullanılan bu teknikte kanser bulguları normalin dışında mamografik görüntülerle ortaya çıkmaktadır. Breast Cancer Detection Demonstration Project'in yaptığı araştırmaya göre mamografik yöntemlerle %90'a yakın bir başarımla mamografik yöntemlerle kanser tespiti yapılabilmektedir. Buna bağlı olarak ancak %10'luk bir bulgu fiziki kontrol teknikleriyle farkedilebilmektedir (Smart ve ark., 1997). Güncel teknolojiyle birlikte mamografik yöntemlerde duyarlılık seviyelerinin arttırılabilmesi için dijital ortamlarda görüntünün sunulabildiği ve daha hızlı yorumlanabildiği cihazlarla tanı sunulabilmektedir. Böylece radyoloji raporu için film ve banyo işleri gibi güncelliğini yitirmiş yöntemler kullanılmamaktadır.

Kanser bulgularında düzenli kontrollerde farkedilebilmektedir dolayısıyla her iki düzenli kontroller arasında bulunan kanser türü olarak interval kanser olarak

adlandırılır (Barlow, 2002). Kırk yaş altı riskli olmasına karşı bu tür bulgulara periyod zamanı beklenilmeden tekrar mamografik gözlem yapılması önerilmektedir.

Görüntünün daha net oluşturulabilmesi için dokunun kompress edilmesine yardımcı olabilecek mekanik aletler mevcuttur. Böylece dokunun hareketsiz olarak kalmasını ve aynı zamanda dokunun kalınlığının her seviyede eşit düzeyde kalmasına yardımcı olmasını sağlamaktadır. Görüntünün veri tabanına aktırılma sürecinde ise X ışınları öncelikle elektrik sinyallerine dönüştürülürler ardından bu elektrik sinyalleri analog dönüştürücüler sayesinde yerel depolama sistemlerine aktarılmaları sağlanmış olur.

İlk aşama tanı yöntemi olarak kullanılan radyolojik bu yöntem son yıllarda yaygın olarak uygulanmaktadır. Mamografik görüntülemelerde dokunun sabit veya normal bir görüntü düzeyi olmamaktadır, hormonal olarak dokunun şekli ve büyüklüğü farklılık göstermesi olağandır (Sırma, 2019). Patolojik olarak bir bulgunun tamamlayıcı yöntemi olan mamografi ile aslında standart bir yapıda olmayan bir dokunun yoğunluk haritası ortaya çıkarılmış olur. Olağan dışı görüntüler mamografi görüntülerinde daha spresifik görünümde dansite bölgelerini oluşturmaktadır. Araştırmalara göre mamografinin tanıda tek başına yeterli olmamaktadır. Mamografinin duyarlılık ölçütlerinin %64 ile %67 arasında değiştiğini ve hassaslık ölçütlerinin %85 ile %97 arasında değiştiğini varsaymıştır, dolayısıyla tamamlayıcı radyolojik yöntemler olan ultrasonografi ve MRG yöntemlerine de ihtiyaç duyulabilmektedir. Ek olarak mamografi yöntemlerinde meme dansitesi, ışın tedavisi uygulanmış hastalarda duyarlılık değerlerini düşüren faktörler arasındadır .

Radyolojik görüntülerin yorumlanmasında globalde standardizasyonu için ortak bir raporlama sistemi geliştirilmiştir. Breast Imaging Reporting and Data System (BI-RADS) bu raporlama standardını oluşturur, Tablo 1.9.'da yer verilen kategorilere göre son sınıflar dört ve beş seviyelerinden sonra biyopsi uygulamalarına yer verilir.

Tablo 1.9. Kanser mamografi sınıflandırma değerleri (Tesci ve ark., 2013)

Sınıflandırma	Tanım
0	Belirlenememiş (Ek inceleme gereklidir.)
1	Negatif (Lezyon yok, yıllık tarama yeterlidir.)
2	Benign Bulgular (Yağ içerikli lezyonlar, 6 aylık kontrol)

Tablo 1.9. (Devamı)

Sınıflandırma	Tanım
3	Olası Benign
4	Şüpheli
5	Yüksek olasılıklı Malign
6	Bilinen Malignite

1.2.4.2. Ultrasonografi (USG)

Ultrasonografi günümüzde yaygın olarak kullanılan tamamlayıcı bir radyolojik araçtır. Sonografik dalgalar kullanılarak doku izlemesi yapılır ve gri bir skalada görüntü sağlanmasına olanak sağlamaktadır. Dokunun incelenmesinde 12 MHz ve yüksek rezolüzyona sahip lineer probalar kullanılır. Ultrasonografik görüntüleme tekniği ile meme dokusu için solid ve kistik bölümleri birbirinden ayrılabilen en etkin araçlar arasında yer almaktadır. Mamografik görüntülemelerde elde edilen bulguların sınıflandırılmasında önemli bir yer tutmaktadır, özellikle yüksek dansite doku ve ışın tedavisi görmüş hastalarda tamamlayıcı olarak sıklıkla kullanılan hızlı ve ucuz bir yöntemdir. Günümüzde ilerleyen teknoloji ile harmonik olarak görüntüleme de kolaylıkla rutin kullanımlarda tercih edilebilmektedir (Demircioğlu, 2013.; Geçer, 2014). Çeşitli çalışmalarda mamografik görüntüleme yönteminin tanısal değerlendirme yöntemlerini değerlendirmiştir, bu bağlamda mamografi ve ultrasonografi kombinasyonu daha yüksek hassasiyetlerde sonuçlar elde edildiği gözlemlenmiş ancak özgüllük değerinde de azalma olduğu görülmüştür. Tıbbi maliyetleri, tanı için gerekli tanı muayeneleri için gereken zamanı ve gereksiz muayeneden doğabilecek zararlı sonuçları engellemek için meme USG hastalar için verimli bir tekniktir (Ayar, 2021).

40 yaş altı hasta gruplarında fiziki muayenede ele gelen kist bulunamadığı durumlarda ultrasonografi yardımıyla lezyonun lokasyon tespiti ve türü yapılabilmekte, solid bir yapı mı yoksa kist mi olup olmadığı daha kolay ayırtedilebilmekte ve iğne biyopsisi yapılırken kullanılan bir dijital görüntüleme yöntemidir. Günümüzde kanserin tespitinde tek radyolojik görüntüleme yöntemi etkin bir sonuç verememektedir, dolayısıyla mamografik yöntemlerle özellikle dens dokularda mamografi düşük sonuçlar verilebilmektedir. Ultrasonografide de mikro lezyonlarının görüntülenebilmesi mamografik görüntülere göre bir dezavantaj gösterebilmektedir.

Ultrasonografi birlikte kullanıldığı durumlarda tespit çıkarımında hata payı %3'e kadar azaltılabilmektedir (Öner, 2018; Yıldız, 2017).

American College of Radiology (ACR)'nin beşinci versiyonunda yayınladığı rapora göre klinisyenlere bir atlas sunmaktadır böylece standartlaştırılmış meme görüntüleme terminolojisi, değerlendirme ve raporlama imkânı sunmaktadır. Sınıflandırma birden başlayıp kanser ilerleme seviyesine kadar en son beşinci seviyeye kadar derecelendirme sistemine ayrılmıştır. Sınıflandırma için saptanan lezyonun şekline, sınırlarına, büyüklüğüne, etraftaki dokulara ve organlara tutunmasına göre Tablo 1.10.'da gösterildiği kategorilerde tespiti yapılmaktadır.

Geleneksel olarak ultrasonografi klinik olarak yapılan muayenelerde farkedilen şüpheli bulguların kontrolünde veya mamografik yöntemlerle tespit edilen anormallikleri kontrol edebilmek ve daha net değerlendirebilmek için kullanılır. Güncel teknolojiye gelişmelerle birlikte mamografide tespit edilebilen küçük veya palpe olarak adlandırılan anormallikleri değerlendirebilme sebebiyle de kullanılabilmektedirler. Mamografi bir tanı aracı olarak asimptomatik hastalar için standart bir yöntem olsa da yoğun doku ile çevrelendiğinde tespit zorlaşmaktadır. USG'nin klinik ve mamografik olarak gizli kalmış veya tesadüfi lezyonları saptayabildiği araştırmalarca saptanmıştır. Bu tarama yöntemi ile mortalite önlenmekte ve gereksiz biyopsilerin önüne geçilmesinde önemli bir araç olarak karşımıza çıkmaktadır.

Tablo 1.10. Kanser USG sınıflandırma değerleri (McLelland ve ark., 1991)

Sınıflandırma	Tanım
BI-RADS 1	Normal
BI-RADS 2	Şüpheli bir bulgu saptanmadı
BI-RADS 3	Muhtemel benign lezyon
BI-RADS 4	Şüpheli normal olmayan lezyon
BI-RADS 5	Malign bulgu

1.2.4.3. Magnetik rezonans görüntüleme (MRG)

Manyetik rezonans görüntüleme dokuya gönderilen elektromanyetik dalgaların geri yansmasıyla elde edilen sinyalin dijital görüntüye dönüştürülme sistemidir ve buna

bağlı olarak yumuşak dokuyu en iyi verimle görüntülemeye etkindir. Bu teknikte diğer yöntemlerde olduğu gibi X ışığı kullanılmaz. Manyetik rezonans fizik prensipleri Bloch ve Purcell tarafından 1946 yılında ilk kez tanımlanmış ve manyetik rezonans görüntüleme ilk kez 1973 yılında Lauterber tarafından kullanılmıştır. Meme kanseri taramada kullanılan önemli bir araçtır, lezyon saptama oranı %88 ile %100 arasında değişmektedir (Kuhl, 2000). Hastalara çekim yapılmadan önce yüksek manyetik alan hakkında bilgiler verilir, klostrrofobi olan hastalar için özel meditasyon seansları da düzenlenebilir.

Dijital veya fiziksel baskı sonucu görüntüleme yöntemlerinin asıl amacı kanser tespitinin yapılabilmesidir. En yaygın tanı aracı olarak mamografi kullanılmaktadır, yüksek dansiteye sahip dokularda tespit oranı %48'e kadar düşebilmektedir bu sebeple tamamlayıcı bir yöntem olan USG ile tam tespit yapılması hedeflenmektedir. İLK adı verilen tümörün tespitinde mamografi yöntemi daha düşük oranlarda tespit imkânı sunabilirken ultrasonografi yönteminde birçok testte negatif testler alındığı bilinmektedir. MRG ile tespitinin kesin bir şekilde yapılabilirdiği araştırmalarda belirtilmiştir. Butler ve ark. yaptığı çalışma incelendiğinde mamografi ve USG korelasyonu ile tespit oranı %93 gibi bir tespit oranına sahipken kalan vakaların tespitinde MRG ile tam tespit edilebildiği farkedilmiştir (Lehman ve ark., 2005). Aşağıdaki Tablo 1.11.'de MRG yönteminin başlıca kullanım alanları belirtilmiştir.

Tablo 1.11. MRG tekniği kullanım alanları

1.	Cerrahi operasyon öncesinde tümörün hangi evrede olduğunun belirlenmesi
2.	Operasyon sonrası artık tümörün saptanması
3.	Klinik kontrol, Mamografi ve USG belirlenemeyen vakaların netleştirilmesi
4.	Lenf nodu metastazı olan vakalarda primer tümör tespiti
5.	Tedavi için uygulanan Neoadjuvan kemoterapinin etki kontrolü
6.	Riski yüksek vakalarda tarama yöntemi olarak kullanılması
7.	Kanserli durumlarda tedavi sonrası durumların kontrolü ve değerlendirilmesinde
8.	Implantların son durumları kontrolü
9.	Patolojik olarak akıntıların kontrolü ve değerlendirilmesi

Dokunun MRG kontrolünde çoğunlukla T2A sekansı tercih edilir, bu sekans ile lezyon lenf nodları ve ödem çok net bir şekilde görüntülenebilmektedir. Lezyonun değerlendirilmesinde fiziksel özellikleri dikkate alınır veya kistin kontrast tutulumu kontrol edilerek değerlendirilir. Diğer görüntüleme tekniklerinde olduğu gibi MRG

teknikinde de saptanan bulgunun standart bir şekilde tariflenebilmesi için Tablo 1.12.'de yer aldığı gibi ortak bir sınıflandırma yöntemi belirlenmiştir.

Neoadjuvan kemoterapi uygulanan hastaların bu tedavi yöntemine pozitif veya negatif yanıtların zamanında değerlendirilmesi klinik açıdan önem taşımaktadır. MRG yöntemi ile kemoterapi tedavisi izlenerek lezyonda küçülme ve yok olması hedeflenmektedir. Görüntülemenin yapıldığı bir lezyonun anatomik anlamda en net olarak sınırlarının belirlenebildiği ve şeklinin kontrol edilebildiği sekans olarak T1A tercih edilmektedir. Saptanan bulgulara sınırlar belli ve şekil daha net olarak görünüyorsa benign bir tümör sınıfına işaret ederken lezyon sınırlarının kaybolduğu veya yayıldığı durumlar malign tümör sınıfına daha yakın olduğu varsayılmaktadır.

Tablo 1.12. Kanser MRG sınıflandırma değerleri

Sınıflandırma	Tanım
0	Belirlenememiş, ek inceleme gereklidir. (MRG ile saptanmış bir lezyonun farklı görüntüleme araçlarıyla incelenmesi)
1	Negatif (Kontrastlanabilmiş bir bulguya rastlanmamış)
2	Benign (Nokta ve sınıfları belli kontrastlanma gözlemlenmesi)
3	Olası Benign (Bölgesel olarak kontrastlanmanın meydana gelmesi)
4	Şüpheli
5	Yüksek olasılık düzeyinde Malign
6	Bilinen Malign (Biyopsi yöntemleriyle de kanıtlanmış)

1.2.5. Tedavi yöntemi olarak Neoadjuvan kemoterapi (NAC)

Lokal İleri Meme Kanseri (LİMK) kavramı Haagensen ve Staut tarafından tarafından sağ kalım ve klinik operasyon konusunda ilk araştırmaları yapan isimler olmuştur. Bu araştırmaya bağlı olarak bir hastanın artık cerrahi olarak bir tedavi yönteminin olmadığı durumlar için (inoperabilite) kriterler belirlemişlerdir. Sonraki çalışmalarda ise bu tür evrede durumlar için kombine tedavi yöntemleri uygulanmıştır, radyoterapi ve sonrasında cerrahi tedavi yöntemleri gibi (Yarbaş, 2020). Günümüzde multidisipliner tedavi yöntemlerinin de temelini atmıştır. Tek bir tedavi yöntemi ile sağ kalım oranları %50'den düşük olduğu araştırmalarda belirlenmekte ve ilk defa 1970 yıllarından sonra kemoterapik yöntemler de aktif olarak dahil edilmeye başlanmıştır (Öner, 2018) .

Lokal ileri meme kanseri üçüncü evrede olan kanser türleri olarak gruplandırılabilir. Bu sınıftaki tümörler yavaş seyirli olabileceği gibi yayılım

hızı biyolojik olarak yüksek hızda da olabilmektedir. LİMK oranı ülkelerin gelişmişlik düzeylerine göre oranları farklılık gösterebilmektedir, gelişmiş ülkelerde bu oran maksimum %20'lerde olmasına karşın az gelişmiş ülkelerde %73 gibi çok yüksek rakamlarda olabilir. Bu oranın yüksek olmasında tanı programlarının eksikliği, toplumsal bilinç, eğitim düzeyi, beslenme alışkanlıkları gibi etkileyen faktörler bulunmaktadır (Ayar, 2021).

Klinik açıdan Limk tanımı yapabilmek için aşağıdaki etkenlerin meydana gelmiş olması beklenmektedir (Bahar, 2021):

- Tespit edilen tümör boyutu minimum 5 cm olması ve lenf bezlerinde meydana gelen lezyonun fiziki olarak elde hissediliyor olması gerekmektedir.
- Tümör boyutundan bağımsız olarak cilt tutulumu olması veya göğüs duvarına zararlı tümörün yerleşmesi.
- Lenf bezlerindeki lezyonun çevre doku veya organları etkilemesi.
- Meme dokusuna etki etmesi ve dokuda portakal kabuğu görünümü vermesi. Dokunun üçte bir oranında ödem oluşturması.
- İnce uçlu iğne yardımıyla biyopsi ile kesin olarak belirlenmiş üçüncü evre kanser türü olduğu belirlenmesi.

Neoadjuvan kemoterapi (NAKT) tedavi yöntemi cerrahi bir işlem öncesinde uygulanan primer tedavi yöntemi olarak kullanılmaktadır, amaç hastalıksız yaşam süresini arttırmak ve sistematik metastazların ortadan kaldırılmasıdır. Bu alandaki çalışmalar çoğunlukla kemoterapik tedavi yöntemleri sonrasında Patolojik Tam Yanıt (PTY) değerlendirilmesinde yoğunlaşmıştır. Bununla birlikte hastalıksız ve tüm sağ kalım oranları bir diğer araştırma konusu olmuştur.

NAKT yöntemi hastanın artık cerrahi yöntemlerle tedavisinin mümkün olmadığı durumlarda etkinin azaltılması amacıyla uygulanmakta veya cerrahi müdahaleye uygun hale getirmede önemli bir tedavi yöntemi olarak kullanılmaktadır. Hastaya bu uygulama altı ay boyunca 4 doz şeklinde uygulanır. Tedavi yöntemi multidisipliner

olarak radyolojik olarak da kontrolü sağlanarak günümüzde aktif olarak kullanılmaktadır. Tedavi öncesi sonrası MRG ile tümörün durumu gözlenebilmektedir (Charfare, Limongelli ve Purushotham, 2005).

Lokal ileri meme kanseri hastaları kemoterapi yöntemi olan neoadjuvan ile tedavi edildiğinde tümörün küçülmesi ve buna bağlı etkileri sistematik olarak incelenmektedir. Tümör yanıtlarının değerlendirilmesinde Dünya Sağlık Örgütü (WHO) yayınladığı kriterler ve yaygın olarak kullanılan tümör değerlendirme ve sınıflandırmada yaygın olarak kullanılmaktadır. 2000’li yıllarda ise Katı Tümörlerde Yanıt Değerlendirme Kriterleri (RECIST) iki boyutlu değerlendirme sistemi yerine daha basit haliyle gruplandırılma sistemi sunmuştur. Bu iki yaklaşım Tablo 1.13.’te yer aldığı gibi dört sınıfta değerlendirilmiştir (“WHO | World Health Organization”, 2022).

Tablo 1.13. WHO ve RECIST değerlendirme kriterleri

	WHO Kriterleri	RECIST Kriterleri
Tam Yanıt	Lezyonların kaybolması	Lezyonların kaybolması
Kısmi Yanıt	En az %50 küçülme	En az %30 küçülme
Hastalık Stabil	Yanıt veya ilerleme olmaması	Yanıt veya ilerleme olmaması
İlerleyici	Tam veya kısmi yanıt olmaması, boyutta %25 artış	Tam veya yanıt olmaması ve boyutta %20 artış

BÖLÜM 2. KAYNAK ARAŞTIRMASI

Cicero ve ark. (2017), göğüs radyografilerinden patolojik tespit için orta büyüklükte tıbbi verilerle CNN algoritmasının eğitimi ve doğrulanması tartışılmıştır. Geliştirilen modelin radyoloji raporlamasına özgü karmaşık problemlerine çözüm sağlaması ve radyologlara ikincil bir bakış açısı sağlaması hedeflenmiştir.

Agrawal ve ark. (2022), tıbbi görüntüleme için derin öğrenme üzerine bir anket sunmuştur. Yaptıkları çalışmada bilgisayar, endüstri ve tıp alanının kesişen zorlu bir konu olan derin öğrenmeye dayalı tıbbi görüntü işlemede son zamanlarda sıklıkla tercih edilen derin öğrenme modelleri çerçevesini tanıtmış, radyolojik görüntülere global olarak uygulanan klasik modeller tartışılmıştır. Akciğer hastalıklarında nöral ağ uygulaması tanıtılmış ve farklı hastalıklarda kullanımı için bir model çizmiştir.

Jaiswal ve ark. (2019), pnömoni tanımlaması ve akciğer görüntü boyutunun model performansında önemine ait bir yaklaşım sunmuştur. Mask-RCNN yaklaşımı ile bölgesel bağlamalı öneri sunmayı hedeflenmiştir. Sunulan model mimarisi ile derin öğrenme ve bilgisayarlı görme tekniklerinin kullanımı, tıbbi görüntülemenin diğer alanlarda da genişletilmesi amaçlanmıştır.

Hwang ve ark. (2019), akciğer tüberkülozu ve pnömoni gibi önemli göğüs hastalıklarını sınıflandırabilen bir derin öğrenme modeli sunmuşlardır. Sunulan algoritma, bağımsız veri setlerinde sürekli olarak yüksek performans gösterdiği ve buna bağlı olarak göğüs radyologlarından birçok vakada üstün performans gösterdiğine yer verilmiştir. Ayrıca, geliştirilen model yardımıyla doktor performansının arttığı gözlemlenmiştir.

Sirazitdinov ve ark. (2019), pnömoni tespiti ve lokalizasyonu için RetinaNet ve Mask R-CNN adlı iki evrişimli sinir ağından oluşan bir model önermiştir ve 2019'da otomatik pnömoni teşhisi için sorumlu bir çözüm olduğu doğruladığı bir çıktı elde edilmiştir. Önerilen model çıktısı ayrıca, yorumlaması ve pratik uygulanabilirliklerini doğrulaması için yardımcı olan bir doktor ekibi tarafından da incelenmiştir.

Rajpurkar ve ark. (2018), göğüs radyografilerinde pnömoni, plevral efüzyon, pulmoner kitleler ve nodüller dahil olmak üzere on dört farklı patolojinin varlığını aynı anda tespit etmek için konvolüsyonel bir sinir ağı olan CheXNeXt olarak adlandırılan bir kütüphane geliştirmiştir, pratisyen radyologlarla benzer bir performans düzeyinde sınıflandırabilen bir derin öğrenme algoritması geliştirmiş ve doğrulanmıştır.

Christe ve ark. (2019), idiyopatik pulmoner fibrozun yanı sıra insan okuyucuyu sınıflandırabilen makine öğrenmesine dayalı bilgisayar destekli algılama algoritması önermiştir, ayrıca yapay zekâ tanıma çok hızlı ve evrişimli sinir ağları (CNN'ler) görüntü tanımlama konusunda insanlardan daha iyi performans elde etmişlerdir. Kaggle tarafından sağlanan göğüs röntgeni görüntülerine sahip veri setini normal ve pnömoni olmak üzere iki sınıf olmak üzere toplam 5216 eğitim ve 624 test görüntüsü ile sınıflandırma için kullanılmış, bu hastalıkları veri setinde sınıflandırmak için beş ana akım ağ algoritması kullanarak çalışmalar ve sonuçları karşılaştırılmıştır.

Correa ve ark. (2018), akciğerlerin ultrason görüntülemesi ve görüntü tanıma kullanılarak otomatik sınıflandırılması için bir yöntem sunmuştur. Sunulan yaklaşım, ultrason dijital görüntülerinden dikdörtgen segmentlerde karakteristik vektörler olarak adlandırılan parlaklık dağılım modellerinin analizine dayanmaktadır.

Knok ve ark. (2019), akciğerin X-ışını görüntüsünü girdi parametresi olarak alan ve işlenen görüntüye dayalı olarak bir çıktı olarak pnömoni olasılığını döndüren akıllı bir sistemin modelini geliştirmek için önceden tanımlanmış bir evrişim sinir ağı mimarisi kullanmıştır. Sunulan modelde, görüntü verilerinin sınıflandırılması için önceden öğrenilmiş ilkeleri kullanarak modelin doğruluğuna büyük ölçüde katkıda bulunan toplam 16 katmandan oluşan VGG16 mimarisi kullanılmıştır.

Rajaraman ve ark. (2018), tanısal yaklaşımın bir parçası olarak CXR'leri kullanarak COVID-19 veya gelecekte ortaya çıkabilecek diğer solunum yolu virüslerine karşı savaşa önemli ve neredeyse evrensel olarak mevcut bir araç geliştirmek amacıyla CXR'lerde görülen bulgulara toplu bir derin öğrenme uygulaması yapılabileceğini önermiştir. COVID-19 pandemisi, dünya çapında nüfus sağlığı ve ulusal ekonomiler üzerinde son derece olumsuz bir etki yaratmıştır bu nedenle erken tanı genellikle yetersiz olmuştur ve serolojik testler yaygın olarak mevcut değildir. Tanısal yaklaşımın bir parçası olarak bu uygulama ile dijitalleştirilmiş göğüs radyografileri kullanılarak COVID-19 pnömonisinin tespiti için bir çözüm aracı sunmuştur.

Anwar ve ark. (2018), klinik uygulamalarda üretilen görüntülerin analiz etmiştir. Klinik problemleri çözme bilimi tıbbi görüntü analizi olarak da bilinmektedir. Bununla ilişkili olarak amaç klinik açıdan bir tanı ortaya koyabilmek için doğru ve yeterli bilgiye sahip olmak gerekmektedir. Biyomedikal mühendisliği de bu alanda gerçekleşen güncel gelişmeleri ve tıbbi görüntü analizini en önemli araştırma konularından biri olarak ortaya çıkmaktadır. Bununla ilişkili olarak derleme araştırmasında evrişimli sinir ağlarını kullanarak tıbbi görüntü analizini geniş anlamda gözden geçirmiş, teknik zorluklarını ve potansiyelini ortaya koymuştur.

Razzak ve ark. (2018), derin öğrenmenin sağlık hizmetlerinde, özellikle tıbbi görüntüde dominasyonu, diğer gerçek dünya sorunlarına kıyasla oldukça yavaş ilerlemektedir. Bu çalışmada araştırmalarında büyümeyi etkileyen faktörleri analiz etmiş, tıbbi görüntüde uygulama alanlarını araştırmışlardır. Ek olarak bu alanda açık olan alanlar vurgulanmıştır.

Maruyama ve ark. (2018), CT, MR ve X-ray görüntülerinin sınıflandırılması için SVM, ANN ve CNN olmak üzere üç makine öğrenme yöntemini uyarlamışlar ve veri kümelerini kullanarak bu yöntemlerin doğruluğunu karşılaştırmışlardır. Konvolüsyonel sinir ağları ile uygulanan yöntemde daha kısa bir zaman aralığında, daha az veri kapasitesiyle tıbbi görüntüleri doğru bir şekilde tanımlama becerisini göstermesini vurgulamışlardır bu nedenle, CNN'i bilgisayar destekli tıbbi görüntü işleme ve denetleme sistemlerine dahil etmenin etkili olduğu sonucuna varılmıştır.

Gabruseva ve ark. (2020), akciğer opasite bölgelerinin lokalizasyonu için basit ve etkili bir algoritma sunmuştur. Önerilen model daha önce ImageNet veri setinde önceden eğitilmiş eğitim seti kullanılmasına dayanmaktadır. Bildirilen yöntem, Kuzey Amerika Radyoloji Derneği'nin sıtma araştırma yöntemlerinde başarılı sonuçlar arasında gösterildiği de belirtilmiştir.

El Kaitouni ve ark. (2020), çalışmalarında tümör tanımlaması için bir MRI görüntüsü alınır ve lezyonları bulmak için bir uzman tarafından manuel olarak analiz edilmektedir. Bu prosedür zaman almaktadır ve aynı vaka için uzmanlar arası ve uzmanlar arası varyasyonlar çok farklı durumlar olabilmektedir. Bu sorunların üstesinden gelmek, uygulayıcıların karar vermelerine yardımcı olmak için son yıllarda birçok otomatik ve yarı otomatik yöntem önerilmiştir. Çalışmada tümör tespiti için geliştirilmiş bir Markov yöntemi ve U-net tabanlı bir derin öğrenme yöntemi kullanmıştır.

Ramirez ve ark. (2019), MRI görüntü segmentasyonu için yeni bir varyasyon modeli sunmuşlardır. Sunulan model, klasik bir toplam varyasyon tabanlı düzeltme işlevine bir belirginlik terimi ekleyerek, arka plandan neyin ilgili (belirgin) olduğunu ayırt edebilmektedir.

Sobhaninia ve ark. (2020), görüntü bölütleme yöntemi olarak çoklu ölçekler ve iki kademeli ağ kullanımı ile daha etkin sonuçlar elde etmişlerdir. Önden görünüşlü göğüs radyografilerinde çoklu patolojilerin tespitinde kurul onaylı radyologlarla karşılaştırılabilir performans gösteren bir derin öğrenme algoritması olan CheXNeXT'i ortaya koymuşlardır. Sunulan çözüm ile, sağlık hizmeti sunumunu iyileştirmek amaçlanmıştır ve çeşitli akut hastalıkların tespiti için göğüs radyografisi uzmanlığına erişimi artırma potansiyeline sahip olabilmeyi hedeflemektedir.

Wu ve ark. (2020), tümör görüntü segmentasyonu için bir 3D U-net tabanlı derin öğrenme modeli kullanmıştır. Gliomlar en sık görülen primer maligniteleri olarak varsayılmaktadır, doğru ve etkin tümör segmentasyonu, teşhis, tedavi planlaması ve

risk faktörü tanımlaması için önem taşımaktadır. Bu araştırmada, multimodal MRI taramalarını kullanarak tümör segmentasyonu için derin öğrenmeye dayalı bir mimari sunulmuştur. Beyin tümörü segmentasyon görevi için 3D U-net tabanlı bir derin öğrenme modeli kurulmuş, kurulan model BraTS 2019 veri seti üzerinde eğitilmiştir.

Chetty ve ark. (2019), 3D U-Net derin öğrenme mimarisine dayalı beyin MRI görüntülerini sınıflandırmak için yeni bir yaklaşım modeli sunmuşlardır, önerilen yaklaşım, U-net modelinde güçlendirici ve güçlendirici olmayan tümörün etrafındaki glioma ve ödemli dokunun yapısal yapısını modellemektedir. Sunulan model hem sinir ağının optimize edilmiş bir halini hem de segmentasyon dokusunun biyolojik bağlamını dikkate almaktadır.

Nisar ve ark. (2021), derleme makalelerinde insan vücudu sisteminin hastalıklarını teşhis etmek için sağlık hizmetlerine uygulanan derin öğrenme modellerini detaylandırmışlar, farklı faktörleri ve parametreleri temel alarak farklı hastalıkları karşılaştırmalı incelemişlerdir. Farklı derin öğrenme uygulamaları karşılaştırılıp ilgili alandaki araştırma fırsatları ve zorlukları belirlenmiştir. Sağlık hizmetlerinde derin öğrenme modelleri üzerine araştırmalar kapsamlıdır ve yine de birçok zorluk öne sürülmektedir. Araştırmada yer alan anket ile sağlık alanında uygulanan önerilen teknikler ve bu yeniliklere yönelik bir adım olabilmesi ve daha akıllı hale gelmelerine yol açabilmeleri hedeflenmiştir.

Pitale ve ark. (2021), Yapay zekâ (AI) ve Derin öğrenme (DL), birçok araştırma ve endüstriyel uygulama alanında üstün problem çözme stratejileri haline gelmiştir, araştırmada biyotıp ve sağlık, güvenlik, eğitim ve teknolojilerdeki en son trendlerde bilgisayarla görme yoluyla derin öğrenme uygulamaları ve araştırma alanlarını incelemişlerdir.

Jahid ve ark. (2021), COVID-19 virüsünün salgınları beklenti sınırlarını aşmakta ve önceki tüm virüs salgınlarına kıyasla tüm hayati etkileyerek rekor kırmaktadır, virüsünün etkisi ciddi bir hastalıklara neden olmakta ve ciddi alveolar hasar ve ilerleyici solunum yetmezliği ile sonucu ölümle sonuçlanabilmektedir. Çalışmada

bilgisayarlı görme teknolojisi kullanılarak göğüs röntgeni görüntüsünden otomatik olarak virüsün etkilerinin saptanması, sınıflandırılması otomatikleştirilmiş süreç, virüs ile mücadele için geleneksel sağlık hizmeti sürecini geliştirmek için büyük bir potansiyel sunmakta birçok kurumda eğitimli doktor eksikliğini azaltabilmeyi hedeflemektedir. X-ray görüntüsünün sınıflandırılması için derin öğrenme tabanlı karma bir model kullanılmıştır. Segmentasyonda etkilenen bölgeyi segmentlere ayırmak için DenseNet tabanlı U-Net mimarisi kullanılmıştır.

Ramirez ve ark. (2019), tıbbi görüntülerin kullanımı dünyadaki çeşitli sağlık merkezlerinde günlük kliniklerin bir parçasıdır ve özellikle bilgisayarlı tomografi görüntüleri şüpheli lezyonlarının erken saptanmasında önemli bir anahtar olabilmektedir. Tomografi görüntü incelemesi herhangi bir prosedürden (örn. bronkoskopi, biyopsi) önce akciğer lezyonlarının saptanmasını sağlamaktadır. Lezyonların baskın lokalizasyonu, farklı görüntü işleme ve bilgisayarlı görme teknikleri kullanılarak gerçekleştirilir. Araştırmada bulanık derin öğrenme kullanarak akciğer lezyonunu lokalize etmek için bir yaklaşım sunmaktadır, LIDC-IDRI veri kümesini kullanan basit bir evrimsel sinir ağı kullanılmakta olup her bir görüntü anatomik yapılara ait olmalarına göre bir olasılık vektörü ile ilişkili olarak bölünmektedir.

Lo Gullo ve ark. (2021), lokal ileri meme kanserinde neoadjuvan kemoterapi sonrası tam yanıtın elde edimesinin cerrahiye kolaylaştırıcı etkisi olmakta ve aynı zamanda ölüm riskini daha az indirgemekle kalmayıp sağkalım süresini için bir belirtleç olmaktadır. Gullo ve arkadaşları nitel ve nicel multiparametrik magnetik rezonans görüntü özelliklerinin bir karışımını kullanarak tedavi yanıtını tahmin etmek için geleneksel makine öğrenimi yaklaşımları uygulanmıştır, böylece tam yanıt neoadjuvan tedaviye yüksek doğrulukla erken tahmin edilmesini sağlamak amaçlanmıştır. Uygulanacak tedavinin etkisiz kalması durumunda kaynaklanabilecek toksisiteyi en aza indirerek kemoterapik tedaviye tam yanıt vermeyenlerde cerrahide gecikmeleri önleyerek ve teknolojinin entegrasyonu klinik yönetimi iyileştirme potansiyeline sahiptir.

Moghadas ve ark. (2021), neoadjuvan kemoterapi, lokal ileri meme kanseri için tedavide önemli bir tedavi yöntemi olarak gösterilmesine karşın araştırmalara göre yaklaşık %70'i tedaviye olumlu yanıt verebilmektedir. Araştırmada tedavide tam yanıtın erken tahmini için makine öğrenme teknikleri ile kantitatif bilgisayarlı tomografi parametrik görüntüleme araştırılmıştır. Tomografi görüntüleri ve ikincil türev dokusal özelliklerinin korelasyonunun tedaviye başlamadan tahmin etmede bir yöntem olarak sunmuşlardır.

Pang ve ark. (2020), tıbbi radyolojik görüntülerden makine öğrenmesi için üst düzeyde özellik çıkaran derin öğrenme radyomiklerindeki son gelişmeler ile meme kanseri için bilgisayar destekli tanı performansını daha çok artırabilmektedir Pang ve arkadaşları derleme araştırmasında farklı modalitelerle kapsamlı bir genel bakış ve bu alanda gelecekteki yönleri önermeyi amaçlamışlardır. Araştırmalarında ayrıca literatürde kullanılan derin öğrenme mimarileri hakkında bir karşılaştırma ve meme kanserinde CAD (Bilgisayar Destekli Tasarım) kullanarak klinik tedavi yönetimine ve karar vermeye referans olarak araştırma yöntemiyle ile potansiyel zorluklar belirtilmiştir.

Herent ve ark. (2019), çalışmalarında manyetik rezonans görüntüleme (MRG) kullanarak iyi huylu ve kötü huylu meme lezyonları arasında ayırım yapmak için bir derin öğrenme modeli sunmuşlardır böylece hastalık potansiyelini değerlendirmek ve meme lezyonlarının farklı histolojik alt tiplerini karakterize etmeyi hedeflemiştir. Sunulan yöntemde mrg görüntülerindeki lezyonları tespit etmek ve karakterize etmeyi aynı anda öğrenen bir derin öğrenme modeli sunulmuştur. Sunulan algoritma performansı eğri altı kalan alan (AUC) değerlerin toplamı ile ayrılmış bir test setiyle ölçümlenmiştir.

Zheng ve ark. (2020), Meme kanseri en tehlikeli hastalıklar arasında yer almaktadır ve araştırmalara göre kadın kanser ölümlerinde en büyük ikinci hastalık olarak yer almaktadır. Çalışmada kanser tespiti için derin öğrenme destekli Adaboost algoritması (DLA-EABA) gelişmiş hesaplama teknikleri ile matematiksel olarak önerilmiştir, manyetik rezonans görüntüleme, ultrason ve mamografi gibi radyolojik görüntüleme yöntemlerinde meme kitlelerini karakterize etmek için CNN tabanlı transfer

öğreniminin incelenmesiyle başlamaktadır. Çalışmada önerilen Adaboost tabanlı yaklaşım kitle tespit etmede yüksek doğruluk oranıyla sonuçlanmakta ve böylece klinik olarak değerlendirildiğinde hasta sağkalım oranını artırabilecek bir yöntem olarak düşünülmektedir.

Mojabi ve ark. (2020), araştırmalarında tomografik mikrodalga ve ultrason özellikli görüntülerinin doku tipi sınıflandırmasını gerçekleştirmek için bir derin öğrenme yaklaşımı önermişlerdir, U-net mimarisini temel alan modelde evrimsel sinir ağı kullanılarak görüntüdeki her pikselin sınıflandırılmasındaki belirsizliği de ölçen bir yöntem olarak sunulmuştur. Çalışmadan önerilen doku sınıflandırma modeli ve belirsizlik niceleme yaklaşımı, Bayes bazlı olarak daha önce çalışılmış bir doku tipi sınıflandırma yönteminden daha iyi performans sonuçları elde edildiği gösterilmiştir.

Giannini ve ark. (2020), çalışmalarında magnetik rezonans görüntüler kullanarak metastazların neoadjuvan kemoterapi sonrası yanıtı tahmin etmede U-net mimarisine dayalı olarak bir derin öğrenme metodu sunmuştur. 39 metastazik oluşan doğrulama setinde, otomatik derin öğrenme algoritması, metastazik olanların %82'sini, %67'lik bir medyan hassasiyetle tespit edebildiği gösterilmiştir. Tedaviye yanıtın tahmini aşamasında klinik olarak günlük manuel segmentasyon zahmetini ortadan kaldırmayı amaçlayan bir yöntem sunulmuştur.

Byra ve ark. (2021), meme kanserinde neoadjuvan kemoterapiye yanıtının erken tahmini için iki derin çalışmalarında öğrenmeye dayalı yaklaşım önermişlerdir. Pre-trained (önceden eğitilmiş) evrimsel sinir ağları ve transfer-learning (öğrenme transfer) yaklaşımları ile sunulan modelde kemoterapiye yanıtın tedaviden önce toplanan ultrason görüntülerine dayanarak tahmin edilebileceğini göstermişlerdir. Modelin daha büyük hasta grubu ve verilerle geliştirilmeyi açık yönü bulunmaktadır.

Yukarıda bahsedilen çalışmalardan bazıları, sağlık alanında yetersiz eğitim veri darboğazını çözmek için transfer öğrenme yöntemlerini kullansa da eğitim verileri üzerinde kullanılmıştır. Buna bağlı olarak bu yöntemin kullanıldığı çalışmalarda diğer çalışmalardan daha iyi tanıma sonuçları elde edildiği görülmüştür. Bununla birlikte,

transfer edilen eğitim veri kümesi ile ilgilenilen sağlık araştırma alanındaki veri kümesi arasındaki büyük farklılıklar sebebiyle öğrenme aktarım modelinde iyileştirmeler yapılmalıdır, aktarım yapılacak alana uygun hale getirilmelidir. Buna bağlı olarak algoritma performansı büyük ölçüde etkilemektedir. Sonraki bölümde de ele ayrıntılı ele alınan araştırmada farklı evrişimli derin öğrenme modelleri detaylı incelenerek ve yapısal avantajları ele alınarak analiz edilmesi planlanmıştır. Doğruluk oranları ve farklı performans indikatörleri karşılaştırılıp elde edilen sonuçların gelecekteki çalışmalara dayanak gösterilmesi hedeflenmiştir.



BÖLÜM 3. MATERYAL VE YÖNTEM

Bu bölümde çalışmada kullanılan derin öğrenme ve derin öğrenme ile bilgisayarlı görü yöntemleri detaylı olarak açıklanmıştır. Bilgisayarlı görüde evrişimli sinir ağı mimari ile bilgisayarlı görüde nesne algılama metotları örnek senaryolarla değerlendirilmiştir.

3.1. Derin Öğrenme Kavramı

Bu başlıkta derin öğrenme kavramı, makine öğrenmesine göre farklılıkları ve yapay zekada konumlanması açıklanmıştır.

3.1.1. Yapay zekâ kavramı ve alt alanları


Yapay zekâ, bilgisayarlar düşünebilir mi sorusuna cevabın arandığı 1950’li yıllardan itibaren süregelen ve halen bu alanda araştırmaları artan bir alan olarak ortaya çıkmıştır. İnsanların düşünsel olarak ortaya koyduğu faaliyetleri makineler aracılığıyla otonom olarak ortaya koyulması genel tanım olarak yapılabilir. Yapay zekanın nihai amacı makinelerde insan benzeri zekâ geliştirebilmektir, bu da ancak insan beyninin nasıl öğrendiğini taklit etmeye çalışan öğrenme algoritmaları ile mümkün olabilmektedir. Öğrenme amacı içermeyen yaklaşımlar da yapay zekâ araştırma alanları içerisinde yer alabilmektedir, örnek uygulama olarak satranç tüm koşullar tamamen bilgisayarda kodlandığı için bir makine öğrenmesi uygulaması olarak yer edilememiştir. Bu tür yaklaşımdaki uygulamalara sembolik yapay zekâ olarak tanımlanmaktadır. 1950’li yıllardan 1980 yılına kadar baskın görüş olarak sürdürmüştür (Chollet, 2021).

1950 yılında Alan Turing tarafından ele alınan bir makalede “Makinelerin düşünebilir mi?” sorusunu sorarak modern kullanılan bilgisayarların ve yapay zekanın temelini

atmıştır. Turing testinde genel konsept olarak gizli bir ortamda bulunan bir makine ve bir insana ikinci bir kişinin belirli bir alanda sorularını klavye yardımıyla yöneltir. Kişinin sorduğu sorulara ortak bir ekrandan aldığı cevaplara göre makineyi ayırt etmeye çalışır, eğer makine ayırt edilemezse Turing testi başarılı olmuş sayılır. Bu test ile günümüzde de kullanılan doğal işleme ve makine öğrenme tekniklerinin temel çalışma prensiplerine yön verici bir esin kaynağı olmuştur (“Vikipedi”, 2022).

Normal zekâ kavramı ile yapay zekâ kavramları kıyaslandığında yapay zekanın birçok avantajı ortaya çıkabilmektedir. İnsan zekâsı hangi teknik olduğu sorgulanmadan bilgi ve tecrübe aktarımı zahmetli bir süreç olmasına karşın yapay zekâ çok kolay paylaşılabilir ve dijital olarak transfer edilebilir (Özdemir, 2019). Tutarlılık kavramı ile kıyaslandığında insanlar arasında değişen görüş farklılıkları esas alındığında aynı durum için farklı senaryo sonuçları elde edilebilir hatta aynı kişinin bir konuda hakkında farklı zaman dilimlerinde farklı kararlar verilebildiği görülebilen yapay zekada kurulan model ile sonuç tutarlılığı olduğu görülmektedir.

Yapay zekâ alanında yapılan araştırmaların temel hedefi veya amacı farklı çıktılar olabilmektedir: bilgi planlama, algılama, sınıflandırma, nesneleri hareket ettirme, öğrenme, doğal dil işleme gibi birçok farklı amaç içerebilmektedir. Genel yapay zekâ, bu alanda uzun vadeli hedefler arasında yer almaktadır ve yaklaşımlar, istatistiksel yöntemleri, sayısal zekayı ve geleneksel sembolik yapay zekayı içerebilmektedir. Bu alanda farklı disiplinlerde alanlar ve teknikleri içermektedir, örneğin arama ve matematiksel optimizasyon, mantık, olasılık ve ekonomiye dayalı yöntemler gibi farklı yöntemler de yer alabilmektedir. Bilgisayar bilimi, matematik, psikoloji, dilbilim, felsefe, sinirbilim, yapay psikoloji ve diğer pek çok şeyden yararlanır. Yapay zekâ; makine öğrenmesi ve derin öğrenme kavramlarını kapsayan çatı bir konumda bulunmaktadır Şekil 3.1.’de de bu durum gösterildiği gibidir.



Şekil 3.1. Yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi

Teknolojinin mevcut durumunu anlamak, yapay zekanın toplum üzerindeki etkilerini netleştirmek için ilk olarak yapay zekâ türlerinin belirlenmesi gerekmektedir. Yapay zekâ kavramı üç farklı kategoride incelenebilmektedir.

Yapay dar zekâ: Günümüzde kullandığımız yapay zekâ türüdür, tek bir görevi gerçekleştirmek üzerine kurulmuş sistemlerdir. Bu sistemlerde karar mekanizması belirli bir veri kümesinden ortaya çıkarılan bilgi çerçevesi içerisinde olacaktır, bunun dışında gerçekleşmemektedir. Önceden tanımlanmış aralıkta çözüm sunabilmektedir, insan gibi duyarlı ve duygular tarafından yönlendirilemezler ve günümüzdeki uygulamalar tamamı yapay dar zekâ türündedir. Örneğin Google asistan veya Siri gibi uygulamalarda kendisine yöneltilen sorular doğal dil işleme ile yorumlamak ve soru için ilgili olabilecek cevapları belirli bir veri kaynağından yorumlayıp cevap döndürmektedir, kişisel bir soruna nasıl yaklaşılacağı gibi soyut sorular yönelttiğinde ise normal zekadan farklı olarak öz farkındalık, bilinç ve gerçek zekadan yoksun olduklarından mantıklı cevaplar alınamamaktadır. Otonom araçlar yapay zekanın kullanımında en iyi ve karmaşık uygulama örnekleri arasında olmasına karşın, birden fazla yapay dar zekanın biraraya gelmesiyle oluşmaktadır ve insan düzeyinde düşünce esnekliğine ve duygulara sahip olmayan yapay dar zekâ türüdür ancak bu tür sistemler insanın yapabileceği görevleri tutarlı ve transfer edilebilir olması sebebiyle daha hızlı bir şekilde yapabildiğinden verim ve üretkenliğin artmasında önemli avantajlar sağlayabilmektedir.

Yapay genel zekâ: İnsan zekâsı seviyesinde makineleri simgelemektedir. İnsanın normal hayatta gerçekleştirebileceği kompleks bir görevi yerine getirebilmekte, insan gibi bilinçli duyarlı öz farkındalığa sahip bilim kurgu filmlerinde tasvir edilen türdür.


İnsanlar olarak, bilinçli kararlar vermek veya yaratıcı fikirler bulmak için soyut düşünme, strateji oluşturma, düşüncelerimizden ve deneyimlerimizden yararlanma yeteneğine sahibiz, bu yönüyle bu tür zekâ bizi makinelerden üstün kılmakta ve makinelerde kopyalanması zor bir problem olarak ortaya çıkmaktadır.

Yapay süper zekâ: İnsan zekasının yaratıcılık, stratejik düşünme, bilinç gibi tüm alanlarda bilişsel performansını aşan bir yapay zekâ türüdür. Tahminlere göre yapay genel zekaya ulaşıldığı durumda yapay süper zekaya ulaşmak daha kolay olacağı varsayılmaktadır (Özdemir ve ark., 2019). Genel çıkarım teknik olarak insan biliş seviyesine ulaşıldığında daha ilerisinin mümkün olabileceğidir. Bu çok insan yapay zekada endişe duyduğu tür olarak varsayılmaktadır.

3.2. Makine Öğrenmesi

Makine öğrenmesi temelde normalde insanların çözebildiği problemleri insanların ötesine geçerek makinelerin bu problemleri öğrenerek ve bir çözüm bulmalarının yöntemleri araştıran bir alandır. Geliştiricilerin bir problemi çözmesi için makinelere belli bir kural seti tanımlarından ötede belli bir veriden öğrenerek probleme çözüm sunması asıl hedef noktasıdır.

Elle programlanmak yerine makine öğrenmesi sistemleri veriden öğrenerek eğitilir, ilgili görevle ilgili olarak istatistiksel bağlamları ortaya çıkartarak hedef göreve otomatize kurallar ortaya çıkartıp bir kural seti veya model sunulur Şekil 3.2.'de gösterildiği gibi.




Şekil 3.2. Klasik programalam ve makine öğrenmesi

Günümüzdeki bilgisayar bir probleme çözümde daha performanslı sonuçları elde etmemize olanak sağlayacak donanımsal performansa sahiptir. Son yirmi yılda yapay zekâ alanında gelişmelerin önemli etken noktalarından bir faktörü olarak da bu sebep gösterilebilmektedir. Makine öğrenmesi çalışma alanlarından olan görüntü işlemede milyonlarca pikselden oluşan görüntüler oluşturmakta ve bu görüntülerin işlenmesi geleneksel istatistiksel metotlarda sınırlı kalabilmektedir, özellikle Bayes analizi bu büyükle ve kompleks datasetlerde yetersiz kalabilmektedir. Bu yönüyle makine öğrenmesi alanı istatistik bilimiyle ilgili bir alan olarak görünmesine karşın daha alt düzeyde ve spesifik olarak ayrışmaktadır ve matematiksel bir alandan ziyade kompleks ve büyük verilerle uğraşarak teorik bir istatistik alanından pratik programlamanın daha yoğun olduğu mühendislik problemi haline gelmektedir (Chollet, 2020). Makine öğrenimi, bilgisayar kullanımı yoluyla tahmin oluşturmaya da odaklanan hesaplama istatistikleriyle yakından ilişkilidir ek olarak teori ve uygulama alanları sağlayan matematiksel optimizasyon ile güçlü bağları vardır.


Veri analitiği alanında, makine öğrenimi, kendilerini tahmine uygun hale getiren karmaşık modeller ve algoritmalar tasarlamak için kullanılan bir yöntemdir; ticari kullanımda bu, tahmine dayalı analitik olarak bilinir. Bu analitik modeller, araştırmacıların, veri bilimcilerin, mühendislerin ve analistlerin "güvenilir, tekrarlanabilir kararlar ve sonuçlar üretmelerine" ve verilerdeki tarihsel ilişkilerden ve eğilimlerden öğrenerek "gizli içgörülerini" ortaya çıkarmasına mümkün kılmaktadır (Ongsulee, 2018).

Geleneksel programlama yöntemleriyle örnek bir senaryo olarak gereksiz e-posta tespiti yapılıp gereksiz e-postalar kutusuna düşmesi bir problem olarak alındığında en çok kullanılan gereksiz e-posta başlıkları kural seti olarak tanımlanıp Şekil 3.3.'deki

akışta da yer aldığı gibi kural sete bağımlı olarak bir sistemle tespit yapılmaya çalışılır. Her olumsuz durumda yeni kural set eklenerek devam eder. Bakımı makine öğrenmesine göre kolay olmasına karşın dar kapsamda ve sınırlı koşullara bağlı olarak yanıt veriyor olacaktır. Aynı problem makine öğrenmesi ile ele alındığında Şekil 3.4.'de belirtilen akışta olduğu gibi kural setler yerine makine öğrenmesi algoritması veri odaklı olarak yorumlama yaparak sonuç üretiyor olacaktır. Yeni bir gereksiz başlık geldiğinde bunu geleneksel programla yöntemlerinde olduğu gibi yeni bir kural seti tanımlamak yerine makine öğrenmesi yöntemlerinde olağan dışı yeni başlıkların yoğunluğunun arttığı otomatik farkedilir ek operasyon ve programlama maliyetinden kurtulma sağlanabilmektedir.



Şekil 3.3. Geleneksel programlama ile problem değerlendirme şeması




Şekil 3.4. Makine öğrenme yöntemiyle problem değerlendirme şeması

Makine öğrenmesi yöntemlerinin geleneksel programlamaya göre kullanım alanlarına göre tercih nedenleri ve koşulları özetlenmek gerekirse:

- Çoklu kural listelerinin oluşturulması gereken problemler için tercih sebebidir, makine öğrenmesi metodlarıyla çoklu kural setleri sadeleştirilebilir karmaşık kural setlerine göre yüksek performansta çalışabilmektedir.
- Tüm problem tipleri geleneksel programlama teknikleriyle çözüm bulunamamaktadır, özellikle görüntü işleme ve doğal dil işleme gibi büyük verinin kullanıldığı alanlarında.
- Değişikliğin yüksek olduğu problemlerde makine öğrenmesi metodları ile daha etkin sonuçlar elde edilebilmekte ve yeni verilere uyum sağlayabilmektedirler.

3.3. Makine Öğrenmesi Türleri

Makine öğrenmesi algoritmaları problem çözümü açısından dört ana gruba incelenmektedir. Şekil 3.5.'de gösterildiği gibi denetimli öğrenme, denetimsiz öğrenme, pekiştirmeli öğrenme olarak alt gruba ayrılmaktadır (Rashidi ve ark., 2019).



Şekil 3.5. Makine öğrenmesi alt grupları ve çıktı türleri

3.3.1. Denetimli öğrenme


Denetimli öğrenme türünde veri seti içersinde yer alan kayıtlar aynı zamanda kayıttaki sınıfı da içermektedir, en çok kullanılan türüdür. Birçok derin öğrenme uygulaması bu kategori içerisinde yer almaktadır. Örnek uygulama olarak gereksiz e-postaların eğitim veri setinde yer alan örnek sınıflandırma etiketleri ile yeni gelen e-postanın etiketinin tespiti sınıflandırma örneği denetimli öğrenme kategorisinde değerlendirilmektedir.

Denetimli öğrenim içerisinde çoğunlukla sınıflandırma yöntemleri yer alsa da farklı yöntemler de bu kategori içerisinde değerlendirilmektedir. Doğal dil işleme problemlerinde bir cümlede arka arkaya gelen kelimelerin tahmini ve dizi oluşturma problemleri, grup özniteliklerden hedef değerin tahminlediği lojistik regresyon problemleri, görüntü işlemede nesne tespiti denetimli öğrenmenin bir konusu olarak yer almaktadır (Jiang ve ark., 2020).

3.3.2. Denetimsiz öğrenme

Denetimsiz öğrenme türünde etiketli veriler mevcut değildir, denetimsiz öğrenmenin klasik bir örneği kümelemedir. Üç tür çiçeğin çanak yaprağı ve taç yaprağı boyutlarının ölçüldüğü örneği ele alındığında her bir ölçüm grubu için çiçeklerin tam adlarına sahip olunmadığı durum ele alındığında üç ölçüm kümesini otomatik olarak belirlemek için denetimsiz öğrenme teknikleri kullanılabilir. Ancak etiketler bilinmediği için her kümeye çiçek-tipi-1, çiçek-tipi-2 ve çiçek-tipi-3 olarak adlandırabilmektedir. Yeni bir ölçüm seti verilirse, en yakın oldukları kümeyi bulabilir ve bunlardan birine sınıflandırabilmektedir (Salin ve Winston, 1992).

Bu kategorinin amacı eğitim verisinin görselleştirilmesi, etiketsiz veri sınıflarında öznitelikler arası korelasyonların keşfinde, Şekil 3.6.'da da gösterdiği gibi üç boyutlu bir dizinin PCA (Principal Component Analysis) algoritması ile boyut azaltma yöntemiyle iki boyutta kümele ve çok fazla bilgi kaybı yaşamadan sadeleştirme problemlerinde sıklıkla tercih edilmektedir ("Principal Component Analysis Explained Visually", 2022).



Şekil 3.6. Denetimsiz öğrenmede PCA algoritması ile boyut azaltımı

Farklı bir kullanım alanı olarak anomali tespittir, eğitim setinde belli bir kümeye dahil bir veri ile oluşturulan modele göre farklı nitelikte bir veri gelmesi, yeniliklerin tespiti olarak nitelendirilip anomali belirleme sistemlerinde sıklıkla yararlanılmaktadır. Ek diğer farklı bir alan olarak ilişki bağlamalarının saptanmasıdır, büyük veride ilginç ilişkilerin saptanmasında yararlanılmaktadır (Aurélien Géron, 2022).

3.3.3. Yarı denetimli öğrenme

Denetimli öğrenmenin özel türü olarak yarı denetimli öğrenmede etiketli veri olması zorunlu değildir ve veri etiketleme maliyetli ve uzun sürebilecek bir süreç gerektirebilir. Veri kümesinde etiketlenmemiş verilerin yoğunluğunun çok olduğu durumlarda tercih edilir ve otokodlayıcılar bu yöntem için bir örnek sayılabilir (Chollet, 2020).

3.3.4. Pekiştirmeli öğrenme

Pekiştirmeli öğrenme, denetimli ve denetimsiz yöntemlerden ayrı olarak ele alınan özel bir öğrenme yöntemi türüdür, çevreden gelen geri bildirimi içerir, bu nedenle tam olarak denetimsiz değildir, ancak eğitim için uygun bir dizi etiketli örneğe de sahip değildir ve bu nedenle denetimli olarak değerlendirilemez. Pekiştirmeli öğrenme yöntemlerinde sistem, istenen davranışı üretme arayışında çevre ile sürekli etkileşim


halindedir ve çevreden geri bildirim almaktadır. Oyun kuramı, yöneylem araştırması, benzetim tabanlı iyileme gibi alanlarda tercih edilmektedir (Salin ve Winston, 1992).

3.4. Yapay sinir ağları ve derin öğrenme

Derin öğrenme makine öğrenmesinin bir alt alanıdır, veriler birbirini takip eden katmanlardan işlenerek beklenen gösterimi elde etme yöntemi olarak adlandırılabilir. Birden çok katmanın bulunması derinlik ifadesini kullanmakta asıl sebep olarak gösterilmektedir. Geleneksel makine öğreniminde katman sayısı bir, iki veya daha az katmanlardan oluşmakta ve daha sığ veriden bilgi edinimi gerçekleşmektedir, derin öğrenmede katmanlı öğrenim modeli olarak yüzlerce katman kullanımı mümkün olabilmektedir (Chollet, 2020). Sinir ağı olarak adlandırılan ve birbiriyle ilişkili katmanlar ile kurulan model ile öğrenme gerçekleştirilir, her bir katmanda veri işlenerek geçerek daha da saflaştırılarak elde edilir.

Her bir katmanda uygulanan girdi işlemi o katmanda yer alan sinir hücrelerinin ağırlıklarında yapılan değişikliği ifade etmektedir. Teknik olarak katmanın parametresi ağırlık olarak ifade edilir. Derin öğrenmede katmanlarda yer alan bu parametreler verinin ve katmanların yoğunluğu da gözönüne alınırsa milyonları bulabilmekte ve her bir parametrede yapılan değişiklik diğer katmanları ve parametreleri de etkilemektedir.

Kurulan derin öğrenme modeli için gözlemlenmeli, modelin çıktısı ile beklenen çıktı gözlemlenmelidir. Modelin gözlemlenmesi kayıp fonksiyonu (lost function) ile yapılır. Kayıp fonksiyonu modelin her bir iterasyonu için modelden gelen çıktı ve beklenen çıktı arasındaki fark puanlar, Şekil 3.7.'de akış şemasında gösterildiği gibi kayıp fonksiyonu sonraki iterasyonda bir geri bildirim sinyali olarak kullanılır. Kayıp fonksiyonunu aza indirgeyecek şekilde giriş fonksiyonundaki ağırlıklar tekrar güncellenir. Bu akışın geriye yayılım (back propagation) olarak adlandırılır (Chollet, 2020).




Şekil 3.7. Derin öğrenme modelinde kayıp değeri ve ağırlık güncellemesi

Bir sinir ağı başlangıç konumunda henüz bir kayıp fonksiyonu olmadığı için rastgele başlangıç ağırlık değerleriyle başlatılır. Bu durumda modelin çıktısı beklenenden çok farklı bir sonuç olacağı için kayıp skoru yüksek olacaktır, sonraki iterasyonlarda en güncel ağırlıklarla gerçek değerlere yakın sonuçlar elde edilmesi beklenmektedir. Optimal değerlere ulaşıldığında döngü sonlandırılır, öğrenme döngüsü olarak isimlendirilen bu akış sonrasında en düşük kayıp fonksiyonu elde edilir.

3.5. Yapay Sinir Ağı Yapısı

Sinir ağının temel yapısı yapay nöronlar oluşturur, her bir bilgi işlenerek çıktıya dönüştürülür. Bir yapay sinir ağı modeli birbirleriyle bağlantılı şekilde oluşan nöronlardan oluşur, bir katmanın çıktısı bağlantılı katmanın giriş verisini oluşturur. Şekil 3.8.'de gösterildiği gibi katmanlı bir sinir ağı modeli ve yapısını giriş verisi, ağırlıklar, gizli katman ve çıkış elemanından oluşur.




Şekil 3.8. Yapay sinir ağı yapısı ve bileşenleri

Giriş katmanında veri setinden gelen her bir veri, bir ağırlığa sahip ağırlıklarla çarpılır. Başlangıç ağırlıkları rastgele verilir ve kayıp fonksiyonundan gelen skora göre güncellenerek optimal ağırlıklara ulaşır. Optimal ağırlıklar bulunduğu durumda eğitilmiş bir sinir ağında en önemli olan girdiler için en yüksek ağırlıklar atanmış olur, ağırlığı en az veya sıfır olarak atanan girdinin etkisinin olmadığı veya önemsiz olarak nitelendirilir. Veri setinden gelen bir x girdisi bir nörondan geçtikten sonra girdinin w_1 ağırlığıyla çarpımıyla ifade edilir. Giriş katmanı, gizli katman ve çıkış katmanlarından oluşan katmanlı sinir ağı sonucu bir sonuç çıktısı elde edilir (Özkan, 2020).

3.5.1. Sapma (bias)

Sapma (Bias), bir düğümün çıktısını hesaplarken, girdilerin ağırlıklarla çarpıldığı ve sonuca bir sapma değeri eklendiği anlamına gelir, Şekil 3.9.'da gösterildiği gibi verilere daha iyi uyması için etkinleştirme işlevinin sola veya sağa kaydırılmasına izin verir. Bu sebeple ağırlıklardaki değişiklikler sigmoid eğrinin dikliğini değiştirirken, sapma onu dengeler ve tüm eğriyi daha iyi uyacak şekilde kaydırır. (Denklem 3.1)'de yer aldığı gibi bias yalnızca çıktı değerlerini etkiler gerçek girdi verileriyle etkileşime girmezler.




Şekil 3.9. Sapma (Bias) bileşeni

$$\text{Toplam } F(z) = \sum_i^n w_i x_i + b \quad (3.1)$$

Sapma değeri bir düğümü harekete geçirmenin en kolay yolu olarak varsayılabilir. Büyük bir sapmaya sahip bir düğüm için, çıktı, küçük pozitif ağırlıklar ve büyük pozitif çıktılar (1'e yakın) üreten girdilerle, özünde yüksek olma eğiliminde olacaktır. Sapmalar negatif olabilir, bu da 0'a yakın sigmoid çıktılara yol açar, eğer sapma çok küçükse (veya 0), çıktıya yalnızca ağırlıkların ve girdilerin değerleri ile karar verilecektir. Şekil 3.9.'da bir sigmoid fonksiyonuna farklı bias değerleri eklendiğinde değişen grafik görüntüsünü elde edilmekte, eklenen değer ağırlıklardan bağımsız olarak yalnızca sağa veya sola ilertebildiği görülmektedir. Bias kullanımı sinir ağının verimli çalışmasını ve sorunları çözme kapasitesini artırır.

3.5.2. Aktivasyon (etkinleştirme) fonksiyonu

Bir yapay sinir ağı düğümünde yer alan giriş sinyallerini çıkış sinyali olarak çevrilir, bu noktada doğrusal olarak gelen fonksiyon doğrusal olmayan bir fonksiyona çevrilerek modelin öğrenme verimi artırılır. Şekil 3.10.'da da belirtildiği gibi doğrusal gelen fonksiyona eklenen bias değeri çıkış değeri elde edilmeden aktivasyon fonksiyonuna iletilir (Ding ve ark., 2018).



Şekil 3.10. Aktivasyon (Etkinleştirme) fonksiyonu

Aktivasyon fonksiyonu işlev olarak, ileri yayılma sırasında her katmanda ek bir adım sunar. Aktivasyon fonksiyonları olmadan çalışan bir sinir ağı olduğunu varsayıldığında, her nöron, ağırlıkları ve sapma değerlerini kullanarak girdiler üzerinde yalnızca doğrusal bir dönüşüm gerçekleştirecektir. Çünkü sinir ağına kaç tane gizli katman eklendiği önemli değildir; tüm katmanlar aynı şekilde davranacaktır, iki doğrusal fonksiyonun bileşimi doğrusal bir fonksiyon olacaktır. Sinir ağı daha basit hale gelse de herhangi bir karmaşık görevi öğrenmek imkansızdır ve bu nedenle model sadece doğrusal bir regresyon modeli haline gelecektir. Aktivasyon fonksiyonları non-lineer bir fonksiyon elde edilir. Bu fonksiyon gizli katmanlarda bulunan her eleman için hesaplanır ve uygulanır. Katmanda bulunan her bir eleman ağırlıkları çarpımının toplamına bias eklenmiş haline 'u' ile ifade edilirse aktivasyon fonksiyonu 'F(u)' ile çıktı olarak iletilir. Ortaya çıkan değerleri 0 ile 1 veya -1 ile 1 vb. arasında (fonksiyona bağlı olarak) eşler. En sık tercih edilen aktivasyon fonksiyonları, Relu, Sigmoid, Softmax, Tanh olarak yer alır.

3.5.2.1. Sigmoid / Lojistik aktivasyon fonksiyonu


Bu fonksiyon ile herhangi bir gerçek değeri girdi olarak alır ve 0 ile 1 aralığındaki değerlerde çıktı üretir, Denklem 3.2.'de yer alan fonksiyona gönderilen veriye göre giriş ne kadar büyükse (daha pozitif), çıkış değeri 1.0'a o kadar yakın olur, ancak giriş ne kadar küçükse (daha negatif), Tablo 3.1.'de gösterildiği gibi çıkış 0.0'a o kadar yakın olur.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.2)$$

Tablo 3.1. Sigmoid / Lojistik aktivasyon fonksiyonu

```
from math import exp
from matplotlib import pyplot

# sigmoid aktivasyon fonksiyonu
def sigmoid(x):
    return 1.0 / (1.0 + exp(-x))
# giriş datalarının oluşturulması
inputs = [x for x in range(-10, 10)]
# çıkış verisinin hesaplanması
outputs = [sigmoid(x) for x in inputs]
# giriş ve çıkış datalarının gösterimi
pyplot.plot(inputs, outputs)
pyplot.show()
```




Sigmoid/lojistik aktivasyon fonksiyonunun en yaygın kullanılan fonksiyonlardan biri olmasının nedeni çıktı olarak olasılığı tahmin etmede gereken modeller için yaygın olarak kullanılmasıdır. Herhangi bir şeyin olasılığı yalnızca 0 ile 1 aralığında olduğundan, aralığı nedeniyle sigmoid doğru seçimdir. Fonksiyon türevlenebilirdir ve düzgün bir gradyan sağlar, yani çıktı değerlerinde sıçramaları önler. Bu, sigmoid aktivasyon fonksiyonunun bir S şekli ile temsil edilir.

Sigmoid işlevi, etki alanı tüm gerçekte sayıların kümesi olduğundan ve aralığı (0, 1) olduğundan, ezme işlevi olarak da adlandırılır. Bu nedenle, işlevin girişi ya çok büyük bir negatif sayı ya da çok büyük bir pozitif sayıysa, çıktı her zaman 0 ile 1 arasındadır bu durum ‘-∞’ ile ‘+∞’ arasındaki herhangi bir sayı için de geçerlidir (“A Gentle Introduction To Sigmoid Function”, 2022).

3.5.2.2. Rectified linear (Relu) aktivasyon fonksiyonu

ReLU en çok kullanılan aktivasyon fonksiyonlarından biridir, neredeyse tüm evrişimli sinir ağlarında veya derin öğrenme metodlarında kullanılabilir. Rectified linear aktivasyon fonksiyonu veya kısaca ReLU, pozitif ise girişi doğrudan çıkaracak, aksi takdirde sıfır verecek olan parçalı lineer bir fonksiyondur ve Denklem 3.3 ve 3.4’te gösterilmiştir. Birçok sinir ağı türü için varsayılan etkinleştirme işlevi haline gelmiştir,

çünkü relu kullanılan bir modelin eğitilmesi daha kolay olmakta ve genellikle daha iyi performans elde edilmektedir.



Şekil 3.11. Sigmoid ve Relu aktivasyon fonksiyonları

$$g(x) = \begin{cases} x & x > 0 \\ 0 & x < 0 \end{cases} \quad (3.3)$$

$$g'(x) = \begin{cases} 1 & x > 0 \\ 0 & x < 0 \end{cases} \quad (3.4)$$

Sıfırdan büyük değerler için doğrusaldır, yani bir sinir ağını geri yayılım kullanarak eğitirken bir doğrusal etkinleştirme işlevinin istenen özelliklerinin çoğuna sahiptir. Şekil 3.11.'de gösterildiği gibi negatif değerler her zaman sıfır olarak çıktığı için doğrusal olmayan bir fonksiyondur. Derin sinir ağlarını eğitmek için hataların geri yayılımı ile stokastik gradyan inişini kullanmak için, lineer bir fonksiyon gibi görünen ve hareket eden bir aktivasyon fonksiyonuna ihtiyaç vardır, ancak aslında verilerdeki karmaşık ilişkilerin öğrenilmesine izin veren lineer olmayan bir fonksiyondur ("Activation Functions in Neural Networks", 2022).

3.5.2.3. Tanh aktivasyon fonksiyonu

Hiperbolik tanjant aktivasyon fonksiyonu aynı zamanda basitçe Tanh (ayrıca "tanh" ve "TanH") fonksiyonu olarak da adlandırılır. Tanh da lojistik sigmoid gibidir ama daha iyi performansta çalışmaktadır. Tanh fonksiyonunun aralığı (-1 ile 1) arasındadır, tanh da sigmoidaldır (S şeklinde). Denklem 3.5. ve 3.6.'te yer aldığı gibi işlev olarak herhangi bir gerçek değeri girdi olarak alır ve -1 ile 1 aralığındaki değerleri çıkarır.


Girdi ne kadar büyükse (daha pozitif), çıktı değeri 1.0'a o kadar yakın olur, girdi ne kadar küçükse (daha negatif), çıktı -1'e yakın olacaktır, Tablo 3.2.

Tablo 3.2. Tanh grafik ve python örnek kullanımı

```
from math import exp
from matplotlib import pyplot
```

```
# tanh aktivasyon fonksiyonu
def tanh(x):
    return (exp(x) - exp(-x)) / (exp(x) + exp(-x))
```

```
# giriş datalarının tanımlanması
inputs = [x for x in range(-10, 10)]
# fonksiyondan gelen sonuçların
hesaplanması
outputs = [tanh(x) for x in inputs]
# giriş ve çıkış değerler grafiği
pyplot.plot(inputs, outputs)
pyplot.show()
```



$$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (3.5)$$

$$f'(x) = 1 - f(x)^2 \quad (3.6)$$

Tanh işlevi, bir sinir ağının katmanları arasında doğrusal olmayan bir etkinleştirme işlevi olarak kullanılabilecek başka bir olası işlevdir. Sigmoid aktivasyon işleviyle birkaç ortak noktayı paylaşır, 0 ile 1 arasındaki girdi değerlerini eşleyecek bir sigmoid fonksiyonunun aksine, Tanh -1 ile 1 arasındaki değerleri eşler. Tanh esas olarak iki sınıf arasında sınıflandırma modellerinde kullanılır (“How to Choose an Activation Function for Deep Learning”, 2022).

3.5.2.4. Softmax aktivasyon fonksiyonu

Softmax fonksiyonu, olayın olasılık dağılımını 'n' farklı olay üzerinden hesaplar. Genel olarak, bu fonksiyon her hedef sınıfın olası tüm hedef sınıflar üzerindeki olasılıklarını hesaplamaktadır, daha sonra hesaplanan olasılıklar verilen girdiler için hedef sınıfın belirlenmesinde yardımcı olacaktır. Softmax aktivasyon fonksiyonu, çoklu boyutlar için sigmoid fonksiyonunun genelleştirilmiş şeklidir ve (Denklem 3.7)'deki gibi ifade

edilir (“Softmax Function Definition”, 2022). Sayı vektörünü olasılık vektörüne çeviren matematiksel fonksiyondur, makine öğreniminde çok sınıflı sınıflandırma problemlerinde genellikle bir etkinleştirme işlevi olarak kullanılır. Softmax'ın çıktısı, her bir sınıfın elde edilme olasılığı olarak yorumlanır. Python programlama dilinde softmax implementesi Tablo 3.3.'te belirtilmiştir.

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.7)$$

$\vec{z}$: (z0, ... zK)'den oluşan softmax fonksiyonu giriş vektörü

z_i : Tüm z_i değerleri, softmax işlevine giriş vektörünün öğeleridir ve pozitif, sıfır veya negatif herhangi bir gerçekteki değeri alabilirler, örnek olarak bir sinir ağı, geçerli bir olasılık dağılımı olmayan (-0.61, 7.13, 3.54) gibi bir vektör çıktısına sahip olabilir, bu nedenle softmax gerekli olmaktadır.

e^{z_j} : Giriş vektörünün her elemanına standart üstel fonksiyon uygulanır, girdi negatifse çok küçük ve girdi büyükse çok büyük olacak olan sıfırın üzerinde pozitif bir değer verir. Ancak yine de bir olasılık için gerekli olan (0, 1) aralığında sabit değildir.


K : Sınıf sayısı

Tablo 3.3. Softmax fonksiyonu implemente edilmesi

```
import numpy as np
def softmax(x):
    """ applies softmax to an input x"""
    e_x = np.exp(x)
    return e_x / e_x.sum()
x = np.array([1, 0, 3, 5])
y = softmax(x)
y, x / x.sum()
```

Fonksiyonda yer alan Z , çıktı katmanının nöronlarından gelen değerleri temsil eder ve üstel, doğrusal olmayan işlev olarak işlev görür. Sonraki adımda bu değerler, normalleştirmek ve daha sonra olasılıklara dönüştürmek için üstel değerlerin

toplamına bölünür. Şekil 3.12.'de yer aldığı gibi sınıflandırma öncesi son adımda çoğunlukla tercih edilir.



Şekil 3.12. Softmax aktivasyon fonksiyon implementasyon örneği

$$P(S1) = \exp(2.33) / (\exp(2.33) + \exp(-1.46) + \exp(0.56)) = 20.838 \quad (3.8)$$

$$P(S2) = \exp(-1.46) / (\exp(2.33) + \exp(-1.46) + \exp(0.56)) = 70.018 \quad (3.9)$$


$$P(S3) = \exp(0.56) / (\exp(2.33) + \exp(-1.46) + \exp(0.56)) = 70.142 \quad (3.10)$$

Her bir hesaplanmış softmax fonksiyonu sonucu ilgili sınıflara ait bir veri noktasının olasılık değerleridir ve toplamı da 1'e eşittir. Hesaplanmış olasılık değerleri dikkate alındığında girdinin sınıfının 1 olduğu görülmektedir, herhangi birin olasılığı değiştirildiğinde sınıfın da olasılık değeri değişecektir. Softmax fonksiyonu çok sınıflı sınıflandırmaların çıktı katmanı için kullanılabilir ve her sınıf için 0 ile 1 arasında değer verir .

3.5.2.5. Exponential linear unit (ELU) aktivasyon fonksiyonu

Üstel doğrusal olan ve ELU olarak isimlendirilen aktivasyon fonksiyonu maliyeti daha hızlı sifıra yakınsama ve daha doğru sonuçlar üretme eğiliminde olan bir fonksiyondur, diğer fonksiyonlardan farkı (Denklem 3.11)'de belirtilen alfa sabiti vardır. Bu alfa sabitinin pozitif olması gerekir.

ELU aktivasyon fonksiyonu Relu fonksiyonuna benzer işlevsellikte çalışır, her ikisi de negatif olmayan girdiler için belirleyici biçimindedir. ELU fonksiyonu çıktı olarak $-\alpha$ 'ya eşit olana kadar grafiksel yavaş yavaş düzgün hale gelirken Relu keskin bir şekilde düzleşir, Şekil 3.13.



Şekil 3.13. Elu aktivasyon fonksiyon ve türev grafiği

$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases} \quad (3.11)$$


Hesaplamaya dahil edilen alfa işlemi nedeniyle hesaplama süresi uzaması dezavantaj olarak nitelendirilebilir. Relu fonksiyonuna benzer nitelikte çalıştığından tercih sebebi olabilmektedir. ELU fonksiyonu grafikte yer aldığı üzere alfanın eksi değerlerinde yavaş düzeltme yaparken Relu fonksiyonunda bu durumda keskin bir şekilde uygulanmaktadır (“Activation Functions”, 2022).

3.5.3. Aktivasyon fonksiyonu seçim kriterleri

Aktivasyon fonksiyonları, kurulan sinir ağında optimum başarı ve performans elde etmek için seçilmesi gereken birçok parametreden biridir böylece oluşturulan modelin özelliklerine göre kurulan yapay sinir ağı daha hızlı ve kolay eğitilebilir. Kurulan modelin farklı katmanlarında farklı aktivasyon fonksiyonları kullanılabilir, gizli katmanlarda kullanılan aktivasyonlarının seçimi girdi olarak verilen veri setini daha iyi öğrenmesini etkileyecektir, çıktı katmanında kullanılan aktivasyon fonksiyonu ise çıktı için kullanılan tipte belirleyici bir kriter noktası olacaktır.

Yapay sinir ağında kurulan modellerde birden fazla gizli katman içerebilmektedir ve gizli katmanlarda türevi alınabilen, doğrusal olmayan aktivasyon fonksiyonları çoğunlukla tercih edilir böylece daha kompleks kalıpları öğrenmesine olanak sağlar.

Çözüm bulunmaya çalışılan problem türüne göre aktivasyon seçim kriterleri de farklılaşmaktadır, genellikle bu kriterler iki ana grupta incelenir. Kategorik tahminleme (sınıflandırma) veya sayısal değişken için tahminleme (regresyon) olarak incelenir Şekil 3.14.'de gösterildiği gibi ("How to Choose an Activation Function for Deep Learning", 2022).



Şekil 3.14. Aktivasyon seçiminde problem tipi kriterleri

Genellikle sadece gizli katmanlarda Relu aktivasyon aktivasyon fonksiyonu tercih edilir, eğer verimli sonuçlar alınmadığı durumda diğer aktivasyon fonksiyonları ile devam edilebilir. Sigmoid ve Tanh fonksiyonları eğitim sırasında (kaybolan gradyanlar nedeniyle) sorunlara daha duyarlı hale getirdiklerinden gizli katmanlarda tercih edilmezler ("How to choose best Activation Function for you model", 2022).

3.6. Yapay Sinir Ağı Öğrenmesi

Sinir ağları yeterince büyük bir katman ve istenen hata payı verilen herhangi bir işlevi yaklaşık olarak öğrenebilir ve temsil edebilir. Sinir ağının gerçek işlevi öğrenmesinin yolu, basit temsillerin üzerine karmaşık temsiller oluşturmaktır. Her gizli katmanda, sinir ağı, önce verilen girdilerin doğrusal dönüşümlerini hesaplayarak ve ardından bir sonraki katmanın girdisi olacak olan doğrusal olmayan işlevi uygulayarak yeni özellik

uzayını öğrenir. Bu işlem çıktı katmanına ulaşana kadar devam eder. Bu nedenle, sinir ağını, girdilerden gizli katmanlar aracılığıyla çıktıya doğru bilgi akışı olarak tanımlayabiliriz. Örnek olarak bilgisayarlar görüntüleri doğrudan anlayamaz ve piksel verileri ilk durumda bir anlam ifade etmemektedir. Bununla birlikte bir sinir ağı, kenarları tanımlayan gizli katmanlarda görüntünün basit bir temsili oluşturabilir. İlk gizli katman çıktısı verildiğinde, köşeleri ve konturları öğrenebilir. İkinci gizli katman göz önüne alındığında, daha derine bilgiler öğrenebilir. Son olarak, tespit edilmesi gereken görüntüdeki nesne kimliğini öğrenebilir. Sinir ağı çok karmaşık modeller oluşturmada yardımcı olabilmekte ve uygulayıcılar için çok uzun zaman alan özellik mühendisliği hakkında temsilleri öğrenmeyi algoritmaya devredilebilmektedir.

Yapay sinir ağlarında öğrenme iki grupta incelenebilir, ileri yayılma ve geri yayılma olarak öğrenme döngüsü ile gerçekleşmektedir. İleri yayılmada amaç o ağı çıktısının hesaplanabilmesidir, geri yayılımda ise düğümlerdeki ağırlıklar güncellenmesidir. İleri yayılım sinir ağındaki girdi katmanından çıktı katmanına geçmenin yoludur. Çıktı katmanından girdi katmanına, geriye doğru hareket etme işlemine geri yayılım olarak adlandırılır (“Coding Neural Network”, 2022).

TensorFlow kütüphanesi ile geriye yayılım algoritması elle hesaplanamayacak büyüklükte işlem yükleri kısa sürede hesaplanabilir hale gelmiştir, sinir ağları katmanlarının oluşturulması ve bağlanması (ağırlıklar ve aktivasyon fonksiyonlarının hazırlanması), tahmin hatası değerlendirme ve bir kayıp fonksiyonu oluşturulması işlemlerinin otomatize edilmesinde işlem kolaylığı sunmaktadır.


3.6.1. İleri yayılım

Probleme bağlı olarak kurulan modele göre gizli katmanda yer alan hücreler için giriş katmanından gelen ağırlık ve giriş değerlerine göre çıkış değeri hesaplanır, gizli katman çıkış değerlerine göre çıkış katmanı girdi değeri elde edilmiş olur. Gizli katmandan elde edilen çıkış değerlerine göre y1 çıkış değeri hesaplanır. Şekil 3.15.'de yer alan g1 hücresi için toplam fonksiyonu Denklem 3.12.'de verildiği gibi hesaplanmaktadır ve g1 hücresi çıkış değeri Denklem 3.13'te yer alan örnek

etkinleştirme fonksiyonu olan Softmax kullanılarak $g1$ düğümü çıktı değeri elde edilmiş olur.

$$z_{g1} = w_1 x_1 + w_2 x_2 + b1 \quad (3.12)$$

$$z_{g1} = \frac{1}{1 + e^{-z_{g1}}} \quad (3.13)$$




Şekil 3.15. Giriş katmanı ile $g1$ gizli katman düğüm arasındaki ilişki

Gizli katmanda yer alan $g1$ sinir hücresi gibi diğer sinir hücreleri içinde (Denklem 3.12)'de yer aldığı gibi toplam fonksiyonu ve çıktı değerini elde etmek için (Denklem 3.13)'te yer alan aktifleştirme fonksiyonu ile diğer gizli katman düğümleri için uygulanıp $y1$ çıktı katmanında hesaplanmış değerler toplamı iletilir. Çıkış katmanı olan $y1$ için giriş değeri verileri Şekil 3.16.'da gösterildiği gibi gizli katmandan gelen güncel çıkış değerleri ile (Denklem 3.14)'te gösterilen toplam fonksiyonu ile elde edilir.

$$top_{y1} = w_3 z_{g1} + w_4 z_{g2} + w_5 z_{g3} \quad (3.14)$$

$$z_{y1} = \frac{1}{1 + e^{-top_{y1}}} \quad (3.15)$$

Çıkış katmanı çıkış değeri olan z değeri Denklem 3.15'te yer alan sigmoid etkinleştirme fonksiyonu ile Şekil 3.16.'da yer alan toplam ağırlıklar kullanılarak elde edilir.



Şekil 3.16. Gizli katmandan gelen bilgiye göre y1 çıkış değeri

İleri yayılımın son aşamasında çıkış katmanı olan y1 sonucu elde edilen hesaplanmış tahmin değeri ile kayıp değeri (Lost Function) veya maliyet değeri elde edilebilmektedir. Bu değeri ölçümlemenin farklı methodları mevcuttur ve en sık kullanılan yöntem olan karesel hata fonksiyonu (Denklem 3.16)'e göre hesaplanır. Birden fazla y değeri için E değerlerinin ortalaması alınarak sonuç kayıp değeri elde edilir (Denklem 3.17)'de belirtildiği gibi.

$$E_{y1} = (y1 - z_{y1})^2 \quad (3.16)$$

$$E_{toplama} = \frac{\sum_1^n E_n}{n} \quad (3.17)$$

İleri yayılım kayıp fonksiyonu elde edilerek tamamlanır, elde edilen kayıp fonksiyonu ile ağırlık değerleri iyileştirilebilmek amacıyla kullanılır.

3.6.1.1. İleri yayılımda maliyet (lost) ölçümü

Kurulan yapay sinir ağında amaç fonksiyonu tahmin edilen sınıf veya değere en yakın tahmini yapmaktır, bu da ağın maliyet veya kayıp değerine bağlı olarak hesaplanabilmektedir. Ağın tahminlemeyi doğru yapma oranı maliyet fonksiyonuna göre oluşturulmaktadır. Her bir ileri yayılım döngüsünde tahminlenen değer ile gerçek

değer karşılaştırılarak oluşan kayıp değeri ile cezalandırma işlemi gerçekleştirilir ve ağırlık doğruluk oranı artırılması hedeflenir. Hata oranının en düşük olduğu nokta optimum değeri ifade böylece gerçeğe en yakın çıktılar oluşturulur.

Derin öğrenme algoritmaları için kayıp fonksiyonu tek boyutlu, seçilen derin öğrenme algoritmasının türü, türevleri hesaplama kolaylığı ve bir noktaya kadar kullanılan veri setindeki aykırı değerlerin yüzdesi gibi belirli bir problem için bir kayıp fonksiyonunun seçilmesiyle ilgili çeşitli faktörler vardır.

Genel olarak kayıp fonksiyonu, ele alınan öğrenme görevinin türüne bağlı olarak iki ana kategoride sınıflandırılabilir: regresyon kayıpları ve sınıflandırma kayıpları. Sınıflandırmada, sonlu kategorik değerler kümesinden çıktıyı tahmin etmeye çalışılır, diğer yandan regresyon sürekli bir değeri tahmin etmekle ilgilenir. Kayıp fonksiyonu hesaplamada yoğunlukla kullanılan maliyet ölçüm türleri Tablo 3.4.'teki gibidir (Yaseen ve ark., 2018).


Tablo 3.4. Kayıp fonksiyonu maliyet ölçüm türleri

Maliyet Fonksiyonu	Formül
Ortalama Hata (ME)	$ME = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)$
Ortalama Mutlak Hata (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
Ortalama Kare Hata (MSE)	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
Kök Ortalama Kare Hata (RMSE)	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$
Ortalama Mutlak Yüzde Hata (MAPE)	$MAPE = \frac{100}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right $

3.6.2. Geri yayılım (Back propagation)

Kurulan yapay sinir ağı modelinde ileri yayılımın ilk iterasyonunda ağırlıklar rastgele atanmakta ve buna bağlı olarak sapma değeri ile çıktı katmanında bir kayıp fonksiyonu elde edilir. Elde edilen maliyet değeri ağırlık yeni ağırlık değerleriyle güncellenebilmesi

için gereklidir. Her bir iterasyonda minimum maliyet değeri elde edebilmek amacıyla ağıdaki ağırlık değerleri optimum seviyeye getirilir. Hatanın minimum seviyeye getirilme sürecinde maliyet fonksiyonunun eğimi esas alınarak ağırlıklarının güncellenmesi amacıyla geriye doğru güncelleme işlemine geriye yayılım olarak adlandırılır Şekil 3.17.'de yer aldığı gibi. Bu süreç çıktı katmanından başlayarak gizli katmanlara ve son aşamada giriş katmanında sonlanır.



Şekil 3.17. Geri yayılım ile ağırlığın güncellenmesi

Gizli katman düğümlerinden biri olan $g1$ 'in çıkış katmanına bağlı olan $w3$ ağırlık değeri güncellenmek istendiğinden gradyeninin hesaplanmasıyla güncelleme yapılır. Gradyen bir vektör olarak o fonksiyonda yer alan tüm değişkenlerin türevlerini oluşturmaktadır.

$$f(x) = \left(\frac{\partial f}{\partial w_1}, \dots, \frac{\partial f}{\partial w_n} \right) \quad (3.18)$$

(Denklem 3.18)'de yer aldığı gibi bir $f(x)$ fonksiyonu için tüm ağırlık gradyenleri elde edilir.

Şekil 3.17.'de yer alan çıkış katmanında gizli katmana doğru yayılımda $w3$ gradyen değeri $\frac{\partial E_{\text{toplam}}}{\partial w_3}$ olarak elde edilir ve elde edilen değer öğrenme katsayısı ile çarpılıp $w3$ değerinden çıkarılır, güncel $w3$ ağırlık değeri elde edilir. $w3$ türevi için zincirleme kuralına göre (Denklem 3.19)'daki gibi her bir giriş ve çıkış değerlerine göre ayrı olarak hesaplanır.

$$\frac{\partial E_{toplama}}{\partial w_3} = \left(\frac{\partial E_{toplama}}{\partial out_{y1}} \right) \left(\frac{\partial out_{y1}}{\partial z_{y1}} \right) \left(\frac{\partial z_{y1}}{\partial w_3} \right) \quad (3.19)$$

Gizli katman olan $g1$ ve $y1$ çıkış değerlerine göre ayrı ayrı türevleri Denklem 3.20, (Denklem 3.21) ve (Denklem 3.22)'de de yer aldığı gibi hesaplanır.

$$\frac{\partial E_{toplama}}{\partial out_{y1}} = -(y1 - out_{y1}) \quad (3.20)$$

$$\frac{\partial out_{y1}}{\partial z_{y1}} = out_{y1}(1 - out_{y1}) \quad (3.21)$$

$$\frac{\partial z_{y1}}{\partial w_3} = out_{g1} \quad (3.22)$$

Her biri için elde edilen sonuçlar (Denklem 3.19)'da yerine yazıldığında (Denklem 3.23)'te delta kuralı sonucu ve sonuç $f(x)$ fonksiyonu Denklem 3.24'deki gibi elde edilmiş olur.

$$\delta_{y1} = -(y1 - out_{y1})out_{y1}(1 - out_{y1}) \quad (3.23)$$

$$\frac{\partial E_{toplama}}{\partial w_3} = \delta_{y1}out_{g1} \quad (3.24)$$

Ağırlık değeri olan w_3 hata oranını azaltılmak üzere güncellenirken eski ağırlık değerinden hesaplanmış değer çıkarılarak yeni ağırlık değeri elde edilmiş olur. Denklem 3.25'te öğrenme katsayısı ile çarpılıp, Denklem 3.26'da farkı ifade edilmiştir.

$$\Delta_{y1} = n\delta_{y1}out_{g1} \quad (3.25)$$


$$w_{3 (yeni)} = w_3 - \Delta_{y1} \quad (3.26)$$

3.7. Gradyan ve Gradyan İnişi

Gradyan bir tensör işleminin türevini ifade etmektedir. Bir girdi vektörü olarak 'x', sınıflandırma değeri 'y' ve maliyet fonksiyonu olarak 'loss' olarak ele alınırsa ağırlık değeri olan 'w' kullanılarak yeni bir 'y' değeri tahmini olan 'pred_y' elde edilir. Maliyet değeri, 'pred_y' ve 'y' arasındaki fark ile hesaplanabilmektedir. Girdi değeri 'x' ve sınıf değeri olan 'y' değeri sabit olduğundan 'w' değerleri maliyet değerlerine eşleyen bir fonksiyon olarak düşünülebilir ve $f(w)$ olarak da ifade edilebilir.

Ağırlık değeri olan w'nin ilk değeri 'w0' olarak ifade edilirse f fonksiyonunun w0'daki türevi $\text{gradyan}(f)(w_0)$ olarak ifade edilir. $\text{Gradyan}(f)(w_0)$ fonksiyonu $f(w) = \text{loss}$ fonksiyonunun w0 noktasındaki gradyanıdır.

Gradyan inişi en iyileme algoritması olarak farklı problemlerde optimum sonuca ulaşmada bir araç olarak kullanılır, amaç fonksiyonu ağırlık ve bias parametrelerini optimumda ayarlanmasını sağlamaktır. Şekil 3.18.'de yer alan w ağırlık fonksiyonu için ilk rastgele atama değerlerinden sonra, maliyet fonksiyonuna göre örnek olarak MSE ele alınırsa bu değer azaltılıp minimuma kadar indirilmesidir (Dogo ve ark., 2018).



Şekil 3.18. Gradyan inişi ve öğrenme oranı

Gradyan inişinde önemli parametrelerden biri de öğrenme oranıdır, bu oran çok küçük kalırsa optimum noktaya yakınsama çok küçük kalacaktır ve Şekil 3.18.'de verilen optimum noktaya iterasyon sayısı ve zamanı artış gösterir, öğrenme oranı

arttırıldığında eğri karşısına geçerek bulunulan noktadan daha uzak bir noktaya sapmasına sebep olacaktır.

Gradyan inişi her durumda beklendiği şekilde düzgün olarak bir iniş gerçekleştirmeyebilir, doğrusal olmayan bir hareketle zikzak hareketiyle ve küçük iterasyonlarla optimum w ve bias değerlerine ulaşılabilir. Bu durum seçilen öğrenme katsayısıyla doğru orantılı olarak değişim gösterebilir. (Denklem 3.27) ve (Denklem 3.28)'de sırasıyla w ve bias değerleri için her bir iterasyonda tekrarlanması gerekmektedir (Ruder, 2016). Formülde yer alan alfa değerleri öğrenme katsayısını ifade etmekte ve optimum noktaya ulaşmada en önemli parametrelerden biridir.

$$w_{\text{yeni}} = w - \alpha \frac{\partial j(w, b)}{\partial (w)} \quad (3.27)$$

$$b_{\text{yeni}} = w - \alpha \frac{\partial j(w, b)}{\partial (b)} \quad (3.28)$$

Türevi alınabilen bir fonksiyonun gradyan iniş ile yerel minimum noktası bulunabilir. Alternatif bir yöntem olarak stokastik gradyan iniş yöntemi de yerel minimumu bulmada farklı bir yöntem olarak tercih edilmektedir. Her bir iteratif inişte tüm veri seti çalıştırılarak maliyet fonksiyonunu azaltabilmek için w ve b için bir güncelleme yapılır ve algoritmanın daha yavaş çalışma riskini doğurur. Stokastik yöntemde tüm veri setinden yararlanmak yerine rastgele veri setinden bir değer seçilerek buna bağlı olarak bir iniş işlemi gerçekleştirilmiş olur ve böylece işlem yükü daha hızlı olabilmektedir. Rastgele seçim ile iterasyon işlemleri sonucu w ve b değerleri güncellendiğinden inişler düzensiz şekilde ilerler ve yerel minimum noktaya yaklaşır. Öğrenme katsayısı benzer şekilde belirlenip inişlerdeki sapmaları arttırma ve azaltmada önemli bir parametre olarak yer almaktadır. Stokastik gradyan iniş yöntemine göre veri setinden rastgele alınan parçalar ile ağırlık bias güncellemesi sonucu iterasyon işlemleri devam eder, böylece en uygun ağırlık değerleri hesaplanır. Bu iteratif adımların her biri “epoch” olarak adlandırılmaktadır. Derin öğrenme modelinde en uygun ağırlıklar belirlendiğinde ilk epoch değerlerinde başarı oranının düşüken sonraki epoch'larda artış yaptığı gözlemlenir (Géron, 2020).


3.8. Bilgisayarlı Görü

Bilgisayarlı görü, dijital sistemlerin ve akıllı makinelerin görsel verilerden veya vidyolardan anlamlı bir şekilde bilgi oluşturabilmesidir, bu bilgiler yardımıyla bilgisayarlar sistematik bir öneri, tespit veya eylemde bulunur ve derin öğrenme yöntemleri ile karar destek sistemleri içerisinde değerlendirildiğinden bir yapay zekâ alanı olarak değerlendirilirler. Bilgisayarların düşünebilme konsepti yapay zekâ ile ortaya atıldığından bilgisayarlı görü ile de bilgisayarların görüntüden analiz yapabilme ve görüntüyü anlama imkânı sunabilmektedir. Bilgisayarlı görü insan görüşüyle benzerlik taşımaktadır, görüntüdeki nesnelerin birbirine göre konumu, uzaklığı veya bir görüntüde aykırı durumları farkedebilmesi insanın yaşam boyu geçmiş bilgi birikimiyle değerlendirilirken makineler eğitilerek bu işleve sahip olurlar. Örneğin bir üretim hattında ürünlerin görsel kontrolleri belli bir zaman diliminde binlercesinin analizi ile zamandan tasarruf sağlayabilmekte veya insan gözüyle tespit edilmesi zor analizleri sunabilmektedir.

Bilgisayarlı görünün bilgisayar tarafından analizinde ve bilgi çıkarımında çok fazla sayıda görüntü verisine ihtiyaç duyar böylece görüntüdeki ayrımları farkedene ve tanıma işlemi gerçekleşene kadar döngüsel olarak tekrar çalıştırır. Örnek olarak bir bilgisayara obje tanıyabilecek bir şekilde eğitebilmek için çok sayıda o objeye ait görüntülerin beslenmesi gerekir, bunu tanımada iki temel araç kullanılır: derin öğrenme ve evrişimsel sinir ağı (Convolutional Neural Networks). Evrişimsel sinir ağı 1980’li yıllardan itibaren görüntü analizinde kullanılmaktadır. Günümüzde kullanılan makine güçlerindeki artışla birlikte algoritma çalıştırmadaki verimin artması, verilerin dijitalleşmesi ve depolama teknolojilerinin gelişmesiyle veriye ulaşımın artması ve derin öğrenme teknolojilerinde ortaya çıkan yeni yöntemler görüntü işlemede meydana çıkan karmaşık problemlerin çözümünde önemli bir araç olarak kullanılmaya başlanmıştır böylece insanların ulaşamayacağı performansta analiz ve hız yeteneği imkânı sunabilmektedirler. CNN algoritmaları sadece görüntü işlemede değil doğan dil işleme veya ses işleme gibi birçok farklı problem türünde bir derin öğrenme yöntemi olarak kullanılmaktadır. Gerçek dünya uygulamaları, bilgisayarla görmenin iş, eğlence, ulaşım, sağlık ve günlük yaşamdaki çabalar için ne

kadar önemli olduğunu göstermektedir. Akıllı telefonlardan, güvenlik sistemlerinden, trafik kameralarından ve diğer görsel aygıtlardan akan görsel bilgi akışı, bu uygulamaların büyümesinin temel itici gücüdür (Géron, 2020).

Aşırı uyum, kurulan ve öğrenilen model, eğitim veri kümesinde son derece iyi performans göstermesi durumunda, ancak test veri kümesinde düşük performans gösterme eğiliminde olduğunda meydana gelmektedir. Model, mevcut olan az miktarda veri için fazla esnek davranmaktadır ve sonunda eğitim verilerini ezberleme eğilimi doğmaktadır. Makine öğreniminde verileri temsil edecek kadar anlamlı, ancak kalıplara fazla uymayacak ve ezberleyecek kadar esnek olmayan bir model tasarlaması asıl amaç olarak ortaya çıkmaktadır, yapay sinir ağları, bu ifade gücünü geliştirmenin bir yolu olarak önerilmiştir, ancak çoğu zaman aşırı öğrenme engeli çoğunlukla aşılamamaktadır. Makine öğrenimi modelinin esnekliğini karşılaştırabilmek için kullanılabilir bir yöntem olarak parametre sayısını saymaktır. Şekil 3.19.'da gösterildiği gibi, 256x256 piksel bir görüntü alanı için ve onu 10 nöronlu bir katmana eşleyen tam bağlı bir sinir ağı, $256 \times 256 \times 10 = 655.360$ parametreye sahip olacaktır. Parametre sayısını azaltmanın yolu olarak evrişimsel katmanlar ile daha fazla parametreyi tek tek öğrenmek zorunda kalacak tam bağlantılı bir ağla uğraşmak yerine, öğrenilen ağırlıkların sayısını azaltmak için aynı parametreyi birden çok kez yeniden kullanarak CNN yaklaşımı bir çözüm olarak kullanabilmektedir. Tam bağlantılı katmanda çok sayıda parametre işlemi yapmak yerine kısmi bağlantılı katmanlar ile iletilen bilgiler kısıtlanarak ve ağırlıklar paylaşılarak daha efektif bir yol izlenir (Mattmann, 2020).




Şekil 3.19. Bir görüntüdeki piksellerin sinir ağına dönüştürülmesi

3.8.1. Evrişimli sinir ağları

Evrişimli sinir sinir ağları (CNN) topolojik olarak ızgara şeklinde matrisel verileri işleme için özel bir tür yapay sinir ağı modelidir. Matrisel gösterim bir boyutlu ifade edilebilen zaman serisi verileri olabileceği gibi 2 boyutta görsel veriler de içerebilmektedir. Evrişimli sinir ağlar ile gerçek pratik uygulamalarda oldukça başarılı olmuşlardır ve “evrişim” adı matematiksel bir işlem serisinden geçtiğini ifade etmekte ve doğrusal bir işlem türüdür. Evrişimli ağların katmanlarında matris çarpımının yerine evrişim işlemi gerçekleştirilen bir sinir ağıdır (Ian Goodfellow, Yoshua Bengio, 2017).

CNN modelinde en temel ve önemli katman “evrişimsel” olarak tanımlanan katmandır. Giriş verisi olarak alınan bir görüntüden ilk evrişimsel katmana görüntüde yer alan tüm piksel karşılıkları yer verilmez yalnızca alıcı alanlar dahil edilir, ikinci evrişimsel katmanda ise ilk evrişimsel katmana bağlı olarak nöronlara bağlıdır. Şekil 3.20.’de de yer alan birden fazla gizli katmanda olan bu yapıda ilk gizli katmanda görüntüye ait en büyük ve en ayırtedici özniteliklere yoğunlaşılırken ilerleyen katmanlarda daha tamamlayıcı ve alt düzeyde özniteliklere yer verilmektedir bu yapısı nedeniyle CNN modelleri görüntü tanımda gerçek dünya problemlerinde başarılı sonuçlar alınabilmektedir.



Şekil 3.20. Evrişim Katmanı (CNN Katmanları)

Konvolüsyonel sinir ağları, görüntü işleme ve tahmine dayalı modelleme veya sınıflandırma görevlerinde meydana gelen çeşitli problemlerin üstesinden gelmek için sıklıkla tercih edilir, CNN'ler için en popüler uygulama alanı görüntü verileri analizidir. (“Guide to Different Padding Methods for CNN Models”, 2022).

3.8.1.1. Evrişim katmanı

Evrişimsel katmanlar bir CNN modelin en temel bölümüdür. Evrişim katmanında giriş verisi olarak bir görüntü verisine bir filtrenin uygulanması ve doğrusallığı bozmak için de bir etkinleştirme fonksiyonu eklenmesiyle sonuçlanır. Aynı filtre bir girişe tekrarlı bir şekilde uygulanmasıyla görüntü verisinde algılanan bir özelliğin konumlarını ve özniteliğini gösteren özellik haritası olarak adlandırılan etkinleştirme haritası çıkarılır. Evrişimli sinir ağlarının güçlü özelliği olarak görüntü sınıflandırma gibi belirli bir tahmine dayalı modelleme probleminin kısıtlamaları altında bir eğitim veri kümesine özgü çok sayıda filtreyi paralel olarak otomatik olarak öğrenme yeteneğidir ve bu katmanda giriş görüntülerinde herhangi bir yerde görüntüye dair algılanabilen oldukça spesifik özellikler çıkarılır.

Evrişimli sinir ağı tek boyutlu veya üç boyutlu verilerle (renkli görseller) kullanılabilmelerine rağmen, iki boyutlu görüntü verileriyle çalışmak için tasarlanmış özel bir sinir ağı modeli türüdür, ağı adını veren evrişimsel katman bulunur. Bu katman “konvolüsyon” adı verilen bir işlem gerçekleştirir. Bir evrişimsel sinir ağı modelinde evrişim, geleneksel bir sinir ağında olduğu gibi, girdi ile ağırlıkların çarpılmasını içeren doğrusal bir işlemdir. İki boyutlu girdi için tasarlandığı göz önüne alındığında, çarpma işlemi bir dizi girdi verisi ile filtre olarak iki boyutlu ağırlık dizisi arasında gerçekleştirilir. Filtre, girdi verisinden daha küçüktür ve girdinin filtre boyutlu bir parçası ile filtre arasında uygulanan çarpma türü matrissel çarpımdır. Bu çarpım, girdinin filtre boyutlu parçası ile filtre arasındaki eleman bazında çarpımdır ve daha sonra toplanır ve her zaman tek bir değerle sonuçlanır (Chollet, 2020).

Aynı filtre bir görüntü üzerinde sistematik uygulanır. Filtre girişteki belirli bir özellik türünü algılamak için tasarlanmışsa, bu filtrenin tüm giriş görüntüsü boyunca sistematik olarak uygulanması, filtrenin görüntünün herhangi bir yerinde bu özelliği keşfetme fırsatı verir. Örnek bir girdi olarak kullanılan görüntüde, görselin sol alt bölgesinde çıkartılan özellik farklı yerlerde de tanınabilmektedir. Böylece az görsel veri olması durumunda da daha hızlı öğrenme imkânı sunabilmektedir.


Çıkarılan özniteklik haritaları katmanlara göre hiyerarşik olarak belirlenmektedir. İlk katmanlarda görselin köçe sınırları gibi genel özellikleri belirlenirken sonraki katmanlarda daha karmaşık örüntüler ortaya çıkartılır.

3.8.1.2. Konvolüsyonel sinir ağlarında filtreler

Matematiksel olarak herhangi bir veri kümesindeki her görüntü piksel değerlerinin bir matrisidir, bir görüntü CNN mimarisi ile çalışırken çıktı boyutu küçültülür ve bu durum veri kaybı olarak kabul edebilir ve problem ihtiyaçlarına göre uygun bir sonuç elde etmek çok zorlaşabilir. Bu durumda, şeklin veya çıktının boyutunun küçülmesi istenmediği durumlarda, verilere daha fazla katman eklemek yardımcı olabilir ve bu ekleme dolgu ile mümkün olabilmektedir (“Guide to Different Padding Methods for CNN Models”, 2022).

Filtreler CNN’de konvolüsyonel katmanda görüntünün kenarlıkları veya şekilleri gibi görüntüdeki özellikleri ortaya çıkarılır, bu özellikler sayesinde model eğitimi yapılabilmektedir. Çıkartılan özellikler bir veri vektörü olarak temsil edilir. Bir görüntüye filtre uygulandığında, dönüştürülmüş görüntüdeki karşılık gelen nokta bir özelliktir; bu filtreyi bu noktaya uygulandığında bu yeni değere sahip olan bir özelliktir. Bir görüntüde ne kadar çok filtre kullanılırsa özellik vektörünün boyutu o kadar büyük olur. Genel amaç, orijinal görüntüdeki önemli özellikleri yakalamaya devam ederken boyutluluğu azaltan filtrelerin sayısını dengelemektir (Geron, 2020).


Gri tonlamalı bir görüntü örnek alındığında a boyutunda ve $f \times f$ filtre boyutuyla ortaya çıkan matris boyutu $(a-f+1) \times (a-f+1)$ olarak sonuç verir. Örnek olarak (8×8) görüntü için (3×3) boyutunda filtreleme uygulandığında sonuç olarak (6×6) matrisel boyutta bir özniteklik matrisi elde edilir. Yeni oluşan katman girdiye kıyasla filtreleme sonucu boyutu azalır ve filtreler matris üzerinde hareketinde köşe değerlerine odaklanması az olacaktır.



Şekil 3.21. Görüntü matrisi üzerinde filtreleme işlemi

Şekil 3.21.'de yer verilen (6x6)'lık bir görüntü matrisi ele alındığında (3x3)'lük bir filtre matrisi görüntü matrisinde bir adım sağa kaydırılarak tüm görüntü taranması sonucu bir öznitelik matrisi ortaya çıkarılıyor olacaktır. Filtre soldan sağa ve bitiminde aşağı kaydırılıp tüm görüntü matrisi tarandığında köşe pikseli olan A noktası için soldan sağa geçişte yalnızca 1 kez alan içerisinde kalırken, orta nokta olan C noktası 9 harekette hesaplamaya dahil edildiği görülmektedir. Bu durumda öznitelik çıkarımında C noktasının etkisi A'ya göre daha yoğun olarak yorumlanması beklenmektedir buna bağlı olarak da köşelerde kalan noktalar için bilgi kaybına sebebiyet verecektir. Sonraki katmanlara da azaltılmış bilgi aktarımı olacaktır. Bu sorun görüntü matrisi üzerinde dolgu katmanları eklenerek piksellerde filtre tarama işleminin eşit yoğunlukla gerçekleşmesi için bir yöntem olarak sunulmaktadır.

Evrişimsel katmanlar çıktının boyutu küçültülür bu nedenle, çıktının boyutunu artırmak ve köşelerde sunulan bilgileri kaydetmek istenilen durumlarda dolgu katmanlarını kullanılabilir. Dolgu katmanları, görüntülerin dış boyutuna fazladan satır ve sütunlar ekleyerek yardımcı olur, böylece girdi verilerinin boyutu çıktı verilerine benzer kalacaktır. Doldurma, temel olarak, bir evrişimli sinir ağının işlediği bir görüntünün alanını genişletir. Görüntü üzerinde hareket eden filtre her pikseli tarar ve görüntüyü daha küçük bir görüntüye dönüştürür. CNN tarafından işlenen bir görüntüye dolgu eklemek, görüntülerin daha doğru bir şekilde analiz edilmesini sağlar.



Şekil 3.22. Filtrelemede padding işlemi


Şekil 3.22.'de, bir görüntünün üzerine dolgu katmanı eklendiği durumda matrisin boyutunu küçültmekten kurtarmış olur.

Modele göre kullanılan üç farklı dolgu türü bulunmaktadır, bunlar sırasıyla; same padding, causal padding, valid padding. Same padding dolguda, dolgu katmanları görüntülerin veya verilerin dış çerçevesine sıfır değerleri ekler, böylece kullanılan filtre matrisin kenarını kaplayabilir ve onlarla da çıkarım yapılabilir. Valid padding'te dolgu uygulanmamaktadır ama görüntünün her pikselinin geçerli olduğunu varsayılır, böylece giriş basit bir modelin köşelerin geçersiz olduğunu varsaydığı filtre tarafından tamamen kapsanabilir. Causal padding özel bir dolgu türüdür ve temel olarak tek boyutlu evrişim katmanlarıyla çalışır, büyük ölçüde zaman serisi analizinde kullanılmaktadır. Tablo 3.5.'te 3x3'lük bir filtre ile kurulan modelde filtre kullanılmayan ilk model karşılaştırıldığında standart model 28x28 model üç kovolüsyonel katman sonrası 22x22 olarak boyutta azalma olduğu görülmektedir. Same padding örneğinde ise 28x28 olarak üçüncü katman sonrasında da boyut aynı kalmaktadır, böylece çıktı boyut küçülme sorunu aşılabilmektedir (Pak ve Kim, 2017).

Tablo 3.5. Same Padding ve Standart Model'de vektör boyutu


Standart model	Model sonuç
<pre> model = Sequential() model.add(Conv2D(32, kernel_size=(3, 3), activation='relu', input_shape=(28, 28, 1))) model.add(Conv2D(64, kernel_size=(3, 3), activation='relu')) model.add(Conv2D(128, kernel_size=(3, 3), activation='relu')) </pre>	<pre> Model: "sequential" Layer (type) Output Shape Param # ----- conv2d (Conv2D) (None, 26, 26, 32) 320 conv2d_1 (Conv2D) (None, 24, 24, 64) 18496 conv2d_2 (Conv2D) (None, 22, 22, 128) 73856 ----- Total params: 92,672 Trainable params: 92,672 Non-trainable params: 0 </pre>
Same padding	Model sonuç
<pre> models = Sequential() models.add(Conv2D(32, kernel_size=(3, 3), activation='relu', input_shape=(28, 28, 1)), padding='same')) models.add(Conv2D(64, kernel_size=(3, 3), activation='relu', padding='same')) models.add(Conv2D(128, kernel_size=(3, 3), activation='relu', padding='same')) </pre>	<pre> Model: "sequential_2" Layer (type) Output Shape Param # ----- conv2d_6 (Conv2D) (None, 28, 28, 32) 320 conv2d_7 (Conv2D) (None, 28, 28, 64) 18496 conv2d_8 (Conv2D) (None, 28, 28, 128) 73856 ----- Total params: 92,672 Trainable params: 92,672 Non-trainable params: 0 </pre>

Tablo 3.6. Rastgele filtreleme sonucu gri tonlamada katman çıktısı

Konvolüsyon gösterimi	Görsel
<pre> raw_data = data[4, :] raw_img = np.reshape(raw_data, (24, 24)) plt.figure() plt.imshow(raw_img, cmap='Greys_r') plt.savefig('input_image.png') x = tf.reshape(raw_data, shape=[-1, 24, 24, 1]) b = tf.Variable(tf.random_normal([32])) conv = tf.nn.conv2d(x, W, strides=[1, 1, 1, 1], padding='SAME') conv_with_b = tf.nn.bias_add(conv, b) conv_out = tf.nn.relu(conv_with_b) with tf.Session() as sess: sess.run(tf.global_variables_initializer()) conv_val = sess.run(conv) show_conv_results(conv_val, 'step1_convs.png') print(np.shape(conv_val)) conv_out_val = sess.run(conv_out) show_conv_results(conv_out_val, 'step2_conv_outs.png') print(np.shape(conv_out_val)) </pre>	

Tablo 3.6. (Devamı)

Filtre görsel




Tablo 3.6.'daki örnek'te giriş görseli olarak gri tonda bir görüntü kullanılmıştır, 5x5 filtre kullanılarak 24x24 boyutta görüntü filtreleme işlemine sokulmuştur. Sonuç olarak oluşan nitelikler aynı görüntü üzerinde benzersiz özelliklerdir, görüntüde var olan nesneyi anlamak için birlikte çalışırlar. Rastgele üretilen filtreleme modeline bias ve aktivasyon fonksiyonu olarak örnek Relu eklendiğinde ağ doğrusal olmayan şekilde davranacaktır, bu durum da çıkartılan öznelitliklerin daha anlamlı şekilde oluşmasını sağlayacaktır (Mattmann, 2020).

3.8.1.3. Biriktirme (pooling) katmanı

Evrişimli bir ağdan sonraki katman olarak biriktirme katmanı olarak adlandırılan katman gelmektedir. Şekil 3.23.'de yer aldığı gibi en sık tercih edilen iki farklı türü vardı: maksimum biriktirme, ortalama örnekleme.

İşlev olarak ağda yer alan parametre sayısını azaltmak ve hesaplama yükünü hafifleterek bellek kullanımı azaltmak amacıyla yer alır ve her bir özellik haritası için bağımsız şekilde çalışır. Bu katmanda en sık kullanılan yaklaşım maksimum biriktirmedir.

Evrişim katmanında yararlı özellikleri ortaya çıkarıldıktan sonra genellikle evrilmiş çıktılarının boyutunu küçültmek aşırı öğrenmeden kaçınmak için önemli bir adımdır, kovolüsyon katman özellik haritası çıktısının yeniden ölçeklendirilmesi veya alt örneklenmesi, parametre sayısının azaltılmasına yardımcı olmaktadır.



Biriktirme katmanı Şekil 3.23.'de de yer alan öznelik haritalarının boyutsallığını azaltan evrişim tabanlı sistemlerde önemli bir adımdır, bir dizi değeri daha az sayıda değerde birleştirir, yani özellik haritasının boyutsallığını azaltır. Yararlı bilgileri tutarak ve alakasız bilgileri ortadan kaldırarak ortak özellik gösterimini değerli bilgilere dönüştürür.

Konvolüsyon katmanının çıktısı olan “ $n_h \times n_w \times n_c$ ” boyutlarına sahip bir özellik haritası için, bir biriktirme katmanından sonra elde edilen çıktının boyutları:


“($n_h - f + 1$) / $s \times (n_w - f + 1) / s \times n_c$ ” olarak elde edilmektedir. n_h özellik harita yükseklik boyutunu, n_w genişliğini, n_c kanal sayısını f filtrenin genişliğini ve s ise filtrenin matraste hareket ederkenki adım uzunluğunu ifade etmektedir (Zheng ve ark., 2020).

3.8.1.4. Tam bağılık katman

Özellik çıkarma işlemleri sonrasında evrişim ve havuz katmanları dahil nöronlar, tek boyutlu bir vektöre dönüştürülür. Bu işlemden sonra gelen katmanlar tam bağlantılı katmanlardır. Tam bağılı katman nöronları Denklem 3.29.'deki hesaplamayı gerçekleştirir.

$$f_{c_1} = f(b + \sum_{q=1}^M w_{1,q} * o_q) \quad (3.29)$$

Denklem 3.29.'da yer alan o değeri ağırlık çarpımları sonrası aktivasyon fonksiyonunu ifade eder. M bir vektörde hizalanmış önceki katman nöronlarının sayısıdır. Tam bağlantılı katmanlardan oluşan tam bağlantılı sinir ağı yapısı, genellikle derin öğrenme yapılarında sınıflandırıcı olarak kullanılır ve bu yapıda genellikle sınıflandırma amacıyla bir SoftMax aktivasyon fonksiyonu ile çıktı katmanını takip eder. Özellik haritası çıkarıldıktan sonra klasik makine öğrenmesi mimarisine dönüş katmanı olarak da düşünülebilmektedir. Şekil 3.24.'de gösterilen yapay sinir ağı yapılarında olduğu gibi ileri yayılım ve geri yayılım yöntemleri bu katmanda gerçekleşmektedir (Saha, 2020).




Şekil 3.24. Tam bağıli katman ile ağı düzleştirilmesi

3.8.1.5. Sinir ağında seyreltme (dropout) katmanı

Evrişimsel sinir ağı modelinin eğitim verilerine çok iyi uyduğu ancak test verilerinde verilerde daha kötü performans gösterdiğinde aşırı uyum (overfitting) yaygın bir sorun olarak ortaya çıkmaktadır, bu sebeple modelin veri setinin genel özelliklerini öğrendiğinde, spesifik örneklerdeki bazı uç özellikleri de iyi öğrenmesidir.

Temelde dropout rastgele seçilen belirli nöron setinin eğitim aşaması sırasında birimlerin (nöronların) yok sayılması anlamına gelir. “Yoksaymak” ile, belirli bir ileri veya geri yayılım sırasında bu birimlerin dikkate alınmaz. Dropout herhangi bir gizli katmana uygulanabilir, bir sonraki katmana çıktı almak için gizli katmandaki bazı nöronları rastgele seçilir. Şekil 3.25.’de gösterildiği gibi gizli katmanda ileri besleme işlemi sırasında çıktı almak ve rastgele seçilen nöronları devre dışı bırakmak için bazı nöronları rastgele seçilmiştir. Daha sonra geri yayılım sürecinde sadece seçilen nöronlara bağlı ağırlıkları güncellenir.



Şekil 3.25. Yapay sinir ağında dropout modeli

Bırakma oranı belirli bir düğümü gizli bir katmanda eğitime olasılığıdır, oran büyükse gizli katmandaki düğümü seçme ve eğitime olasılığı daha yüksektir. Örnek olarak bırakma oranı 0,1 ise gizli katmandaki her bir düğümün eğitim adımında yalnızca 0,1 eğitilme olasılığı vardır ve aynı zamanda ileri ve geri yayılıma sadece seçilen düğümler için izin verilir. Bırakma oranı 1 ise ağdaki tüm nöronlar eğitilecektir.


Dropout yöntemi sınırlı miktarda eğitim verisinin olduğu ve modelin eğitim verisinde fazla uyması (overfitting) muhtemel olduğu problemlerde daha etkilidir, fazla miktarda eğitim verisinin olduğu problemlerde kullanmanın tercih edilememektedir (“A Gentle Introduction to Dropout for Regularizing Deep Neural Networks”, 2022).

3.8.2. Evrişimli sinir ağı model mimarileri

ImageNet projesi görsel bir veritabanı olarak nesne tanımadada kullanılan ortak bir veri setidir. Bu veri seti 14 milyondan fazla görüntü içermektedir, çok farklı kategorilerde

görüntüler mevcuttur. Örnek olarak balon, çilek gibi tipik olarak 20000'den fazla kategori bulunmaktadır ve her bir kategoriye ait görüntü verileri manuel olarak etiketli olarak depolanmaktadır. Veritabanına erişim ücretsiz olarak sunulmakta ve ImageNet veritabanında bulunan görsellerin sınıflandırabilmesi için her yıl bir yarışma düzenlenmektedir. “ImageNet Büyük Ölçekli Görsel Tanıma Yarışması” (ILSVRC) olarak adlandırılan yarışmada yazılımsal sınıflandırma çözümleri rekabet etmektedir.

ImageNet projesinde asıl amaç sadece en yüksek doğruluk sonucuna ulaşmak değil aynı zamanda kaynak kullanımı, makinede güç tüketimi ve gecikme zamanları önemli bir faktör olarak ele alınmaktadır. CNN modeli doğrusal olmayan işlem birimlerinin ve alt örnekleme katmanlarının bir karışımından oluşan çok sayıda öğrenme aşamasına ayrılmıştır, her katmanın bir dizi evrimsel filtre kullanarak birkaç dönüşüm gerçekleştirdiği çok katmanlı hiyerarşik bir ağıdır. Yarışmada en yüksek sonuç alan modeller Şekil 3.26.'da yer aldığı gibi problem türüne göre genişleme/derinlik/çözünürlük bazlı olarak farklı yaklaşımlarda ölçeklendirme yöntemleri sunulmuştur (Tan ve Le, 2020).




Şekil 3.26. CNN mimarilerinde ölçeklendirme

ImageNet projesi için sunulan modellerde CNN mimarisini daha güçlü hale getirebilmek adına birçok farklı derinliklerde ve parametrelerden oluşan modeller sunulmuştur ve sonraki çalışmalara referans oluşturulabilecek ve düşük hata oranlarında modeller sunulmuştur. ImageNet yarışma projesi için Facebook, Google

ve Microsoft gibi büyük ölçekli kuruluşların da dahil olmasıyla sunulan modellerin performansları yüksek sonuçlara ulaşmıştır. Şekil 3.27.'de gösterildiği gibi her yıl düzenlenen yarışmadan 2012'den 2015'e kadar en performanslı modeller gösterilmiştir (Mouhssine ve ark., 2020). Sırasıyla modellerde 8 katmandan başlayan modeller 152 katman kullanımına ve elde edilen hata oranlarında da yüzde 28.2'den 3.57'ye kadar düşen en performanslı ve referans oluşturulabilecek ilerlemede modeller sunulmuştur. 2012'den 2018 yılına kadar olan ImageNet yarışması için en başarılı olarak kabul edilen modeller aşağıda listelendiği gibidir (Nguyen ve ark., 2017).

- Lenet (1998)
- AlexNet (2012)
- ZFNet (2013)
- Inception V1 (GoogLeNet) (2014)
- VGG-16 (2015)
- ResNet (2016)
- ResNeXt-10 (2017)
- PNASNet-5 (2018)

Bu başlık altında, Imagenet yarışmasında en yaygın kullanılan evrimsel sinir ağı modellerinin problem bazlı olarak avantajları ve dezavantajları ve model yapısı sunulmuştur.




Şekil 3.27. Yıllara göre ImageNet'te raporlanan model hata oranları

3.8.2.1. Lenet model mimarisi

Lenet modeli 1998 yılında tanımlanmış bir CNN modelidir. İlk evrişimsel bir yapay sinir ağı modeli olma özelliği de taşımaktadır. Lecun ve arkadaşları tarafından sunulan modelle birlikte banka çeklerinde yer alan numaraların tanımlanması için geliştirilen bir çözüm olarak sunulmuştur. Bu yöntemle birlikte el yazısı ile yazılmış 0'dan 9'a kadar yer alan banka çek numaraları sayısallaştırılmıştır. Sunulan yöntemde 32x32 piksellik gri tonlamada görseller kullanılmıştır. Tablo 3.7.'de python keras model ve görsel katman grafiğinde de belirtildiği gibi biriktirme katmanında max-pooling tekniği yerine average-pooling tekniği kullanılmıştır ve bu sonraki modellerde geliştirilmiştir. Biriktirme katmanlarda aktivasyon fonksiyonu olarak hiperbolik tanjant ve sigmoid fonksiyonları tercih edilmiştir bunun yerine günümüzdeki modellerde Relu aktivasyon fonksiyonu tercih edilmektedir ve graph transfer yapısı günümüz modellerinde kullanılmamaktadır. Tam bağlantılı katmanda rakamlardan oluşan 10 sınıf bulunmakta ve softmax aktivasyon fonksiyonu tercih edilmiştir. İlk katmanda 5x5'lik boyutta filtre kullanılarak 14x14x6 lık yeni evrişimsel katman boyutlarına ulaşılmıştır. Kanal sayısı incelendiğinde derinliği yüksek bir model olarak kabul edilmektedir ("LeNet-5 Tutorial: Architecture, Features and Importance | Analytics Steps", 2020).

Tablo 3.7. LeNet CNN model mimarisi




3.8.2.2. AlexNet model mimarisi

LeCun ve arkadaşları 1995 yılında LeNet'i tanıttıktan sonra evrişimli sinir ağı modelinin temeli atılmıştır, 2012 yılında sunulan AlexNet modeli ile bilgisayarlı görüde nesne sınıflandırması ve tanımda önemli ölçüde performansla sonuç alınan ilk evrişimli sinir ağı modeli olarak yer almaktadır (Ezhilarasi ve Varalakshmi, 2019). LeNet modelinde problem girdisi olarak el yazısından rakam tanıma işlemi sınırlı ölçüde çözüm sunabilmektedir, yüksek çözünürlükte ve nesne algılamada başarılı sonuçlar alınamamıştır. AlexNet modeli ile modeli mimarisi derinleştirilerek ve parametrelerde optimizasyonlar ile 2012 yılındaki ImageNet yarışmasını kazanmıştır. %17'lik bir hata oranı ile sınıflandırma başarımı elde edilmiştir.

Tablo 3.8.'de evrişimsel sinir ağı modeli gösterilmiş ve keras kütüphanesi ile AlexNet modeli için Python ile gösterimi ifade edilmiştir. Bu modele göre her bir evrişim katmanında sonra biriktirme katmanı eklenmemiştir ve LeNet'e göre daha derin evrişimsel bir ağ olmaktadır. Tabloda da gösterilen FC1 ve FC2 tam bağlantılı katmanlarda sinir hücrelerinde %50 seyreltme (dropout) eklenmiş ve girdi görsellerinde veri artırımı tekniği de ek olarak kullanılan yöntemlerdir. Böylece aşırı öğrenmeden kaçınarak test verisinde de yüksek sonuç alan bir model ortaya koyulmuştur (Khan ve ark. 2019; Mattmann, 2020).

Tablo 3.8. AlexNet model mimarisi



```

alexnet_model = keras.models.Sequential([
    keras.layers.Conv2D(96,(11,11),strides = 4,name="conv0")(X_input)
    keras.layers.Activation('relu')(X)
    keras.layers.Conv2D(256,(5,5),padding = 'same' , name = 'conv1')(X)
    keras.layers.Activation('relu')(X)
    keras.layers.MaxPooling2D((3,3),strides = 2,name = 'max1')(X)
    keras.layers.Conv2D(384, (3,3) , padding = 'same' , name='conv2')(X)
])
  
```

Tablo 3.8. (Devamı)

keras.layers.Activation('relu')(X)
keras.layers.MaxPooling2D((3,3),strides = 2,name = 'max1')(X)
keras.layers.Conv2D(384, (3,3) , padding = 'same' , name='conv3')(X)
keras.layers.Activation('relu')(X)
keras.layers.Conv2D(256, (3,3) , padding = 'same' , name='conv4')(X)
keras.layers.Activation('relu')(X)
keras.layers.MaxPooling2D((3,3),strides = 2,name = 'max2')(X)
keras.layers.Flatten()(X)
keras.layers.Dense(4096, activation = 'relu', name = "fc0")(X)
keras.layers.Dense(4096, activation = 'relu', name = 'fc1')(X)
keras.layers.Dense(6,activation='softmax',name = 'fc2')(X)


3.8.2.3. ZFNet model mimarisi

ImageNet yarışmasında 2013 yılında sunulan ZFNet modeli ağın performansını niceliksel olarak incelemek ve görselleştirebilmek amacıyla sunulmuştur . 2013 yılından öncesi sunulan modellerde dene ve yanıl yöntemiyle geliştirilen modellerin arkaplanda anlayışı net olarak bilinmemekteydi, bu modelle birlikte DeconvNet sinir ağları yaklaşımı sunuldu. Böylece nörondaki aktivasyon ve kurulan modelin performansı ve etkinliği görselleştirilebilmiştir.

DeconvNet yaklaşımı ile klasik CNN modeli ile aynı özelliklerde çalışmaktadır fakat normal sıralamada yer alan evrim katmanı ve biriktirme katmanları sırası değiştirilir böylece evrişim katmanından öğrenilen çıktı veya algılanabilir özellik haritası nöron düzeyinde yorumlanabilir.

ZfNet model mimarisi ile evrişimsel katmanlarda tüm nöronların etkin olmadığı AlexNet mimarisi ile doğrulanmıştır. DeconvNet yaklaşımı ile özelliklerin görselleştirmesi ile evrişimsel katmanda sınırla sayıda nöronların aktif olduğu deneysel olarak ispatlanmıştır. Bu sonuçlara bağlı olarak Zeiler ve Fergus'ın sunduğu modelde CNN topolojisi işlevselliği önplana alınarak parametrelerde optimizasyonlar sunularak ZFNet modeli sunulmuştur.

Tablo 3.9. ZFNet model mimarisi




Tablo 3.9.'da model grafiği ve python keras modelinde gösterildiği gibi 1. ve 2. katmanda adım sayısı küçültülmüş ve filtre boyutu 7x7 ve ikinci katmanda azaltılarak 2x2 olarak konumlandırılmıştır böylece özellik sayısını maksimum sayıda tutuabilmek hedeflenerek modelin öğrenim kapasitesi arttırılmıştır (Khan ve ark. 2019; Mattmann, 2020).. Ek olarak 3,4 ve 5 nolu katmanlarda aktivasyon harita sayıları sırasıyla 385x384x256'dan 512X1024x512'ye yükseltilmiştir. Böylece modelin özellik çıkarım sayısını arttırmaktadır. CNN topolojisinde yapısal iyileştirmeler ve parametre optimizasyonu sayesinde %14.8 hata oranı elde edilmiştir.

3.8.2.4. Inception (GoogLeNet) model mimarisi

Szegedy ve ark. tarafından sunulan bu modelin temel fonksiyonu modelde düşük hesaplama oluşturarak düşük hata sonucu elde edebilmektedir. CNN mimarisinde diğer modellerden farklı olarak bir başlangıç bloğu yapısı bu modelle sunulmuştur. Başlangıç bloğu kullanı klasik mimaride yer alan evrişim katmanları arka arakya eklenmek yerine her bir evrişim katmanı bölünür, filtreleme işlemi ve birleştirme işlemleri paralel olarak işlenerek tekrar birleştirilerek bir sonraki katmana iletilir ve hesaplama gücünde ölçekleme sağlanmış olur. Şekil 3.28.'de gösterildiği gibi

geleneksel evriřimli sinir aęları mikro düzeyde paralel olarak iřlenmekte ve aę ierisinde aę mimarisi ile k bloklar olarak deęiřtirilmektedir.



řekil 3.28. GoogLenet model mimarisi

řekil 3.28.'de gsterilen bařlangı (Inception) bloęunda geleneksel evriřimsel sinir aęı mimarisi mikro dzeyde ele alınarak, aę ierisinde aę olarak bir model nerilmektedir. Bařlangı bloęu ierisinde 1x1, 3x3 ve 5x5 filtreler yer almaktadır bylelikle hem k z niteliklerin hem de byk boyutta z niteliklerin ıkarılmasında yardımcı olabilmektedir, aynı resim iin farklı znrlkler yer alması durumunda eřitliliklere duyarlı bir model olarak znrlk bazlı sorunlara zm getirebilmektedir (Khan ve ark., 2019; Mattmann, 2020).

GoogleNet mimarisi ile geniř lekte filtrelerden nce 1x1'lik filtreler eklenerek z nitelik ıkarımındaki darboęaz engellenmiř olur buna baęlı olarak gereksiz ıkarılan z nitelikleri elemek iin sinir aęında seyreltme (dropout) iřlemi de gerekleřtirilerek sinir dęmlerindeki baęlantı yoęunluęu indirgeniř olur. Ek olarak tam baęlı katman her bir mikro evriřimsel aę iin kullanmak yerine genel bir tam baęlantılı katman tercih edilir. Gerekleřtirilen dropout ve mikro evriřim mimarisi ile parametre sayısı nemli lde azaltılmıř olur, sayısal olarak ImageNet yarıřması

özelinde parametre sayısı gerçekleştirilen bu mimari optimizasyonla kırk kat azaltılarak 1 milyon parametre değerine ulaşılmıştır.

Tablo 3.10. GoogleNet katman mimarisi

type	patch size/ stride	output size	depth	#1×1	#3×3 reduce	#3×3	#5×5 reduce	#5×5	pool proj	params	ops
convolution	7×7/2	112×112×64	1							2.7K	34M
max pool	3×3/2	56×56×64	0								
convolution	3×3/1	56×56×192	2		64	192				112K	360M
max pool	3×3/2	28×28×192	0								
inception (3a)		28×28×256	2	64	96	128	16	32	32	159K	128M
inception (3b)		28×28×480	2	128	128	192	32	96	64	380K	304M
max pool	3×3/2	14×14×480	0								
inception (4a)		14×14×512	2	192	96	208	16	48	64	364K	73M
inception (4b)		14×14×512	2	160	112	224	24	64	64	437K	88M
inception (4c)		14×14×512	2	128	128	256	24	64	64	463K	100M
inception (4d)		14×14×528	2	112	144	288	32	64	64	580K	119M
inception (4e)		14×14×832	2	256	160	320	32	128	128	840K	170M
max pool	3×3/2	7×7×832	0								
inception (5a)		7×7×832	2	256	160	320	32	128	128	1072K	54M
inception (5b)		7×7×1024	2	384	192	384	48	128	128	1388K	71M
avg pool	7×7/1	1×1×1024	0								
dropout (40%)		1×1×1024	0								
linear		1×1×1000	1							1000K	1M
softmax		1×1×1000	0								

Tablo 3.10.'da da görüldüğü gibi başlangıç (Inception) blokları modelin ortasındaki bölümlerde kullanılır. Inception blokları yalnızca modelin eğitimi sırasında kullanılır. Bu modelde 0.4 oranında seyreltme (dropout) kullanılarak gradyan kaybı probleminin önüne geçilmiş olur. Daha sonraki dönemlerde Google sunulan mimarinin Inception-v3 ve Inception-v4 olmak üzere daha gelişmiş modellerini de sunmuştur.

3.8.2.5. VGG model mimarisi

Görüntü işlemede başarılı sonuçlar alınan CNN yapılarında tasarımsal geliştirmeler devam etmiştir, buna bağlı olarak ImageNet yarışmasında VGG grubu sunduğu modelle 2014 yılında ikinci olarak yer almıştır. Görsel Geometri Modeli (Visual Geometry Group) olarak adlandırılan model ile etkili bir model sunulmuştur. Mimari olarak iki veya üç evrişimsel katmanında ardından bir birleştirme katmanı ve

tekrarlayan yapı olarak basit bir yapıda yer almaktadır ve toplam olarak 19 evrişimsel derinliğe kadar oluşturulabilmektedir.

AlexNet ve ZfNet mimarisine benzer bir yapıda oluşturulmuştur, bu modellerle karşılaştırıldığında 19 evrişimsel katman kullanılmış ve yalnızca 3x3 lük filtreler eklenmiştir, çünkü daha öncesinde sunulan ZfNet mimarisine göre küçük filtre kullanımı performansı artırabileceğini göstermişti. Sonuç olarak hesaplama karmaşası küçük boyutlu filtreler kullanılarak azaltılmış olduğu gibi özneteliklerin daha iyi belirlenmesini sağlamıştır.

Tablo 3.11.'de yer aldığı gibi Evrişim katmanları sonrasında biriktirme katma yöntemi olarak maksimum biriktirme (max-pooling) seçilmiştir, görüntü sınıflandırmada daha performanslı sonuçlar elde edildiği görülmüştür. Küçük filtre kullanımı kaynaklı olarak fazla parametre sayısı (138 milyon) ortaya çıkması modelin darboğazı olarak değerlendirilmektedir (Kurnianingsih ve ark., 2019). Tablo 3.11.'de yer aldığı gibi 3x3 olarak seçilen filtre boyutuyla evrişim katmanları A,B,C,D veya E derinliklerinde oluşturulur, maksimum biriktirme yöntemi ile boyut küçültme işlemi gerçekleştirilir.

Tablo 3.11. VGG evrişimsel sinir ağı modeli

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

3.8.2.6. ResNet (Residual Network) model mimarisi

Kaiming He ve ark. tarafından 2015 yılında sunulan model “Artık Ağ” olarak da adlandırılır. ResNet kendinden önceki yıllarda sunulan AlexNet ve VGG modellerine göre yirmi kata kadar daha derin bir yaklaşım sunmakta ve 152 evrimsel katman yer almaktadır (Targ ve ark., 2016). Bu model ile % 3,6’lık bir hata oranı oluşmakta ve sunulan diğer modellere kıyasla çok daha modelde hesaplama karmaşıklığı azaltılmıştır.

Yapısı itibarıyla yüksek katman sayısı ile derinliği yüksek olan bir modeli eğitebilmenin yolu olarak atlama bağlantılarının yer almalarıdır. Atlama bağlantıları ile bir katmandan çıktısı ve ardından gelen katmanı olan veri aynı zamanda ardışıl ikinci katmanın da girdisi olmaktadır.


Bir ağı eğitmekteki amaç amaç fonksiyonu olan $y(x)$ fonksiyonunu elde etmekse girdi değeri olan x modeldeki ağı çıktısı katmanına direkt olarak eklenirse model artık $f(x) = y(x) - x$ ’i oluşturabilmek için eğitime devam edecektir. Bu senaryo artık öğrenme olarak adlandırılmaktadır.

3.8.3. Bilgisayarlı görüde nesne algılama

Otomatik öznitelik çıkarmayla birlikte bilgisayarlı görüde derin öğrenme kullanımı önemli bir araştırma konusu olmuştur ve bu tür problemler için farklı derin öğrenme modelleri sunulmuştur. Yüksek oranlarda doğruluk performansı için büyük ölçekli görüntü setleri gerekmektedir. CNN modelleri görüntü sınıflandırma, algılama, nesne izleme ve tanıma gibi bilgisayarla ilgili görevleri gerçekleştirmek için büyük etiketli veri kümelerine ihtiyaç duyar. Teknolojideki ilerleme ve GPU gibi güçlü grafik işlemci birimlerinin kullanılabilirliği ile veri kümelerinde derin öğrenme kullanımı yaygınlaşmıştır ve nesne sınıflandırması, tespiti ve tanınması gibi alanlardaki son teknoloji sonuçlar araştırmacılar tarafından gösterilmiştir. Hem eğitim hem de test gerçekleştirmek için derin öğrenme modelleri, güçlü hesaplama kaynakları ve daha büyük veri kümeleri gerektirmektedir.

Nesne algılama, sınıflandırma problemlerinde karakteristik bir türevidir (Şekil 3.29.). Giriş objesi olarak bir görüntü veya bir görüntü içerisinde yer alan çok sayıda nesne sınıfı verildiğinde, nesne algılamanın amacı, görüntüde önceden belirlenmiş sınıflardan herhangi bir nesne içerip içermediğine karar vermektir. Buna bağlı olarak da bu nesnelerin resimde nerede bulunduğunu göstermektir.

Nesnelerin sınıflandırılmasında önceden belirlenmiş sınıfların tekil piksellerdeki koordinatlarına göre bir nesnesinin parçası olarak veya değil olarak nitelendiren anlamsal bölünmesi ile saptanır bu sebeple nesne görüntü sınıflandırmanın bir alt görevidir. Görüntünün sınıflandırılması aşamasında görüntünün bir nesnenin olasılığını tanıırken nesnelerin lokalizasyonu resimdeki bir nesnenin alanını tanımayı gerektirir. Nesnelerin yerini belirlemek için kullanılan algoritmalar bir nesnenin görüntüye ilişkin alanının koordinatlarını sağlar. Önceden tanımlanmış bir kategori olarak yaşadığımız görsel dünya binlerce nesne işgal etmektedir, araştırma topluluğu öncelikle yüksek düzeyde yapılandırılmış nesneler olarak örneğin arabalar, yüzler, bisikletler ve uçaklar veya yapılandırılmamış sahneler olarak gökyüzü, çimen ve bulut gibi yüksek düzey nesneler yer almaktadır. Bir nesnenin uzamsal konumu ve kapsamı, bir sınırlayıcı kutu diğer bir ifadeyle görseldeki nesneyi sınırlayan eksenle hizalanmış bir dikdörtgen, kullanılarak temel olarak tanımlanabilir (Chai ve ark., 2021).



Şekil 3.29. Temel sınıflandırma modellerinden nesne tespiti geçiş modelleri

Nesne algılamanın temel amacı güçlü nesne algılama algoritmaları geliştirerek hem yüksek doğruluk hem de yüksek verimlilik elde etmektir dolayısıyla performans sonuçlarında algılama ve doğruluk elde etmek de zorluklara neden olabilir. Bu zorluklar farklı alanlarda ayrıştırılabilir. Gerçek dünyadaki nesnelerdeki varyasyonlar renk, boyut, şekil, malzeme ve poz varyasyonlarını içerebilmektedir bu etkenler görüntü sınıfı içerisinde varyasyonlara yol açabilmektedir. Aydınlatma, hava koşulları, nesnenin fiziksel konumu, perspektif, dağınıklık, gölge, bulanıklık ve hareket gibi faktörler görüntüleme koşulları ve sınırsız ortamlar kategorisinde ele alınan zorluk sınıfıdır. Düşük çözünürlüklü görüntüler, sıkıştırma gürültüsü, filtre bozulmaları gibi faktörler ekran gürültüsü olarak değerlendirilirler. Dedektör tarafından ayırt edilecek binlerce yapılandırılmış ve yapılandırılmamış gerçek dünya nesne kategorisi bulunmaktadır. Diğer bir tür olarak verimliliğe ulaşmayla ilgili zorluklar şunlardır: Düşük kaliteli mobil cihazların sınırlı belleği, sınırlı hızı ve düşük hesaplama yetenekleri vardır. Binlerce açık dünya nesne sınıfı ayırt edilmelidir, büyük ölçekli görüntü veya video verilerinin ve daha önce benzeri görülmemiş nesnelerin işlenememesi olarak bulunur.


3.8.3.1. Görüntüde nesne tespiti yaklaşımı

Görüntü sınıflandırma daha önceki bölümde uygulamada da belirtilen bir görüntüye ait bir sınıf etiketi atama olarak ifade edilirken, görüntüde nesne tespiti ise görüntü içerisinde yer alan bir veya daha fazla tanımlanmış nesnenin kutu sınırlaması ile ifade edilme işlemidir. Görüntü sınıflandırma ve görüntü içerisinde yer alan lokalizasyonu belirleme problemi olarak iki görevi birlikte içinde barındırmaktadır, bu yönüyle görüntü sınıflandırmaya göre görüntüde nesne tespiti işlemi daha kompleks bir problem olarak tanımlanabilir ve görüntü sınıflandırma işleminin bir türevi olarak özelleşmiştir (Zhao ve ark., 2019). Bu iki görevi birlikte barındıran çözüm modeline nesne sınıflandırma olarak adlandırılır. Bilgisayarlı görüde aşağıdaki üç temel başlıkta ayrım yapılabilmektedir.

- Görüntü Sınıflandırma: Bir görüntüde yer alan nesnenin sınıfının tahmini.
- Girdi: Tek bir nesnenin etiketli olduğu görüntü seti.

- Çıktı: Bir sınıf tahmini ve bağlı olarak etiketi.
- Nesne Yerelleştirme: Bir görüntüde yer alan nesnelerin konumlarının sınırlayıcı bir kutu ile çerçevelenmesi ve konumlarının belirlenmesi.
- Girdi: Bir görüntüde yer alan bir veya birden çok nesne içeren etiketli veri seti.
- Çıktı: Bir veya birden çok nesne sayısına bağlı olarak nesneyi çevreleyen sınır kutusu.
- Nesne Algılama: Bir görüntüde konumları ve sınırları belirlenmiş nesneler için etiketlenmesi.
- Girdi: Bir veya birden çok nesneden oluşan görüntü seti.
- Çıktı: Bir veya birden çok nesneye sahip görüntü için sınırlandırılmış kutular ve kategori sınıflarının etiketleri.

Bilgisayarlı görünün alt bir türevi olarak tanımlanan nesne tespiti ile görüntüde yer alan etiketlenmiş objelerin çerçevelenme ile sınır tespiti olarak özetlenebilmektedir, bu alanda bir diğer araştırma konusu olarak ifade edilen yöntemin uzantısı olarak tespit işlemi gerçekleştirilen objenin bir çerçeve kutusu yerine objenin yerinin piksel bazlı sınıflandırılma veya diğer adlandırma ile anlamsal sınıflandırma ile nesne segmentasyonudur. Maskeleye olarak ifade edilen bu yöntem ile girdi olarak verilen bir görüntüde yer alan her bir piksel için nesneye ait olup olmadığı ikili değişkende tutulan ve buna bağlı olarak nesnenin birebir sınırlarının elde edilme yöntemidir. Şekil 3.30.'da da gösterildiği gibi belirtilen sınıflandırma türleri problem türüne göre araştırma konusu olmuştur ("A Gentle Introduction to Object Recognition With Deep Learning", 2022).



Şekil 3.30. Bilgisayarlı görüde görüntü sınıflandırma alt türevleri

Görüntü işleme teknolojisi son yıllarda donanımsal araçların gelişmesiyle daha da ilerleme kaydetmiştir, grafik işleme birimi olarak ifade edilen GPU ve tensör işleme birimi olarak ifade edilen TPU ile derin öğrenme modelleri ile gerçek zamanlı uygulamalar oluşturmaya izin verebilmektedir.

Görüntüde nesne tespiti için kullanılan evrişimli sinir ağı modellerinin bir türevi olarak alanda yer alan çalışmalarda en sık kullanılan metodlar aşağıdaki gibidir:

- R-CNN (Regional- Convolutional Neural Network)
- Fast R-CNN
- Mask R-CNN
- MobileNet
- SSD (Single Shot Detector)
- HOG (Histogram of Oriented Gradients)
- Retina-Net
- YOLO (You Look Only Once)


Klasik görüntü sınıflandırma yöntemlerinde bir model için performans ölçülmesinde tahmin edilen etiket değerleri baz alınarak bir hata oranı ortaya çıkarılır. Sınıflandırma ve lokalizasyon bazlı modellerde performans kriteri belirlenmesinde etiketlenen nesnenin beklenen ve tahmin edilen çerçevedeki mesafe kriterleri ölçüt alınır.

3.8.3.2. YOLO algoritması ile nesne tespiti

Joseph Redmon ve ark. tarafından 2015 yılında YOLO ya da “You Look Only Once” olarak adlandırılan nesne tanıma model sunulmuştur. Farklı nesne tanıma modellerinden R-CNN’e göre hızlı çalışmakta ve buna bağlı olarak da gerçek zamanlı görüntü ve vidyolarda da kullanımı mümkün olabilmektedir (Redmon ve ark.,2015).

Modeldeki yaklaşım girdi olarak sunulan görüntü hücre ızgaralarına bölünür, bununla birlikte bölünen her bir hücre için evrişimsel sinir ağı içermektedir. Yolo mimarisine


göre ilk sunulan modele göre evrişimli sinir ağı modeli olarak GoogleNet ve sonrasında üzerinden yapılan güncelleme ile VGG model bazlı DarkNet olarak ifade edilmiştir. Son adım olarak tahmin için aday olabilecek kutuların birleşimi olan sınırlayıcı çerçeveler üretilmiş olur. Saniyede 45-155 arası değişebilen sayıda kareye kadar çalışma hızına sahiptir (Redmon ve ark., 2015).



Şekil 3.31.Yolo ile nesne tespitinde ızgara modeli


Şekil 3.31.'de yer alan ızgaralama sistemine göre her bir ızgarada daha önce belirlenen nesnenin o alan içerisinde varlığı sorgulanır, eğer bu hücre içerisinde obje kesiti var ise bu objenin orta noktasının aynı zamanda bu hücre içerisinde olup olmadığı (boyut uzunlukları ve sınıfı) da o hücre sorumluluğunda yer alır ve çerçeveleme sorumluluğu objenin merkez noktasının bulunduğu hücre ile gerçekleştirilir.

Her bir hücrede çıktı olarak bir tahmin vektörü belirlenmiş olur, bu vektör güven skoru (nesne varlığına göre 0-1 arası değer alır), Bx (nesne orta noktası için x değeri), By (nesne orta noktası için y değeri), Bw (nesne genişliği), Bh (nesne yüksekliği) ve sınıf olasılığı değerlerini içerir. Güven skoru, elde edilen kutu güven skoru ile belirlenen objeler için sınıf olasılığı çarpımı ile elde edilir. Kutu güven skoru ise $P(\text{nesne})$ (nesnenin kapsanma olasılığı) ve IoU (Intersection over union) çarpımı olarak ifade edilir. Şekil 3.32.'de belirtildiği gibi tahmin edilen alan ve gerçek alan değerleri baz alınarak bir IoU skoru elde edilir.



Şekil 3.32. Kesişim alan skoru

Şekil 3.33.'de yer alan sınırlayıcı kutunun oluşturulma hesaplamasına yer verilmiş, nesne orta noktası için x koordinat değeri t_x ve y koordinat değeri t_y , genişlik ve yükseklik değerleri olan t_w ve t_h değerleri her bir hücrede ağ sonucu olarak hesaplanmış değerler olarak oluşturulmaktadır. İşlem yapılan ızgaranın köşe noktalarına uzaklıkları ise c_x ve c_y ile ifade edilirse “anchor box” çerçevesinin p_w , p_h olarak genişlik ve yükseklik değerleri belirlenir.



Şekil 3.33. Sınırlayıcı kutu konum ve şeklin temsil örneği

BÖLÜM 4. ARAŞTIRMA BULGULARI

Bu bölümde meme kanseri teşhisi koyulmuş hastalarda tedavi yöntemi olarak uygulanan Neoadjuvan Kemoterapi (NAC)'nin yanıtın tahminlenmesinde patolojik veriler kullanılarak değerlendirilmesi ve sonraki bölümlerde aynı vaka ve hasta verilerinin radyolojik görüntüleriyle analizi ve sonuçların değerlendirilmesini kapsamaktadır. Hasta verilerinin toplanmasında Sakarya Eğitim ve Araştırma Hastanesi genel cerrahi ve radyoloji bölümlerinden ilgili vaka ile ilgili veriler dört farklı uzman doktor ile periyodik olarak yüz yüze görüşme aracılığıyla elde edilmiştir. Çalışmada kullanılan veriler en az 1 yıl içerisinde toplanmıştır. Verilerin toplanması ve yorumlanması aşamalarında uzman doktorlardan destek alınmış verilerin kullanılmasında etik kurul onayı alınmış ve çalışma hastane etik kurulu tarafından da desteklenmektedir.

4.1. Tedaviye Cevabın Tahminlemesinde Patolojik Verilere Göre Analizi

Mamografi ve ultrason görüntüleme tekniklerinin her ikisinde de sınırlı duyarlılık ve özgüllük vardır, lezyonları tanımlamada ve özellikle yoğun meme varlığında kısmen çözülebilen sınırlamaları vardır. Tüm bu görüntüleme araçlarının sınırlılıkları nedeniyle, kesin bir teşhis koyabilmek için, hastalar genellikle ağırlı ve maliyetli biyopsi prosedürleri alınabilmektedirler, çıplak gözle görülemeyen ve dolayısıyla önemli ölçüde görüntü özelliklerini vurgulayan tıbbi görüntüleme yöntemleri tıbbi görüntülemenin ayırıcı ve öngörücü potansiyelini artırmaktadır. Ancak tıbbi görüntülerde %100'lük bir kesinlik sonucuna ulaşamamaktadır. Bu çalışmada Neoadjuvan kemoterapi (NAC) sonrasında patolojik komplet yanıt alınabilmiş ve istenilen sonuç alınamamış hasta patolojik verileri önerilen derin öğrenme yöntemi için veri seti olarak kullanılmıştır. Derin öğrenme modellerinden evrişimli sinir ağı (CNN) algoritması ile model oluşturulup modelin sisteme sunulacak yeni bir hasta

verilerleriyle tahminleme başarımı ortaya koyulmuş ve yeni verilerle modelin geliştirilmesi sağlanması hedeflenmiştir. Araştırmada ek olarak, patolojik verilerin veri üzerindeki dağılımları ve modele girdi olarak sağlanmadan önce bir dizi ön işleme aşamaları ile verinin standardizasyonu ve normalizasyonu gerçekleştirmiştir. Patolojik komplet yanıt tahmini için kullanılan değişkenler Tablo 4.1.'de belirtilmiştir.

Tablo 4.1. Veri seti değişkenleri ve açıklamalar

Değişkenler	Açıklamalar
millerkat	Miller katsayısı.
lnreg	Tümörlü lenf nodu değeri.
tamkomplet	Hem tümör hem aksillada tam yanıt alınması.
millerpayne	1-5 arası değerden oluşmakta ve 5 değeri kitlenin kaybolduğunu, 1-4 arası kaybolmadığını ifade etmektedir.
yas	50 70 arası olarak 3 kategorik gruba ayrılmaktadır.
preopmetastazvarlığı	Preop metastaz varlığı.
neoboyutUSG	Neoadjuvant öncesi tümör boyutu.
neoöntümörcapı	Neoadjuvant öncesi tümör çapı.
neooncesiaksilla	Neoadjuvant kt öncesi aksilla tutulumu.
klินิกlenfkat	Klinik enf katsayısı
patLN	Patolojik Met LN katsayısı, kemoterapi öncesi koltukaltı lenf nodu metastazı varlığı.
multifoksl	Multifokal-sentrik, farklı kadranlarda birden fazlaysa multi sentrik katsayısı.
aksilla	Aksilla (Koltuk altı operasyonlarıyla ilgili değer)
slnbbaşarısı	Slnb, başarılı bir örnekleme yapıp yapılamama, lenf nodu yüksek düşük algı ve etki değeri.
metboyutu	Lenf nodu metastaz boyutu, mini makro orta kategorik değerlerinde.
patolojikmetkat	Patolojik metazyaz lenf nodu katsayısı, ameliyat sonrasındaki lenf nodu metastaz varlığı
metkat2	Metastaz lenf nodu katsayısı
neosonrasıpathboyutu	Neoadjuvant sonrası patoloji boyutu
tümörboy	Neoadjuvant sonrası tümör boyutu
grade	None
klินิกTNM	None
klіnіkEVREKAT	None
ptnm	None
pevrekat	None
patoloj2	None
estkat	None

Tablo 4.1. (Devamı)

Değişkenler	Açıklamalar
progkat2	Prog katsayısı
cerb2	None
luminalsubtip	Luminal tip
ki67kat	Ki 67 kat
lenfnod	Ekstrakapsüler invazyon lenf modu dışına tümör invazyonu
vasinvas	None
lenfinvz	None
nörinvas	None
dvitkat	D vitamin katsayı
dvitkat2	D vitamin katsayı 2

Kemoterapik tedaviye yanıt (Neoadjuvant Tam Yanıt) tahmini için etkileyen değerler Tablo 4.1.'de verildiği gibidir ve toplam hasta sayısı 348'dir. Uzman hekimlerin değerlendirmeleri doğrultusunda elde edilen bu verilerde tam yanıt etkinin kontrolünü sağlayan kontrol (karar) değişkenleri (tamkomplet, millerkat ve lnreg) olarak belirlenmiştir.

4.1.1. Derin öğrenme çerçeveleri ve seçimi

Derin öğrenme metotlarının uygulanabilirliği konusunda araştırmalar son yıllarda makine performanslarındaki artış ve alternatif farklı metotların sunulması ile popülerlik kazanmıştır. Çerçeveler sunulan derin öğrenme modellerini daha hızlı bir şekilde ortaya çıkarılmasını sağlayan bir araç veya kütüphanedir. Bir evrişimli sinir ağı modeli (CNN) modeli hiçbir kütüphane veya çerçeve kullanılmadığı durumda en ilkel şekilde bir modeli oluşturabilmek haftalar sürebilecek bir işlem yüküyle karşı karşıya bırakabilmektedir bu sebeple önceden ortaya çıkarılmış modeller ve optimize edilmiş parametreler içeren bir araç ile daha etkin bir model ortaya çıkarılabilmektedir. Böylelikle sadeleştirilen işlemler ve katman yapıları ile okunabilirlik ve değişikliğe açık bir modül ortaya çıkarılmış olur.

Farklı problem tipleri için sunulan mimarileri inşa edebilmek için farklı programlama dillerini destekleyen ve aynı zamanda farklı kullanım amacına göre farklı çözümler sunan derin öğrenme çerçeveleri mevcuttur. Her bir çerçevenin yanında getirdiği

avantajları ve dezavantajları da bulunmaktadır. Tablo 4.2.'de CNN mimarisi için uygun alternatiflerin yer aldığı en yaygın kullanılan alternatif çerçeveler sunulmuştur. Projede tabloda yer alan Keras kütüphanesi seçilmiştir. Python tabanlı bir derin öğrenme kütüphanesi olan Keras açık kaynak kodlu bir kütüphanedir ve akademik araştırmalarda sıklıkla tercih edilmektedir. TensorFlow, Microsoft Cognitive Toolkit, Theano kütüphaneleri üzerinde yer alan bir katman olarak çalışmaktadır. Tamamen kullanıcı dostu bir yaklaşım sunmakta ve genişleyebilir bir yapıya imkân sağlamaktadır. Google tarafından 2017 yılında sunulan Tensorflow 2.0 kütüphanesi ile Keras bütünleşmiş çalışır bir duruma getirilmiştir.

Görüntü işleme problemlerinde oldukça geniş çözüm olanakları sunabilmektedir: veri ön işleme, veri artırımı gibi tekniklerle küçük boyutta yer alan veri kümelerine karşın etkili sonuçlar elde etmede tercih sebebi olabilmektedir. İçerisinde yer aldığı ImageNet yarışmasında görüntü sınıflandırmada etkin modeller olarak kabul edilen Inception, MobileNet, VGG gibi modeller için önceden eğitilmiş model ağırlıkları otomatik olarak kullanımı ve kolay entegrasyonu mümkün olabilmektedir böylece karmaşık model yapıları kurulmasına imkân tanımaktadır. Yalnızca görüntü işleme problemlerinde değil, doğal dil işleme gibi önemli alanlarda da modüler bir yapı kurulmasına imkân vermektedir. Farklı çerçevelerin topluluk desteği Keras'a göre daha az bulunmakta olması, limitli prgramlama dillerine destek vermeleri, endüstriyel kullanımlarda yaygın olarak kullanılmaması sebebiyle projede geliştirme aracı olarak Keras çerçevesi seçilmiştir.

Tablo 4.2. Derin öğrenme için çatıların karşılaştırılması (Pathak ve ark., 2018)


İsim	Özellikler	Arayüz	Derin Öğrenme Modeli	Geliştirici	Lisans
Caffe	Modelleme ve optimazasyon için hızlı	C, C++, Python, Matlab	CNN	Berkeley Vision Learning Center	BSD Lisans
CNTK	Hiperparametre ayarı otomatik yapılması	Python, C++, C#	CNN	Microsoft	MIT Lisans

Tablo 4.2. (Devamı)


İsim	Özellikler	Arayüz	Derin Öğrenme Modeli	Geliştirici	Lisans
TensorFlow	Görüntü sınıflandırma, taşınabilirlik	C++, Python, Java, Go	CNN	Google	Apache 2.0
Theano	Çok boyutlu diziler kullanılarak derleme	Python	CNN	Montreal Üniversitesi	BSD Lisans
Torch	Oto gradyan farklılaşması	C, C++	CNN	R. Collobert, K. Kavukcuoglu, C. Farabe	BSD Lisans
Chainer	Multi GPU desteği	Python	CNN	Preferred Networks	MIT Lisans
Keras	Modüler prototipleme, genişletilebilir	Python	CNN	F. Chollet	MIT License
MXnet	Taşınabilirlik, otomatik farklılaşma	Python, R, C++, Julia	CNN	Makine Öğrenmesi Topluluğu	Apache 2.0

4.1.2. Verinin analizi ve önerilen model


Hasta sayısı olarak 341 hastanın ele alındığı veri setinde 37 değişkene sahiptir. Tam komplet yanıtta referans alınan karar değişkenleri danışmanlık alınan uzman doktorun belirlediği değişkenler baz alınarak karar değişkenleri olarak millerkat, lnreg ve tamkomplet olarak belirlenmiştir. Şekil 4.1., Şekil 4.2. ve Şekil 4.3.'de karar değişkenlerinin veri setindeki değer ve dağılımları grafiksel olarak histogram analizi elde edilmiştir.



Şekil 4.1. MillerKat değişkeninin veri setindeki değer ve dağılımı




Şekil 4.2. Tamkomplet değişkeninin veri setindeki değer ve dağılımı



Şekil 4.3. Lnreg değişkeninin veri setindeki değer ve dağılımı

Veri kümesindeki değişkenlerin birbirine ne derece bağımlı olduğunu keşfetmek ve ölçmek model öncesi süreçte önemli bir adımdır ve bu bilgiler performansı karşılıklı bağımlılıkların varlığıyla azalacak olan doğrusal regresyon gibi makine öğrenimi algoritmalarının beklentilerini karşılamak için ve verilerin daha iyi hazırlanması için yardımcı olabilmektedir. Şekil 4.4.'de değişkenler arası korelasyonlar 0-1 arası değişen değerlerle gösterilmiştir. Değişkenler arası korelasyon en yükseğe 1'e azsa 0'a yakın değer ile ifade edilmiştir. Grafiğe göre tamkomplet yanıtta millerpayne, lnreg ve millerkat değişkenleri en çok etki ettiği görünmektedir.



Şekil 4.4. Değişkenler arası korelasyon haritası

Tam komplet tahmini için alanında uzman tıp hekimiyle ve korelasyon matrisi sonuçlarına göre tahmin edilmesi beklenen karar değişkenleri üç farklı senaryo ile oluşturulmuştur. Senaryoları oluştururken karar değişkenleri ve ihmal edilen değişkenler ile senaryolar aşağıdaki gibi belirlenmiştir.

Model verileri %70 eğitim ve %30 test seti olarak ikiye ayrılmıştır. “Scikit” kütüphanesi “train_test_split” fonksiyonu ile “random_state” olarak adlandırılan rastgelelik parametresi belirtilmediği durumda, her çalıştırıldığında veya yürütüldüğünde yeni bir rastgele değer oluşturulur ve eğitim ve test veri kümeleri her seferinde farklı değerlere sahip olabilmektedir. Bunu önlemek adına random_state = 0

veya 1 gibi başka bir tam sayı sabit bir değer atandığında, kod bloğunun kaç kez çalıştırıldığından bağımsız sonuç aynı olması sağlanmıştır, eğitim ve test veri kümelerinde aynı değerlere böylelikle ulaşılabilmiştir. Rastgele durum parametresi, oluşturulan bölmelerin tekrarlanabilir olmasını sağlamıştır. Scikit-learn, bölmeleri oluşturmak için rastgele permütasyonlar kullanır. Bu da rastgele sayıların aynı sırada üretilmesini sağlamaktadır (Géron, 2020).

Tablo 4.1.'de yer alan 36 değişken giriş değişkeni olarak yer alıp karar değişkeni olarak bir sonraki bölümde yer alan senaryolara göre tüm senaryolarda 2 farklı sınıfta tahminleme işlemine göre Şekil 4.5.'de yer alan model özeti sunulmuştur. Modelde giriş katmanı ve çıkış katmanı dışında 6 gizli katmandan oluşmakta ve her bir katman 128 düğümden oluşmaktadır. Gizli katmanlar arasında aktivasyon fonksiyonu olarak “Relu” etkinleştirme fonksiyonu ve çıkış katmanında “Softmax” etkinleştirme fonksiyonu seçilmiştir.

Modelde “epoch” sayısı 120 ve “batch_size” sayısı 16 olarak 3 senaryoda da sonuçlar gözlemlenerek değerlendirilmiştir. “Epoch” sayısı bir yapay sinir ağında ileri yayılım ve geri yayılım sürecinin tamamlanmasını ifade etmektedir. “Batch_size” ileri yayılım veya geri yayılım sürecinde geçişteki eğitim örneklerinin sayısını ifade etmektedir, bu sayının artması bellek kullanım kaynağını da arttırmakta ve model eğitiminde performans sonuçlarına da yol açabilmektedir. İterasyon sayısı ise batch sayısından bağımsız olarak ileri yayılım ve geri yayılım süreçlerinin ayrı ayrı değerlendirilerek değerlendirilmektedir. Eğitim verisi olarak 1000 örneklem varsayıldığında ve batch boyutu 500 olarak ele alındığında 1 epoch'u tamamlamak için iki iterasyona ihtiyaç duyulmaktadır.

Modelde aşırı öğrenmeyi veya eksik öğrenmeyi engellemek adına epoch sayısı ve batch değerleri için kesin bir değer bulunmamaktadır, kurulan modele, değişken sayısına veri büyüklüğüne göre bu değer değişkenlik gösterebilmektedir. Bu sebeple modele göre en iyi değerlerin elde edildiği epoch ve batch sayısı optimal olarak kabul edilmektedir.

Eğitim modeli optimal seviyeden fazla çalıştırıldığında minimum toplam maliyete yol açıp ezber yapma ile sonuçlanabilecektir. Bu durumda eğitim setinde elde edilen sınıflandırma başarımları yüksek olurken test setinde daha düşük değerler elde edilebilecektir. Yüksek varyans değeri ve buna bağlı olarak düşük bias değeri ile elde edilmiş olur. Bu durumun engellenebilmesi için yüksek özellik sayısının azaltılması ile korelasyonu yüksek değişkenlerin silinmesi veya tek bir yeni değişken ile modelin oluşturulması avantaj sağlayabilmektedir. Yüksek düzeyde veri ile bu durumun önüne geçmek mümkün olabilmektedir. Tersini durum olarak modelin eğitim verilerinden öğrenmesini temel hedef olarak ele alınmaktadır, ancak çok fazla eğitime tabi tutulması istenmemektedir buna bağlı olarak eğitim işlemi daha erken durdurmak bir çözüm olabilmektedir. Ancak, modelin eğitim verilerinden yeterince kalıp öğrenmemesine buna bağlı olarak baskın eğilimi bile yakalayamamasına neden olabilmektedir.

```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
dense (Dense)                (None, 128)                 4736
-----
dense_1 (Dense)              (None, 128)                 16512
-----
dense_2 (Dense)              (None, 128)                 16512
-----
dense_3 (Dense)              (None, 128)                 16512
-----
dense_4 (Dense)              (None, 128)                 16512
-----
dense_5 (Dense)              (None, 128)                 16512
-----
dense_6 (Dense)              (None, 128)                 16512
-----
dense_7 (Dense)              (None, 2)                   258
-----
Total params: 104,066
Trainable params: 104,066
Non-trainable params: 0
-----
None

```

Şekil 4.5. Önerilen katmanlı model yapısı

Tablo 4.1.'de yer alan 36 değişken giriş değişkeni olarak yer alıp veri setinde yer alan tamkomplet, lnreg ve millerkat değişkenleri hastalığın seyrinin tahminlenmesinde karar değişkeni olarak uzman doktor tarafından manuel şekilde belirlenmiştir. Aşağıda


belirtilen senaryolarda Şekil 4.5.'de yer alan aynı model ile 3 senaryoda karar değişkenleri, tahminlenecek sınıf değeri olarak ele alınmıştır.

- Senaryo 1
- Karar değişkeni: tamkomplet
- İhmal edilen değişken: millerkat, lnreg


- Senaryo 2
- Karar değişkeni: lnreg
- Dahil edilen değişken: millerkat
- İhmal edilen değişken: tamkomplet

- Senaryo 3
- Karar değişkeni: millerkat
- Dahil edilen değişken: lnreg
- İhmal edilen değişken: tamkomplet

Senaryo 1 değişkenleriyle model sonucu doğruluk değeri olarak 0.794 ve loss değeri olarak 0.304 elde edilmiştir. Modeldeki epoch sayısı ve her bir adımda elde edilen eğitim ve doğrulama değerleriyle model doğruluk ve loss grafikleri Şekil 4.6. ve Şekil 4.7.'de yer verilmiştir.




Şekil 4.6. Senaryo 1 epoch doğruluk grafiği




Şekil 4.7. Senaryo 1 kayıp değer (Loss) grafiği

Senaryo 2 değişkenleriyle model sonucu doğruluk değeri olarak 0.601 ve loss değeri olarak 0.604 elde edilmiştir. Modeldeki epoch sayısı ve her bir adımda elde edilen eğitim ve doğrulama değerleriyle model doğruluk ve loss grafikleri Şekil 4.8. ve Şekil 4.9.'da yer verilmiştir.




Şekil 4.8. Senaryo 2 epoch doğruluk grafiği




Şekil 4.9. Senaryo 2 kayıp değer (Loss) grafiği

Senaryo 3 değişkenleriyle model sonucu doğruluk değeri olarak 0.699 ve loss değeri olarak 0.386 elde edilmiştir. Modeldeki epoch sayısı ve her bir adımda elde edilen eğitim ve doğrulama değerleriyle model doğruluk ve loss grafikleri Şekil 4.10. ve Şekil 4.11.'de yer verilmiştir.



Şekil 4.10. Senaryo 3 epoch doğruluk grafiği



Şekil 4.11. Senaryo 3 kayıp değer (Loss) grafiği

Modele göre senaryolardaki tahmin doğruluk ve kayıp değerleri göz önüne alındığında Tablo 4.3.'de yer alan karar değişkeni tahmin başarıımı %80 başarı ile en yüksek sonucu elde edilmiştir.

Tablo 4.3. Senaryo özet metrikleri

	Accuracy	Loss
Senaryo 1 (tamkomplet)	0.8	0.3047
Senaryo 2 (lnreg)	0.6019	0.6043
Senaryo 3 (millerkat)	0.6990	0.3865

4.2. Tedaviye Cevabın Tahminlemesinde Radyolojik Verilere Göre Analizi

Tıbbi görüntüler, radyologlar ve doktorların günlük işlerinde önemli bir rol oynamaktadır, görsel muayene mümkün olmadığında, hastalıkların tespiti, teşhisi ve tedavisi için tıbbi görüntülere dayalı olarak kararlar verilmektedir. Bu nedenle, klinik sağlık hizmetlerini iyileştirmenin bir yolu da tıbbi görüntüleri daha verimli ve akıllı bir şekilde sunmak ve analiz etmektir. Diğer bir yandan, sağlık hizmeti sağlayıcıları tarafından kolaylıkla kullanılabilecek yüksek kaliteli tıbbi görüntüler elde etmenin etkili yollarını bulmak anlamına gelmektedir (Baranwal ve ark., 2020; Ezhilarasi ve Varalakshmi, 2019; Jemimma ve ark., 2018; Prakash ve Kumari, 2019) . Diğer bir

faktör olark, sağlık hizmeti sunumunu kolaylaştırmak için tıbbi görüntüleri analiz etmenin akıllı yollarını bulmak anlamına gelmektedir.

Araştırmacılar ve klinisyenler tıbbi görüntülerden daha iyi yararlanmak için bilgisayar destekli sistemlerden yardım almaları doğaldır ve bilgisayarlar özellikle yoğun veri, tekrarlayan ve hesaplama görevlerinde insan gücüne göre yüksek performansta sonuçlar verilmektedir. Bilgisayar destekli sistemler ile yalnızca doktorları tıbbi görüntüleri üretme ve yorumlama gibi zorlu ve zahmetli eforlardan kurtarma potansiyeline sahip olmakla kalmamaktadır bunlara bağlı olarak aynı zamanda tıpta insan hatalarını önlemeye de yardımcı olabilmektedir (Hemanth ve ark., 2019; Madhupriya ve ark., 2019; Razzak ve ark., 2019; Somasundaram ve Gobinath, 2019).

Geleneksel yöntemlerde araştırmacılar inceleme için ele alınan hedef alan hakkındaki bilgi ve tecrübeler dayalı olarak manuel yöntemlerle özellikleri çıkararak tıbbi görüntüleri sayısal olarak tanımlamayı önermektedirler, ancak bu bilgi odaklı yaklaşım her durumda geçerli olmamaktadır. Birincil sebep olarak profesyonel olmayan kişiler olması gereken bir öznitelik çıkarma yöntemi tasarlamak için gerekli tıbbi donanım ve bilgilere sahip olmayabilir, ikinci durum olarak çıkarılan manuel özellikler çoğunlukla yalnızca sınırlı durumlarda çalışırlar ve karmaşık senaryolara karşısında doğru sonuç verme eğilimi düşüktür. Bu durumları önlemek adına muhtemel geçici çözüm olarak hedef alanla ilgili gizli öznitelikleri doğrudan kullanılan tıbbi verilerden öğrenmektir. Bu tür bir veriye dayalı yaklaşım ile manuel özellik çıkarım mühendisliği olmadan verilerden spesifik alan bilgisini doğal olarak öğrenebilmesi mümkün olmaktadır. Bununla birlikte otomatik veri çıkarım ile optimizasyon zorluğu ortaya çıkmakta ve büyük verinin yorumlanmasında donanım kısıtları problemleri sebebiyle ilkel veri odaklı yaklaşımlar yalnızca istenen alan bilgisini saptamak için yeterli model kapasitesine sahip olmayan sık mimarileri kullanmaktadır (Rahimpour ve ark., 2019; Vinoth ve Venkatesh, 2018).

Günümüzde, öğrenme tekniklerinin gelişimi ve paralel hesaplama için donanımdaki gelişmeler, derin sinir ağları gibi derin modellerin öğrenilmesini mümkün kılmıştır. Derin öğrenmedeki atılım, sınıflandırma, nesne algılama ve anlamsal bölümlendirme gibi

birçok bilgisayarla görme görevinde eşi görülmemiş ilerlemelere yol açmaktadır. Aynı şekilde, geleneksel yaklaşımlardan derin öğrenmeye dönüşen tıbbi görüntü hesaplama yöntemlerinde de büyük bir ivme gerçekleşmiştir. Tıbbi alanda derin öğrenmeye çok fazla dikkat gösterilmesine rağmen son yıllarda tıbbi görüntü hesaplama kısmında iyileştirme için hala çok fazla alan yer almaktadır. Farklı derin öğrenme yöntemleri, farklı nesne sınıflarının sınıflandırılması gibi çeşitli makine öğrenimi görevlerini yapmak için sinir ağı algoritmalarını eğtmek için verileri kullanır, konvolüsyonel sinir ağları, görüntülerin analizi için çok güçlü olan derin öğrenme algoritmalarıdır.

Bir CNN görüntü eşlemesi, her bir sinirsel bağlantının tüm uzamsal çevirilerde aynı yerel dönüşümü gerçekleştirmesini gerektiren güçlü kısıtlama ile karakterize edilir. Bu, sistemdeki serbestlik derecesi sayısı ile durum sayısı arasındaki oranı genelleme şansını artırmaktadır. Bu avantaj, görüntü işleme alanında önemlidir, çünkü uygun kısıtlamalar kullanılmadığında, girdi verilerinin yüksek boyutluluğu genellikle kötü tasarlanmış sorunlara yol açabilmektedir. Bir dereceye kadar, CNN'ler biyolojik görme sistemlerinin modellerini yansıtmaktadır. CNN'ler, başlangıçta ayrı bir ön işleme veya özellik çıkarma aşamasına ihtiyaç duymadan ham verileri alır: bir CNN'de özellik çıkarma ve sınıflandırma aşamaları, tek bir çerçevede doğal olarak gerçekleşir. CNN mimarisinde, işlem birimleri üzerindeki ağırlıkların paylaşılması, serbest değişkenlerin sayısını azaltarak ağı genelleme performansını artırır. CNN'lerin, donanımda uygulama için ideal olarak uygun olduğu ve çok hızlı gerçek zamanlı uygulamaya olanak sağladığı çalışmalarda yer almaktadır. Bir CNN'nin ilk katmanı, genellikle, verilerin temel özelliklerini çıkararak, nispeten iyi bir uzaysal çözünürlükte doğrusal olmayan şablon eşleştirmeyi sağlar. Sonraki katmanlar, hiyerarşik bir şekilde evrimsel katmanları oluşturarak önceki özelliklerin belirli uzamsal kombinasyonlarını tanımayı öğrenir (Browne ve Ghidary, 2003).


Sağlıkta derin öğrenme yaklaşımları yaygınlaşsa da hala iyileştirilmesi gereken çok fazla sayıda araştırma alanı bulunmaktadır. Bu çalışmada bilgisayarlı görü yöntemlerinden CNN ve VGG derin öğrenme yöntemleri ile daha önceki bölümde patolojik veriler ile ele alınan yaklaşım, bu bölümde Neoadjuvant kemoterapi sonrası

MR görüntüleri üzerinde sınıflandırma problemi için geliştirilmiş bir model olarak sunulmaktadır.

4.2.1. Verilerin toplanması ve analizi

Çalışmada sağlık profesyonelleri ve klinisyenler tarafından çoğunlukla kullanılan MR görüntüleri kullanılarak bir sınıflandırma modeli oluşturulmuştur. Bu model sayesinde hastalardaki neoadjuvant kemoterapi sonrası tümör boyutunun izlenmesi ve buna bağlı karar vermede bilgisayarlı görme yöntemleri ile tespit edilebilmesi hedeflenmiştir.

Veri kaynağı olarak, ilk olarak tedaviden önce tümörlerden toplanan MRI görüntülerine dayanarak NAC'ye yanıt verenleri yanıt vermeyenlerden ayırt etmek için derin CNN'lerle transfer öğrenimi uygulanmakta (önceden tahmin). Bu görev için, kötü huylu ve iyi huylu meme kitlelerinin ayırımında başarıyla kullanılmış olan derin öğrenme tekniklerini kullanılmaktadır. Bu nedenle araştırmada alanında uzman radyologların eşliğinde 341 hastanın 677 nac öncesi ve sonrası toplanan MRI kesitleri kullanılmıştır. Şekil 4.12.'de ise ele alınan görüntü verileri için uygulanan model öncesi ön işleme adımları gösterilmiştir.



Şekil 4.12. Görüntü ön işleme adımları

Ön işleme yardımıyla modele girdi olarak kullanılan verilerin oluşturulmak istenilen evrişimli sinir ağına uygun olarak işlenmesine yardımcı olan önemli bir adım olmaktadır. Böylece yeni eklenen veya test edilen bir görüntü için modele uyumluluğu şartı kontrolü otomatik olarak gerçekleştirilir ve uygun dönüşüm işlemi ile benzer görüntü verileriyle ilerlemeye önemli ölçüde yardımcı olabilmektedir.


Şekil 4.13.'de yer alan adımlar ilki olan gri tonlama temelde ele alınan görüntüyü renkliden siyah beyaza dönüştürmek amacıyla kullanılır. Derin öğrenme modelinde bu işlem ile hesaplama yükü azalması hedeflenmektedir. Medikal görüntü olan MR görüntü kesitinin tanınabilmesi için renkli bir görüntüye ihtiyaç olmamasından RGB (Red, Green Blue) model karşılığı ifade değerini kolaylaştırıyor olacaktır. Renkli görüntülemenin farklı problem türlerinde önemli olsa da araştırma alanı olan bu konu özelinde renksiz olarak tanıma insan faktörüyle de doğru olarak algılanabilmektedir.

Sonraki adım olarak veri formatına bağlı olarak yeniden ölçeklendirme işlemi gerçekleştirilmiştir böylece görüntü piksel yoğunlukları önceden tanımlı bir aralık olan 0,1 arasında yansıtma işlemidir. Böylece farklı görüntülerde yüksek veya düşük piksel aralıklarına sahipse diğer tüm görüntülerin toplam kayba dengelenmesini sağlar ve standart bir öğrenme oranı sağlamaktadır.

Veri toplama sürecinde verimsiz görsellerin olması veya yetersiz verilerin olduğu durumda mevcut veri kullanılarak değişiklikler ile yeni veri üretme için kullanılır. Veri büyütme, görüntünün yatay veya dikeyde belli açılarla döndürme, kesme, kırpma olarak çeşitlendirebilirler. Kullanılan veri setinin artması yüksek kaynak tüketimi ve eğitim süresinin artmasına da sebebiyet verebilmektedir. Model için yeterli görüntü verisi olması sebebiyle veri arttırımı kullanılmamıştır.

Standardizasyon adımı ile elde edilen görüntü setlerinin yükseliklerini ve genişliklerini sabit bir boyutta ölçeklendirme işlemidir, sapma değeri 1 ve ortalama değeri 0 olacak şekilde yeniden düzenlenir. Yüksek çözünürlüklerde yorumlama performansı düşük olması beklendiğinden veri kalitesini ve tutarlılığını artırmak amaçlı ön işleme tekniklerinde önemli bir adımı oluşturmaktadır.

Veri ön işleme adımlarıyla veri modele hazır hale getirilmesi hedeflenmiştir. Böylece elde edilen format ile anlaşılır ve model için daha verimli hale getirir. Bu adımlar scikit-learn, numpy, opencv ve keras gibi Python temelli kütüphaneler ile matematiksel ön işleme operasyonlarının gerçekleştirilebilmesi mümkündür.



Şekil 4.13. NAC tedavisi uygulanan hasta MR görüntü seti örneği

Meme kanseri, dünya çapında kadınlar arasında en sık rastlanan ve teşhis edilen ve buna bağlı olarak da yaşamı tehdit eden kanser ölüm nedenidir. MR, özellikle kırk yaş üstü kadınlarda en sık görülen yaş grubu olan meme kanserini saptamak için tercih edilen yöntem olarak karşımıza çıkmaktadır bu durum sadece tarama aracı değil aynı zamanda meme yoğunluğunu gösterebildiği için risk değerlendirmede bir analiz metodu olarak kullanılmaktadır. MR görüntüleri derin öğrenme yöntemleri analizi ile meme kitle karakterizasyonu konusunda radyologlara yardımcı olmak için bilgisayar destekli sistemlerle tahminlenmesi önerilmiştir, uygulama örneği olarak meme kitle segmentasyonunun oluşturulmasında iyi huylu kitlelerin ayırt edilmesi yer almaktadır.


Yüksek derece mamogram yoğunluğu meme kanseri için güçlü ve bağımsız bir risk faktörü olarak görünmektedir, fakat meme kanseri riskini ölçeklemede önemli rolü net olarak belirlenememektedir. Sebep olarak, kanseri tetikleyecek yoğunluk dışındaki diğer risk faktörlerin bu durumu etkisi net olarak ifade edilememektedir.

Radyolojik görüntülerin yorumlanması spesifik olarak analiz edilen önceki bölümde ele alınan patolojik konuyla korelasyonu açısından klinik bilgi birikimi

gerektirmektedir. Şekil 4.13.'de gösterilen NAC tedavisi sonucu ulaşılan MR görüntü veri setleri uzman radyolog eşliğinde kesitler alınarak oluşturulmuştur. Elde edilen görüntü setleri görüntü ön işleme adımlarından sonra model eğitime hazır hale getirilmesi amaçlanmıştır.


4.2.2. Önerilen model mimarisi ve sonuçların değerlendirilmesi

Ele alınan çalışmada, meme kanseri MRI görüntüleri ile erken NAC yanıt tahmini için yeni bir derin öğrenme tabanlı yaklaşım önerilmektedir. İlk olarak, tedaviden önce tümörlerden toplanan MRI görüntülerine dayanarak NAC'ye yanıt verenleri yanıt vermeyenlerden ayırt etmek için derin CNN'lerle transfer öğrenimi uygulanmakta (önceden tahmin). Bu görev için, kötü huylu ve iyi huylu meme kitlelerinin ayrımında başarıyla kullanılmış olan derin öğrenme tekniklerini kullanılmaktadır. Bu nedenle araştırmada 341 hastanın toplamda 400 kesit NAC öncesi ve sonrası MRI kesitleri kullanılmış görüntülerden oluşmaktadır. Sunulan model ile sonraki kemoterapi yöntemlerinden sonra toplanan tümör MR görüntülerinden yanıt tahmin edebilen CNN tabanlı bir model önerilmiştir. Böylece NAC yanıt tahmini için derin öğrenme temelli bir yaklaşım uygulanması planlanmıştır. Şekil 4.14.'de belirtilen ön işleme ve sınıflandırma aşamaları sonucundan NAC'den kaynaklanan kitle şeklindeki değişikliklerin tedaviye yanıt verenleri ayırt etmek için kullanılıp kullanılamayacağını değerlendirmesi amaçlanmıştır.



Şekil 4.14. Sunulan model mimari ve akışı

Araştırma kapsamında iki farklı model mimari yapısı önerilmiştir, bunlardan ilk klasik CNN yapısı ve ikincisi de VGG bazlı model olarak sunulmuştur. Bir evrişimli sinir ağı, Şekil 4.15.'deki katmanlardan oluşur ve RGB girdi görüntü setleri olarak giriş verisi ön işleme adımlarından sonra modele giriş verisi olarak sağlanır, sırasıyla evrişimli katman, biriktirme katmanı, tam bağlantılı katman ve çıktı katmanı adımlarıyla işlenir.



Şekil 4.15. CNN temel model yapısı

Giriş olarak eklenen görüntünün işlendiği her adım aşağıdaki süreçlerden oluşmaktadır ve Şekil 4.16.'da gösterildiği gibi aşağıda yer alan katmanlar ile model bileşenleri açıklanmıştır (Aloysius ve Geetha, 2017; Yue ve ark. , 2020).


Konvolüsyon Katmanı ve Aktivasyon Fonksiyonu: Görüntüden özellikler çıkarmak amacıyla sıralı katmanları ile özellikleri ortaya çıkarmak için gerçekleştirilir. Aktivasyon fonksiyonu ile modele doğrusal olmayanlık özelliği kazandırarak modelin öğrenme performansı artırır.

Biriktirme Katmanı: Evrişimsel katmanlardan sonra eklenen bu katman ile modeldeki ağırlıkların sayısının azaltılmasına olanak sağlar ve buna bağlı olarak ağıdaki parametre sayısını azaltılarak hesaplama karmaşıklığının azaltılmış olur.

Düzleştirme Katmanı: Evrişimsel katmanları sonrası biriktirme katmanı adımlarından sonra oluşan matrisi tek boyutlu dizi haline dönüştürerek klasik yapay sinir ağı modeline dönüştürür.

Tam Bağlantılı Katman: Evrişimsel katmanlar sonucu oluşan tek boyutlu dizi için sınıflandırma işleminde kullanılan standart sinir ağı yöntemi uygulanır.

Relu Aktivasyon Fonksiyonu: Modelde evrişimsel katmanlarından sonra eklenen aktivasyon fonksiyonudur. Bu katmanın temel görevi giriş verisinden gelen negatif değerleri sıfıra dönüştürmektir ve buna ek olarak önceki katmandan gelen işlemlerden model lineer bir yapıya sahiptir ve bu lineeriteyi bozmak ve dönüştürülmesi gerekmektedir. Böylece model daha verimli öğrenmesi sağlanmış olur.



Şekil 4.16. Önerilen evrişimli sinir ağı modeli boyut matris yapısı

Sunulan iki model, Python programlama dili 3.7 sürümü ve Keras derin öğrenme kütüphanesi kullanılarak uygulanmıştır. Çalışmada kullanılan veri seti, eğitim ve test veri seti olarak %75 - %25 oranında iki gruba ayrılmıştır. Girdi verisi olarak görüntü boyutları sabitlenerek 224x224 boyutunda yeniden düzenlenerek daha etkili sonuçlar alınması hedeflenmiştir. CNN ve VGG mimarilerine dayalı olarak önerilen iki farklı model tasarımı sunulmuş ve modeller için katman bilgileri ve parametre sayıları Tablo 4.4. ve Tablo 4.5.'de gösterildiği gibi oluşturulmuştur. Çalışmaya bağlı olarak tasarım katmanları olarak tanımlanan önerilen modeldeki görüntülerin boyutu, kullanılan katmanlarıdaki evrişimsel katman sayısı, ortaklama katman sayısı ve dizimdeki yeri olarak ifade edilmektedir. Model parametreleri kapsamında ise evrişimsel katmanlarda kullanılan filtrenin boyutu ve kaydırma (shifting) oranını gibi değerlerini temsil etmektedir. İki model için de epoch sayısı 120 ve batch size değeri 20 olarak atanmıştır ve CNN bazlı modele göre VGG bazlı model için başlangıç ağırlıkları ImageNet

ağırlıklarıyla öğrenme işlemi başlatılmıştır böylece rastgele değerlerle öğrenme işlemi başlamak yerine anlamlı değerler ile öğrenme aktarımı (transfer learning) hedeflenmiştir.

Tablo 4.4. Sunulan evrimsel yapay sinir ağı modeli

Model 1: CNN Bazlı Sınıflandırma Modeli		
Katman (Tip)	Çıkış Boyutu	Parametre Sayısı
Conv2D	(None, 222, 222, 32)	896
MaxPooling	(None, 111, 111, 32)	0
Conv2D	(None, 109, 109, 32)	9248
MaxPooling	(None, 54, 54, 32)	0
Conv2D	(None, 52, 52, 64)	18496
MaxPooling	(None, 26, 26, 64)	0
Conv2D	(None, 24, 24, 128)	73856
MaxPooling	(None, 12, 12, 128)	0
Flatten	(None, 18432)	0
Dense	(None, 128)	2359424
Dropout	(None, 128)	0
Dense	(None, 1)	129
Toplam Parametre Sayısı		2,462,049

Tablo 4.5. VGG bazlı evrimsel sinir ağı modeli

Model 2: VGG Bazlı Sınıflandırma Modeli		
Katman (Tip)	Çıkış Boyutu	Parametre Sayısı
Vgg16	(None, 7, 7, 512)	14714688
Flatten	(None, 25088)	0
Dense	(None, 128)	3211392
Dropout	(None, 128)	0
BatchNormalization	(None, 128)	512
Dense	(None, 1)	129
Toplam Parametre Sayısı		17,926,721

Model performans değerleri sunulan iki model için eğitim sonrası ölçümlenmiştir. Performans sonuçları değerlendirildiğinde 2. modeldeki (VGG tabanlı mimari) başarı oranı daha yüksek olduğu görülmüş ve kayıp fonksiyonu sıfır değerine daha yakın olduğu için model 1'e göre daha iyi bir sınıflandırma sonucu elde edilmiş ve Tablo 4.4. ve Tablo 4.5.'de gösterilen başarı metrikleri özetlenmiştir. Model 2'de doğruluk performansı değerlendirildiğinde %78'lik bir başarı oranı elde edilmiştir ve kayıp

değerinin sıfır değerine yakın bir sonuca sahip model 2'nin daha etkin sonuç alındığı gözlemlenmiştir. Bu modellerden elde edilen performans değerleri olarak Tablo 4.6'daki gibi 50 dönem için doğruluk ve kayıp fonksiyon grafikleri elde edilmiştir. Geri çağırma değerleri de Tablo 4.7'deki diğer performans ölçütleri olarak gözlemlenmiştir.

Hassaslık Değeri - Precision rate (P) = TP (True Positive) / (TP + FP (False Positive))

Geri Çağırma Değeri - Recall rate (R) = TP (True Positive) / (TP + FN (False Negative))

Tablo 4.6. Model doğruluk ve kayıp değeri oranları

Model	Doğruluk Oranı	Kayıp Değeri
Model 1 (CNN Tabanlı Mimari)	0.7215	0.259
Model 2 (VGG Tabanlı Mimari)	0.7848	0.0248

Tablo 4.7. Hassaslık ve geri çağırma değerleri

Modeller	Hassaslık (Precision) Değeri	Geri Çağırma (Recall) Değeri
Model 1	0.7073	0.7250
Model 2	0.7778	0.7870


Araştırmada, sağlık sektöründe sıklıkla kullanılan MRI görüntüleri aracılığıyla NAC sonrası tahminleme için CNN ve VGG tabanlı önerilen modellerin sınıflandırmadaki performans değerlendirilmiştir. Evrişimli katman sayısı, veri seti kalitesi, iterasyon sayısı eğitim sırasında modelin başarısını etkileyebilecek ana kriterler arasında olabilmektedir. Eğitim setinde hasta örneklem sayısı sınırlı olabilir ve bu durum aşırı öğrenmeye neden olabilir, bu tür durumlar için önceden eğitilmiş bir mimariye sahip olan VGG tabanlı model ile sınırlı sayıda görüntü ile daha iyi sonuçların alınabileceği gözlemlenmiştir. Sonuç olarak, önceden eğitilmiş VGG tabanlı modellerin, farklı özelliklere sahip nesnelerle eğitilmiş olsalar bile, veri toplamanın sınırlı olduğu sağlık alanında uygulanabilirliğinin yüksek olduğu gözlemlenmiştir.

4.3. YOLO ile Nesne Tespiti ve Önerilen Model Mimarisi

GoogleNet mimarisi baz alınarak oluşturulan YOLO model mimarisi 24 evrişimli katman yer almakta, bu katmanlardan sonra iki tam bağlı katmandan oluşmakta ve Şekil 4.17.'de model yapısı gösterilmiştir. Klasik evrişimli sinir ağı modelinde olduğu

gibi evrişim katmanlarında giriş olarak kullanılan görüntü için özellik haritaları çıkarılmaktadır buna bağlı olarak tam bağlı katmanda da koordinat bilgileri ve çıkış sınıf olasılıkları ortaya çıkarılır (Chen ve ark., 2018; Fang, Wang ve Ren, 2020).

2006 yılından itibaren Nvidia şirketinin sunduğu grafik işlemcilerinin aynı zamanda diğer işlemler için kullanımlar için sunduğu bir yazılım mimarisi olan CUDA ve bu mimari ile uyumlu çalışabilecek grafik kartları ile GPU (General Purpose Graphics Processing Units) yüksek performansta görüntü işleme imkânı sunmaktadır. GPU'nun yüksek sayıda kontrol birimleri ve fazla sayıda çekirdek yapısına sahip olması sebebiyle geleneksel CPU donanım yapısına göre görüntü işlemede piksel bazlı işlem yağıldığı göz önüne alındığında daha yüksek performans sonuçlarına imkân vermektedir. YOLO model mimarisi de CUDA mimarisi ile sunulan bir sinir ağı mimarisi olarak işlemci gücü olarak hızlı işleme kapasitesi olan GPU işlemcisinden faydalanmaktadır (Shafiee ve ark., 2017).



Şekil 4.17. YOLO model mimarisi

Kurulan model, Google'ın açık kaynak olarak sunduğu Colab platformu ile yüksek işlemciye sahip "Intel(R) Xeon(R) CPU @ 2.20GHz" sanal makinesi ile eğitim işlemi gerçekleştirilmiştir.

4.3.1. Veri analizi ve önerilen model

Çalışmada MRI görüntüleri kullanılarak meme kanserinde erken NAC tahmininde Yolo tabanlı derin öğrenme modeli sunulmuştur. Önerilen modele bağlı olarak elde

edilen görüntüler ile tedaviye yanıt vermede önceden tahmin için Yolo tabanlı görüntüden nesne tespit yöntemiyle öğrenme işlemi gerçekleştirilmesi amaçlanmıştır. Görev için CNN bazlı VGG ile görüntü segmentasyonunda kullanılan çalışma modelinden farklı olarak görüntüde yer alan bölgesel tespit ile lokalizasyonun daha net ortaya çıkarılması hedeflenmiştir buna bağlı olarak kötü huylu ve iyi huylu meme kitlelerinin lokalizasyonunun belirlenmesi asıl amaç olarak hedeflenmiştir.

Araştırmada görüntü segmentasyonunda kullanılan görüntü veri seti aynı şekilde uygulanmıştır, 341 hastanın 400 kesit NAC tedavi öncesi ve sonrası MRI görüntü kesitlerinden oluşmaktadır.

Sunulan Yolo bazlı derin öğrenme modeli ile NAC tedavi yöntemi sonrası hastadan toplanan MRI görüntülerinde tedavi sonrası yanıtın değerlendirilmesinde önemli bir uygulama yöntemi olması hedeflenmiştir. Böylece tedaviye tam yanıtın MRI görüntüleriyle değerlendirilmesinde değerlendirilmesinde eğitim sonucu eğitilmiş model kullanılarak hazırlanan Python 3.4 versiyonu ve Tkinter arayüz kütüphanesiyle hazırlanan arayüz ile klinisyenlerin kullanımına sunulması hedeflenmiştir.

Önceki bölümde ele alınan görüntü sınıflandırma yönteminde kullanılan görüntü ön işleme adımları Yolo için de uygulanmıştır. Ön işleme yöntemleri olarak görüntülerin seçimi, gri tonlama dönüşümü, normalleştirme, görüntü standardizasyonu ve görüntü segmentasyonu adımları sırasıyla uygulanmıştır. Ön işleme adımında Yolo’da görüntü segmentasyon yöntemlerinden farklı olarak, özelliği bir türü olan görüntüde nesne tespitinde eğitim veri setinde her bir görüntü için nesnenin görüntüdeki konumu da belirlenmektedir. Görüntüdeki nesne için sınırlayıcı kutu değerleri belirlenir. Bu değerler $[x_merkez, y_merkez, w, h]$ olarak sabit ve aşağıda verilen formatta normalleştirilerek her bir görsel için uygulanmıştır.

$$x_merkez = (görüntü\ sol\ üst\ x\ koordinatı + kutu\ genişliği/2) / görüntü\ genişliği$$



$$y_merkez = (görüntü\ sol\ üst\ y\ koordinatı + kutu\ yüksekliği/2) / görüntü\ yüksekliği$$

$$w = kutu\ genişliği / görüntü\ genişliği$$

$$h = kutu\ yüksekliği / görüntü\ yüksekliği$$

Görüntüde yer alan objelerin algılanması ve kurulan derin öğrenme modelinin eğitilebilmesi için görüntü setinde bulunan her bir verinin açıklanması ve etiketlenmesi modele sunum öncesi yer alan adımdır. Bu adım için MakeSense web tabanlı uygulamadan yararlanılmıştır. Uygulama GPL (Genel Kamu Lisansı) ile ücretsiz olarak sunulmakta ve görsellerin etiketleme aracı olarak çalışmada tercih edilmiş ve Tablo 4.8.'de örnek bir nesne çerçeveleme işlemine yer verilmiştir. Çoklu olarak tüm görsel verinin çerçeveleme ve etiketleme işlemi sunan uygulama ile her bir düzenlenen görsel için bir x_ merkez, y_ merkez, w ve h değerleri çıktı olarak elde edilmiş olur.

Tablo 4.8. MRI eğitim görsellerinin etiketlenmesi

MRI Görüntü	Makesense.ai ile nesne etiketleme	Etiketleme değerleri
		<pre>0 0.336851 0.499271 0.073852 0.138549 0 0.655032 0.463540 0.051948 0.105005</pre>
		<pre>0 0.347808 0.497812 0.073864 0.100630 0 0.649351 0.504375 0.061688 0.140007</pre>

Önerilen sinir ağı modeline göre optimizasyon parametreleri sırasıyla: eğitim epoch sayısı 2000 olarak seçilmiş, her bir evrişim katmanının kullanılan filtre sayısı 64, bir diğer optimizasyon paramteresi olarak maliyet fonksiyonunu minimum değerini bulmada yinelemeli olarak çalıştırılan ve diğer bir deyişle değişkenlerin derecesini ölçen Stokastik Gradyan İnişi (SGD) yöntemi ile hata oranı en az indirgenmesi amaçlamıştır. Model eğitim adımı aynı zamanda kaç verinin işlenmesinin belirlenebilmesinde bir değişken olan 'batch' sayısının maksimum değeri 2000 olarak konfigürasyon dosyasında belirlenmiştir. Yolo versiyon 4 ile oluşturulan model

mimarisine göre Şekil 4.18.'de de gösterilen 161 evrişimsel katman yapısı Google Colab platformunda yüksek GPU işlemci desteği sunan sanal makinesi ile eğitim işlemi 6 saat süren eğitim süresi ile tamamlanmıştır. Eğitim işleminde “DarkNet”, önceden eğitilmiş ağırlıkları ile eğitim başlatılmıştır. Yolo algoritmasının literatürde az sayıda uygulamasının olması sebebiyle Yolo'nun da ilk yazarı olan J Redmon ve ark. sunmuştur ve aynı zamanda model eğitiminde rastgele değerlerle model başlatılmasının önlenmesi adına çerçeve olarak kullanılmaktadır (Carata ve ark., 2019).

```


124 conv 256 1 x 1/ 1 26 x 26 x 512 -> 26 x 26 x 256 0.177 BF
125 conv 512 3 x 3/ 1 26 x 26 x 256 -> 26 x 26 x 512 1.595 BF
126 conv 256 1 x 1/ 1 26 x 26 x 512 -> 26 x 26 x 256 0.177 BF
127 conv 128 1 x 1/ 1 26 x 26 x 256 -> 26 x 26 x 128 0.044 BF
128 upsample 2x 26 x 26 x 128 -> 52 x 52 x 128
129 route 54 -> 52 x 52 x 256
130 conv 128 1 x 1/ 1 52 x 52 x 256 -> 52 x 52 x 128 0.177 BF
131 route 130 128 -> 52 x 52 x 256
132 conv 128 1 x 1/ 1 52 x 52 x 256 -> 52 x 52 x 128 0.177 BF
133 conv 256 3 x 3/ 1 52 x 52 x 128 -> 52 x 52 x 256 1.595 BF
134 conv 128 1 x 1/ 1 52 x 52 x 256 -> 52 x 52 x 128 0.177 BF
135 conv 256 3 x 3/ 1 52 x 52 x 128 -> 52 x 52 x 256 1.595 BF
136 conv 128 1 x 1/ 1 52 x 52 x 256 -> 52 x 52 x 128 0.177 BF
137 conv 256 3 x 3/ 1 52 x 52 x 128 -> 52 x 52 x 256 1.595 BF
138 conv 24 1 x 1/ 1 52 x 52 x 256 -> 52 x 52 x 24 0.033 BF
139 yolo
[yolo] params: iou loss: ciou (4), iou_norm: 0.07, obj_norm: 1.00, cls_norm: 1.00, delta_norm: 1.00, scale_x_y: 1.20
nms_kind: greedy (1), beta = 0.600000
140 route 136 -> 52 x 52 x 128
141 conv 256 3 x 3/ 2 52 x 52 x 128 -> 26 x 26 x 256 0.399 BF
142 route 141 126 -> 26 x 26 x 512
143 conv 256 1 x 1/ 1 26 x 26 x 512 -> 26 x 26 x 256 0.177 BF
144 conv 512 3 x 3/ 1 26 x 26 x 256 -> 26 x 26 x 512 1.595 BF
145 conv 256 1 x 1/ 1 26 x 26 x 512 -> 26 x 26 x 256 0.177 BF
146 conv 512 3 x 3/ 1 26 x 26 x 256 -> 26 x 26 x 512 1.595 BF
147 conv 256 1 x 1/ 1 26 x 26 x 512 -> 26 x 26 x 256 0.177 BF
148 conv 512 3 x 3/ 1 26 x 26 x 256 -> 26 x 26 x 512 1.595 BF
149 conv 24 1 x 1/ 1 26 x 26 x 512 -> 26 x 26 x 24 0.017 BF
150 yolo
[yolo] params: iou loss: ciou (4), iou_norm: 0.07, obj_norm: 1.00, cls_norm: 1.00, delta_norm: 1.00, scale_x_y: 1.10
nms_kind: greedy (1), beta = 0.600000
151 route 147 -> 26 x 26 x 256
152 conv 512 3 x 3/ 2 26 x 26 x 256 -> 13 x 13 x 512 0.399 BF
153 route 152 116 -> 13 x 13 x 1024
154 conv 512 1 x 1/ 1 13 x 13 x 1024 -> 13 x 13 x 512 0.177 BF
155 conv 1024 3 x 3/ 1 13 x 13 x 512 -> 13 x 13 x 1024 1.595 BF
156 conv 512 1 x 1/ 1 13 x 13 x 1024 -> 13 x 13 x 512 0.177 BF
157 conv 1024 3 x 3/ 1 13 x 13 x 512 -> 13 x 13 x 1024 1.595 BF
158 conv 512 1 x 1/ 1 13 x 13 x 1024 -> 13 x 13 x 512 0.177 BF
159 conv 1024 3 x 3/ 1 13 x 13 x 512 -> 13 x 13 x 1024 1.595 BF
160 conv 24 1 x 1/ 1 13 x 13 x 1024 -> 13 x 13 x 24 0.008 BF
161 yolo

```


Şekil 4.18. Yolo v4 evrişimli sinir ağı modeli

Modelin ortalama kesinlik değeri (precision) %71, ortalama doğruluk değeri (accuracy) %70,51, IoU değeri (önceki bölümde hesaplamada belirtilen nesnenin gerçekte olan alanı ile tahmin edilen alan kesişiminin toplam birleşim alana oranı) %67.00 olarak elde edilmiştir. Şekil 4.19.'da 2000 epoch'a kadar olan model hata oranı (loss function) gösterilmiştir. Şekil 4.20.'de örnek bir test verisinde Colab

platformunda oluşturulan model ile elde edilen test görüntüsü ve nesnenin oransal tahminleme sonuçları elde edilmiştir.




Şekil 4.19. Epoch, hata oranı grafiği




Şekil 4.20. Test görüntü setinde nesne tespiti

Model sonucu elde edilen ağırlık fonksiyon dosyası kullanılarak klinisyenlerin kullanımına sunmak üzere Python Tkinter kütüphanesi kullanılarak oluşturulan arayüz ile yeni MRI görüntülerinde tahminleme için bir son kullanıcı form uygulaması oluşturulmuştur. Oluşturulan uygulamada algoritma temel olarak Şekil 4.21.'de yer aldığı gibi oluşturulmuştur ve Şekil 4.22.'de de oluşturulan prototip uygulama test ekran görüntüsü yer almaktadır.



Şekil 4.21. Radyologlar için oluşturulan arayüz uygulama akışı




Şekil 4.22. Model ağırlık dosyası ile oluşturulan son kullanıcı arayüzü

Tkinter, tüm Python dağıtımlarında bulunan ortak bir kullanıcı arabimi oluşturmak için sunulan çözümdür ve standart olarak kütüphanede yer almaktadır. Python 3.7 sürümüyle birlikte özel bir eklentiye gereksinim duymadan oluşturulan kullanıcı paneli ile daha önce eğitilmiş model ağırlık dosyası Şekil 4.21.'de yer alan algoritmik şema ile kullanıcıya gerçek yüklenen görüntü ve model tahmin görüntüsü arayüzü

sunulmaktadır. Prototip olarak tasarlanan form uygulaması bir saniye altında sonuç alınmakta ve algoritma şemasında da belirtildiği gibi yeni bir eğitim işlemi gerçekleşmeden daha önce eğitilmiş model ile cevap vermektedir, buna bağlı olarak hastane sistemlerinde standart olarak kullanılan minimum standarttaki tüm bilgisayarlarda çalışmasını da mümkün hale getirmektedir.

4.4. Sonuç ve Öneriler

Sağlık hizmeti sağlayan kurumlar günlük olarak farklı yapılarda ve kaynaklarda heterojen bir büyük veri üretmektedir buna duruma bağlı olarak geleneksel yöntemler ile bu yapıdaki verileri anlamlandırabilmek ve yönetilebilirlik öngörüsü azalabilmektedir. Makine öğrenmesi ve derin öğrenme yöntemleriyle bu tür verilerin yönetilebilmesi ve yorumlanabilmesi ve analiz edilebilmesinde güçlü bir araç olarak ortaya çıkmaktadır. Prognoz olarak adlandırılan klinik bir uygulamada bir hastalığın gelişim sürecinin tahmin edilmesi, koşullara göre hastalığın seyrinin kötüleşmesi, iyileşmesi veya sabit kalması gibi öngörülerde bulunma sürecini kapsamaktadır. Hastanın prognoz takibi ile doğru teşhis ve tedavi yönteminin belirlenmesinde patolojik test sonuçları, radyolojik görüntüler gibi farklı yapıda veri türleri ve farklı kaynaklarda depolanan verilerin derin öğrenme yöntemleriyle yorumlanması klinisyenlere büyük ölçüde çözüm sağlamaktadır. Tam otomatik akıllı tıbbi görüntü teşhis sistemlerinin yeni nesil sağlık sistemlerinin bir parçası olması beklenmektedir. Şekil 4.23.'de ele alınan probleme önerilen akış modeli sunulmuştur.



Şekil 4.23. Sunulan model akış şeması

Hastalığın doğru teşhisi ve görüntü verilerinde analizin doğru yapılabilmesi ve öngöründe uygun görsel verinin elde edilmesi ve yorumlanmasına bağlıdır. Radyolojik görüntü alma cihazları son yıllarda önemli ölçüde iyileşmiştir. X-Ray teknolojisi ve MRI taramaları sayesinde yüksek çözünürlüklü radyolojik görüntüler elde edilebilmektedir fakat görüntü yorumlamanın otomatize edilmesi ve faydaları henüz yeni elde edilmeye başlanmıştır.

Tıbbi görüntü analizinde aktif olarak kullanılan manyetik rezonans görüntüleme (MRI), bilgisayarlı tomografi (CT), ultrason ve pozitron emisyon tomografisi (PET) gibi amaca göre değişen farklı görüntüleme modülleri kullanılarak elde edilen tıbbi görsel verilerden verimli ve etkili bilgi çıkarımı için makine öğrenmesi teknikleri kullanılır ve bu modüller farklı vücut organları ve dokular hakkında önemli fonksiyonel ve anatomik bilgiler sağlamaktadır. Anomalilerin saptanması, lokalizasyonu ve teşhisinde önemli bir noktada yer almaktadır. Tıbbi görüntü analizinde temel amaç, hastalıkların etkin teşhisi ve prognozu için klinisyenlere ve radyologlara yardımcı olacak sistemler sunmaktır. Görüntü yorumlama için geleneksel makine öğrenimi algoritmaları önemli ölçüde klinisyenler tarafından hazırlanmış özniteliklere dayanmaktadır ve buna bağlı olarak görüntüde yer alan yapısal özellikler uzman klinisyenler yardımıyla çıkartılmaktadır. Hastadan hastaya değişen radyolojik veya patolojik olarak geniş kapsamlı veri çeşitliliği olması nedeniyle geleneksel öğrenme yöntemleri güvenilir olmamaktadır ancak derin öğrenme tabanlı yöntemler bu görev için potansiyellerini göstermiş ve literatürde hastalıkların tespiti için çeşitli çalışmalar sunulmuştur. Sınıflandırma problemlerinde kullanılan derin öğrenme modelleri, özellikle evrişimli sinir ağları diğer güncel öğrenme tabanlı olmayan tekniklerle karşılaştırıldığında tıbbi görüntü sınıflandırma görevlerinde yüksek performans verdiği kanıtlamıştır. Çalışmada da yer alan sınıflandırılma problemi için evrişimli sinir ağ modeli kullanan lokaliteye duyarlı görüntü sınıflandırma ve görüntüde nesne tespitine yönelik bir yaklaşım sunulmuştur.

Medikal görüntüler rutin klinik uygulamalarda yaygın olarak kullanılmakta ve bu görüntülerin analiz edilmesi, yorumlanması ve bunlara bağlı olarak tetkik ve teşhis aşamaları uzman hekimler ve radyologlar tarafından yapılmaktadır. Çalışılan

görüntülerle ilgili bulguları anlatmak için yapılan çalışmalarda incelenen ve çalışmada da ele alınan kanser türü hakkında metinsel radyoloji raporları yazılmaktadır. Bu tür raporların yazılması bazı durumlarda örnek olarak daha az deneyimli radyologlar ve klinisyenler veya merkezi olmayan sağlık hizmeti veren kurumlarda personel deneyim ve sağlık donanım kapasitelerinin sınırlı olduğu durumlarda zor olabilmektedir. Ek olarak, uzman radyologlar ve klinisyenler zaman kısıtının ve hasta yoğunluğunun fazla olduğu durumlar için rapor oluşturabilmek zaman alıcı veya hata payı yüksek sonuçlar doğurabilmektedir. Buna bağlı olarak, tıbbi görüntülemelerde yapay zekanın kullanımı radyolog veya klinisyenlerin yerini almaktan ziyade yükü ve tekrarlayan ve tekdüze görevlerden gelen dikkati dağıtmayı azaltmada işbirlikçi bir ortam olarak hizmet vermesi amaçlanmıştır.

Klinik karar destek sistemleri için derin öğrenme modellerinin eğitimi çoğunlukla zaman alan ve ciddi ölçüde insan çabası gerektiren büyük miktarda verinin (patolojik veriler, radyoloji görüntüler) sistematik bir şekilde toplanmasını gerektirir. Normal koularda tıbbi veriler, vakaya özel olarak dikkatli bir şekilde toplanıyor olsa da, derin öğrenme sistemlerinde ihtiyaç duyulan verinin doğru (beklenen) işlevselliğini bozabilecek birçok etken mevcuttur. Toplanan veriler araçsal ve çevresel gürültülerden etkilenebilmektedir, örnek olarak yüksek çözünürlüklü tıbbi görüntüler elde etmek için MRI gibi yöntemler harekete karşı oldukça hassastır. Hastanın baş pozisyonu veya solunumun hareketi bile ortaya çıkan görüntüde istenmeyen bozukluklara neden olabilmekte, buna bağlı olarak yanlış tanı riskini artırabilmektedir. Çalışmada görüntü verileri ön işleme adımıyla modeli etkiyebilecek bozuklukta görüntüler radyolog eşliğinde elenmiştir. Yapay zeka destekli sistemlerin klinik kullanılabilirliği için veriye dayalı sağlık hizmetlerinin geliştirilmesine bağlı olduğu ortaya çıkmaktadır.

Model sonuçlarında doğruluk, kesinlik, geri çağırma ve fl-ölçümü gibi performans metrikleriyle yüksek performans sonuçlarına ulaşılmış olsa da çıktıya ulaşma süreci literatürde de kara kutu (black box) sorunu veya açıklanabilirlik farklı bir alan olarak yer almaktadır. Bir sinir ağı modeli oluşturmada kullanılan matematik basit olmasına rağmen, çıktıya nasıl ulaşma süreci son derece karmaşıktır. Derin öğrenme modelleri,

girdi olarak çok büyük miktarda veri ile model oluşturulmaktadır ve tahmine dayalı modeller oluşturur ve sistemin teknik ve mantıksal temellerini açıklamak zordur veya çoğu zaman imkansızdır. Derin modellerini özellikle de evrişimli sinir ağlarının açıklanabilirliği için belirginlik haritalarının kullanılmasıyla sağlanması mümkün olabilmektedir. Fakat çalışmada da yer alan sağlık uygulamalarında kullanılan derin öğrenme sistemlerinin yorumlanması özel bir araştırma konusu olarak yer almaktadır.

Mamografi ve ultrason görüntüleme tekniklerinin her ikisinde de sınırlı duyarlılık ve özgüllük vardır, lezyonları tanımlamada ve özellikle yoğun meme varlığında kısmen çözülebilen sınırlamalar yer almaktadır. Tüm bu görüntüleme araçlarının kısıtları nedeniyle kesin bir teşhis koyabilmek için hastalara genellikle ağırlı ve maliyetli biyopsi prosedürleri uygulanmaktadır. Çıplak gözle görülemeyen ve dolayısıyla önemli ölçüde görüntü özelliklerini vurgulayan tıbbi görüntüleme yöntemleri tıbbi görüntülemenin öngörücü potansiyelini artırmaktadır. Bu çalışmada Neoadjuvan kemoterapi (NAC) sonrasında patolojik komplet yanıt alınabilmiş ve istenilen sonuç alınamamış hasta patolojik verileri yapay zeka uygulaması için veri seti olarak kullanılmıştır. Yapay zeka derin öğrenme modellerinden CNN (Convolutional Neural Network) algoritması ile model oluşturulup modelin sisteme sunulan yeni bir veride tahminleme başarımı ortaya koyulmuş ve yeni verilerle modelin geliştirilmesi sağlanması hedeflenmektedir. Araştırmada, patolojik verilerin ayrıntılı analizini üreten bir ara yüzle birleştirilerek doktorların araştırmalarını kolaylaştırması hedeflenmiştir.

Ek olarak, sağlık sektöründe sıklıkla kullanılan MRI görüntüleri aracılığıyla tümör tespiti için CNN ve VGG tabanlı önerilen modellerin sınıflandırmada performansları değerlendirilmiştir. Evrişimli katman sayısı, veri seti kalitesi, dönem sayısı eğitim sırasında modelin başarısını etkileyebilecek ana kriterler arasında olabilir. Eğitim setinde hasta örnek sayısı sınırlı olabilir ve bu durum aşırı öğrenmeye neden olabilir. Bu gibi durumlar için önceden eğitilmiş bir mimariye sahip olan VGG tabanlı model ile sınırlı sayıda görüntü ile daha iyi sonuçların alınabileceği gözlemlenmiştir. Sonuç olarak, önceden eğitilmiş VGG tabanlı modellerin, farklı özelliklere sahip nesnelerle eğitilmiş olsalar bile, veri toplamının sınırlı olduğu sağlık alanında uygulanabilirliğinin yüksek olduğu gözlemlenmiştir. Eğitim sırasında

öğrenilen özelliklerin farklı modeller üzerinde yüksek doğrulukla aktarılabildiği ve bu tür modelleri sağlık alanındaki sınıflandırma problemlerinde uygulanabilir bir seçenek haline getirdiği gözlemlenmiştir.

Nesneye yönelik algılama son yıllarda gelişime açık alanlar arasında yer almakta ve buna bağlı olarak karmaşık senaryoların yer aldığı sağlık alanında da uygulanabilirliği son yıllardaki literatür çalışmalarında sıklıkla görülmektedir. Sunulan nesne algılama çalışmalarında doğruluk oranları önemli bir metrik olarak karşımıza çıkmış olsa da gerçek zamanlı sistemlerde ve uygulama alanlarında hız da ikincil önemli bir metrik olarak değerlendirilmektedir. Bu nedenle gelecek çalışmalarda doğruluk ve hız arasındaki ilişkili modern sonuçları elde etmede önemli bir kriter olarak yer almaktadır. Güçlü özellik temsili gücü sunabildiğinden derin sinir ağlarından CNN modelleri temel alınarak oluşturulan nesne algılama metotlarında iki temel mimari kullanılmaktadır. İlki öncelikle nesne konumlandırma ve sonrasında sınıflandırma işlemi ile iki aşamalı bir yöntem ve ikincil yöntem olarak doğrudan konumlandıran ve sınıflandıran yöntemlerden olan ve çalışmada önerilen YOLO modeli ile algılama hızı daha yüksek bir sonuç elde edilmiş olur. Oluşturulan nesne tespiti modelinde elde edilen ağırlık modeli ve uygulanabilirliği bir saniye altında sonuç üreterek klinik çalışma alanlarında önemli bir kriter olan süre darboğazı için çözüm alternatifi sunabilmektedir.

Önerilen sınıflandırma modellerinin değerlendirilmesinde ve oluşturulan modelin ne kadar etkili olduğunun ölçülmesinde farklı performans metrikleri kullanılmaktadır. Oluşturulan modelin tahminleme başarımının test edilmesinde, sınıflandırma yöntemlerinde sıklıkla kullanılan metotlarla ölçümleme ve doğrulama işlemleri gerçekleştirilebilmektedir. Bu metotlar arasında ROC eğrisi hesaplama, Jaccard benzerlik katsayısı skoru, Hamming loss değeri, Matthews korelasyon katsayısı ve karışıklık matrisi sıklıkla tercih edilen yöntemler arasındadır. Çalışmada sunulan model başarımının değerlendirme kriteri olarak karışıklık matrisi kullanılarak ele alınmış, farklı yöntemler ile ölçülmesi çalışmanın araştırmaya açık alanları olarak yer almaktadır.

Çok ölçekli nesne algılama bu alanda zorlu görevler arasında yer almaktadır, çalışmada ele alınan radyolojik MR görüntülerinde küçük lezyonlar nesneleri içeren görüntü verileri bulunmaktadır. Evrişimli sinir ağı hiyerarşik bir yapıdadır ve her katmanda görüntü özellik haritası oluşturulur buna bağlı olarak özellik haritasında temsil edilen anlamsal bilgi farklıdır ve özellik haritalarının son katmanında bir nesne sınıflandır gerçekleştirilir. Buna bağlı olarak nesne sınırlayıcı kutlu oluşturulur. Sağlık görüntü verilerinde çok ölçeklilik sıklıkla karşılaşılan bir problem türü olarak karşılaşılmaktadır. Son evrişim katmanında çıkarılan küçük nesne özelliği kaybı gelecek çalışmalarda geliştirilmesi gereken bir araştırma alanı olarak yer almaktadır.

Çalışmada kullanılan veriler etik kurul iznine bağlı olarak işlenen spesifik bir hasta grubuna özel olarak tutulan görüntü ve sayısal verilerden oluşmaktadır. İşlenen verilerin bütünlüğünün korunması, veri sürekliliğinin sağlanabilmesi için ortak bir bilişim sistemi oluşturulmuş olsa da spesifik bir hastalığa özgü verilerin depolanıp standardize haline getirilmesi geliştirilmeye açık bir alan olmaktadır.

KAYNAKLAR

- A comprehensive guide to convolutional neural networks, <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, Eriřim Tarihi: 2022-05-26.
- A gentle introduction to dropout for regularizing deep neural networks, <https://machinelearningmastery.com/dropout-for-regularizing-deep-neural-networks/>, Eriřim Tarihi: 2022-05-26.
- A gentle introduction to object recognition with deep learning, <https://machinelearningmastery.com/object-recognition-with-deep-learning/>, Eriřim Tarihi: 2022-05-26.
- A gentle introduction to sigmoid function, <https://machinelearningmastery.com/a-gentle-introduction-to-sigmoid-function/>, Eriřim Tarihi: 2022-05-26.
- Abbasov, A. 2019. Lokal ileri meme kanserli hastalarda neoadjuvan kemoterapi sonrasında Pd-1, Tigit, Lag-3, Tim-3 gibi ümmün kontrol mekanizma resptör ekspresyonlarının akan hücre ölçerle araştırılması. İstanbul Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Activation functions in neural networks, <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>, Eriřim Tarihi: 2022-05-26.
- Activation functions, https://cheatsheet.readthedocs.io/en/latest/activation_functions.html, Eriřim Tarihi: 2022-05-26.
- Agrawal, T., & Choudhary, P. 2022. Segmentation and classification on chest radiography: a systematic survey. The Visual Computer, 1-39.
- Ak, N. 2016. Meme kanserinde neoadjuvan kemoterapi yanıtını predikte eden patolojik faktörler. İstanbul Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Aloysius, N., Geetha, M. 2017. A review on deep convolutional neural networks. 2017 International Conference on Communication and Signal Processing (ICCSP) içinde (0588–0592). IEEE. doi:10.1109/ICCSP.2017.8286426
- Amin, R., Al Ghamdi, M. A., Almotiri, S. H., & Alruily, M. 2021. Healthcare Techniques Through Deep Learning: Issues, Challenges and Opportunities.
- Anwar, S. M., Majid, M., Qayyum, A., Awais, M., Alnowami, M., & Khan, M. K. 2018. Medical image analysis using convolutional neural networks: a review. Journal of medical systems, 42(11), 1-13.

- Ayar, Y. 2021. Triple negatif ve her2 pozitif adjuvan veya neoadjuvan kemoterapi alan meme kanseri hastalarının klinikopatolojik özelliklerin değerlendirilmesi. Hacettepe Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Bahar, Z. 2021. Neoadjuvan kemoterapi almış meme kanserli hastalarda tedavi yanıtının tanı anındaki görüntüleme ve patoloji parametreleri ile tahmini. Marmara Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Baranwal, S. K., Jaiswal, K., Vaibhav, K., Kumar, A. ve Srikantaswamy, R. 2020. Performance analysis of Brain Tumour Image Classification using CNN and SVM. Proceedings of the 2nd International Conference on Inventive Research in Computing Applications, ICIRCA 2020, 537–542. doi:10.1109/ICIRCA48905.2020.9183023
- Barlow, W. E. 2002. Performance of Diagnostic Mammography for Women With Signs or Symptoms of Breast Cancer. CancerSpectrum Knowledge Environment, 94(15), 1151–1159. doi:10.1093/jnci/94.15.1151
- Baskar, P., Joseph, M. A., Narayanan, N., & Loya, R. B. 2013. Experimental investigation of oxygen enrichment on performance of twin cylinder diesel engine with variation of injection pressure. In 2013 International Conference on Energy Efficient Technologies for Sustainability, 682-687.
- Belhaouari, S. B. ve Islam, A. 2021. Deep Learning in Healthcare. Lecture Notes in Bioengineering. doi:10.1007/978-3-030-67303-1_13
- Browne, M. ve Ghidary, S. S. 2003. Convolutional Neural Networks for Image Processing: An Application in Robot Vision. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2903, 641–652. doi:10.1007/978-3-540-24581-0_55
- Carata, S., Mihaescu, R., Barnoviciu, E., Chindea, M., Ghenescu, M. ve Ghenescu, V. 2019. Complete Visualisation, Network Modeling and Training, Web Based Tool, for the Yolo Deep Neural Network Model in the Darknet Framework. Proceedings - 2019 IEEE 15th International Conference on Intelligent Computer Communication and Processing, ICCP 2019, 517–523. doi:10.1109/ICCP48234.2019.8959758
- Chai, J., Zeng, H., Li, A. ve Ngai, E. W. T. 2021. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. Machine Learning with Applications, 6, 100134. doi:10.1016/J.MLWA.2021.100134
- Charfare, H., Limongelli, S. ve Purushotham, A. D. 2005. Neoadjuvant chemotherapy in breast cancer. British Journal of Surgery, 92(1), 14–23. doi:10.1002/bjs.4840
- Chen, Y., Goorden, M. C., Beekman, F. J. ve Du, J. 2018. Understanding of Object Detection Based on CNN Family and YOLO. Journal of Physics: Conference Series, 1004(1), 012029. doi:10.1088/1742-6596/1004/1/012029
- Chetty, G., Singh, M., & White, M. 2019. Automatic brain image analysis based on multimodal deep learning scheme. In 2019 International Conference on Machine Learning and Data Engineering (iCMLDE); 97-100.
- Chollet, F. 2021. Deep learning with Python. Simon and Schuster.

- Christe, A., Stathopoulou, T., Mougiakakou, S. G., Christodoulidis, S., & Ebner, L. 2020. Automated Diagnosis of Pulmonary Fibrosis Using Deep Learning and CT Images. In A102. ILD DIAGNOSIS AND MONITORING (2558-2558). American Thoracic Society.
- Cicero, M., Bilbily, A., Colak, E., Dowdell, T., Gray, B., Perampaladas, K., & Barfett, J. 2017. Training and validating a deep convolutional neural network for computer-aided detection and classification of abnormalities on frontal chest radiographs. *Investigative radiology*, 52(5), 281-287.
- Coding Neural Network, <https://towardsdatascience.com/coding-neural-network-forward-propagation-and-backpropagation-ccf8cf369f76>, Erişim Tarihi: 2022-05-29.
- Correa, M., Zimic, M., Barrientos, F., Barrientos, R., Román-Gonzalez, A., Pajuelo, M. J., ... & Oberhelman, R. 2018. Automatic classification of pediatric pneumonia based on lung ultrasound pattern recognition. *PloS one*, 13(12).
- Cuzick, J., Warwick, J., Pinney, E., Warren, R. M. L. ve Duffy, S. W. 2004. Tamoxifen and Breast Density in Women at Increased Risk of Breast Cancer. *JNCI Journal of the National Cancer Institute*, 96(8), 621–628. doi:10.1093/jnci/djh106
- Day, N., Williams, D. ve Khaw, K. 1989. Breast cancer screening programmes: the development of a monitoring and evaluation system. *British Journal of Cancer*, 59(6), 954–958. doi:10.1038/bjc.1989.203
- Demircioglu, S. 2013. Neoadjuvan kemoterapi alan meme kanserli hastalarda NF-KB, survivin ve KI-67 ekspresyonlarının değerlendirilmesi. Necmettin Erbakan Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Ding, B., Qian, H. ve Zhou, J. 2018. Activation functions and their characteristics in deep neural networks. 2018 Chinese Control And Decision Conference (CCDC) (1836–1841). IEEE. doi:10.1109/CCDC.2018.8407425
- Dogo, E. M., Afolabi, O. J., Nwulu, N. I., Twala, B. ve Aigbavboa, C. O. 2018. A Comparative Analysis of Gradient Descent-Based Optimization Algorithms on Convolutional Neural Networks. 2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS) (92–99). IEEE. doi:10.1109/CTEMS.2018.8769211
- Doughty, J. C., McCarter, D. H. A., Kane, E., Reid, A. W., Cooke, T. G. ve McArdle, C. S. 2005. Anatomical basis of intra-arterial chemotherapy for patients with locally advanced breast cancer. *British Journal of Surgery*, 83(8), 1128–1130. doi:10.1002/bjs.1800830830
- Elmore, J. G. 2005. Screening for Breast Cancer. *JAMA*, 293(10), 1245. doi:10.1001/jama.293.10.1245
- Ezhilarasi, R. ve Varalakshmi, P. 2019. Tumor detection in the brain using faster R-CNN. *Proceedings of the International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)*, I-SMAC 2018, 388–392. doi:10.1109/I-SMAC.2018.8653705

- Fang, W., Wang, L. ve Ren, P. 2020. Tinier-YOLO: A Real-Time Object Detection Method for Constrained Environments. *IEEE Access*, 8, 1935–1944. doi:10.1109/ACCESS.2019.2961959
- Gabruseva, T., Poplavskiy, D., & Kalinin, A. 2020. Deep learning for automatic pneumonia detection. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 350-351.
- Geçer, M. F. 2014. Neoadjuvan kemoterapi uygulanan meme kanserli hastalarda PET/BT ile tedavi yanıtının değerlendirilmesi. İstanbul Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Géron, A. 2019. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, Inc.
- Ghassemi, N., Shoeibi, A., Rouhani, M., & Hosseini-Nejad, H. 2019. Epileptic seizures detection in EEG signals using TQWT and ensemble learning. In *2019 9th International Conference on Computer and Knowledge Engineering (ICCKE)*, 403-408.
- Giannini, V., Defeudis, A., Rosati, S., Cappello, G., Vassallo, L., Mazzetti, S., ... & Balestra, G. 2020. Deep learning to segment liver metastases on CT images: impact on a radiomics method to predict response to chemotherapy. In *2020 IEEE International Symposium on Medical Measurements and Applications* 1-5.
- Giordano, S. H., Buzdar, A. U. ve Hortobagyi, G. N. 2002. Breast Cancer in Men. *Annals of Internal Medicine*, 137(8), 678. doi:10.7326/0003-4819-137-8-200210150-00013
- Global Cancer Observatory (GCO), <https://gco.iarc.fr/>, Erişim Tarihi: 2022-05-29.
- Guide to different padding methods for CNN models, <https://analyticsindiamag.com/guide-to-different-padding-methods-for-cnn-models/>, Erişim Tarihi: 2022-05-29.
- Gullo, R. L., Eskreis-Winkler, S., Morris, E. A., & Pinker, K. 2020. Machine learning with multiparametric magnetic resonance imaging of the breast for early prediction of response to neoadjuvant chemotherapy. *The Breast*, 49, 115-122.
- Harbeck, N., Penault-Llorca, F., Cortes, J., Gnant, M., Houssami, N., Poortmans, P., ... Cardoso, F. 2019. Breast cancer. *Nature Reviews Disease Primers* 2019 5:1, 5(1), 1–31. doi:10.1038/s41572-019-0111-2
- Hemanth, G., Janardhan, M. ve Sujihelen, L. 2019. Design and implementing brain tumor detection using machine learning approach. *Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019*, 2019, 1289–1294. doi:10.1109/ICOEI.2019.8862553
- Herent, P., Schmauch, B., Jehanno, P., Dehaene, O., Saillard, C., Balleyguier, C., ... & Jégou, S. 2019. Detection and characterization of MRI breast lesions using deep learning. *Diagnostic and interventional imaging*, 100(4), 219-225.
- How to choose an activation function for deep learning. <https://machinelearningmastery.com/choose-an-activation-function-for-deep-learning>, Erişim Tarihi: 2022-05-29.

- How to choose best activation function for you.
<https://medium.com/@siddharthzs/how-to-choose-best-activation-function-for-you-model-8af90557245b>, Erişim Tarihi: 2022-05-29.
- Hwang, E. J., Park, S., Jin, K. N., Im Kim, J., Choi, S. Y., Lee, J. H., ... & Park, C. M. 2019. Development and validation of a deep learning–based automated detection algorithm for major thoracic diseases on chest radiographs. *JAMA network open*, 2(3).
- Ian Goodfellow, Yoshua Bengio, A. C. 2017. *Deep lLearning. Genetic Programming and Evolvable Machines* (C. 19). Springer US.
- İpci, Ö. 2014. Neoadjuvan kemoterapi uygulanan meme kanserli hastalarda prediktif faktörlerin yeri. Mustafa Kemal Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Jaiswal, A. K., Tiwari, P., Kumar, S., Gupta, D., Khanna, A., & Rodrigues, J. J. 2019. Identifying pneumonia in chest X-rays: a deep learning approach. *Measurement*, 145, 511-518.
- Jemimma, T. A. ve Jacob Vetharaj, Y. 2018. Watershed algorithm based DAPP features for brain tumor segmentation and classification. *Proceedings of the International Conference on Smart Systems and Inventive Technology, ICSSIT 2018*, 155–158. doi:10.1109/ICSSIT.2018.8748436
- Jiang, T., Gradus, J. L. ve Rosellini, A. J. 2020. Supervised Machine Learning: A Brief Primer. *Behavior Therapy*, 51(5), 675–687. doi:10.1016/j.beth.2020.05.002
- Karataş, A. F. 2017. Meme kanseri hastalarında neoadjuvan kemoterapiye yanıtın değerlendirilmesinde meme Mrg ve Pet-ct yöntemlerinin karşılaştırılması. Manisa Celal Bayar Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Khan, A., Sohail, A., Zahoor, U. ve Qureshi, A. S. 2019. A Survey of the Recent Architectures of Deep Convolutional Neural Networks. *Artificial Intelligence Review*, 53(8), 5455–5516. doi:10.1007/s10462-020-09825-6
- Kocer, B. 2021. The Relationship between Mammographic Density and Factors Affecting Breast Cancer Risk. *Sisli Etfal Hastanesi Tıp Bulteni / The Medical Bulletin of Sisli Hospital*. doi:10.14744/semb.2021.30771
- Kuhl, C. K. 2000. MRI of breast tumors. *European Radiology*, 10(1), 46–58. doi:10.1007/s003300050006
- Kurnianingsih, Allehaibi, K. H. S., Nugroho, L. E., Widyawan, Lazuardi, L., Prabuono, A. S. ve Mantoro, T. 2019. Segmentation and Classification of Cervical Cells Using Deep Learning. *IEEE Access*, 7, 116925–116941. doi:10.1109/ACCESS.2019.2936017
- Lee, S. G., Orel, S. G., Woo, I. J., Cruz-Jove, E., Putt, M. E., Solin, L. J., ... Schnall, M. D. 2003. MR Imaging Screening of the Contralateral Breast in Patients with Newly Diagnosed Breast Cancer: Preliminary Results. *Radiology*, 226(3), 773–778. doi:10.1148/radiol.2263020041
- Lehman, C. D., Blume, J. D., Weatherall, P., Thickman, D., Hylton, N., Warner, E., ... Schnall, M. 2005. Screening women at high risk for breast cancer with mammography and magnetic resonance imaging. *Cancer*, 103(9), 1898–1905. doi:10.1002/cncr.20971

- LeNet-5 Tutorial: Architecture, features and importance
<https://www.analyticssteps.com/blogs/lenet-5-tutorial-architecture-features-and-importance>, Erişim Tarihi: 2022-05-29.
- Madhupriya, G., Guru Narayanan, M., Praveen, S. ve Nivetha, B. 2019. Brain tumor segmentation with deep learning technique. *Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019*, 2019-April, 758–763. doi:10.1109/ICOEI.2019.8862575
- Madigan, M. P., Ziegler, R. G., Benichou, J., Byrne, C. ve Hoover, R. N. 1995. Proportion of Breast Cancer Cases in the United States Explained by Well-Established Risk Factors. *JNCI Journal of the National Cancer Institute*, 87(22), 1681–1685. doi:10.1093/jnci/87.22.1681
- Martin, A. M. ve Weber, B. L. 2000. Genetic and hormonal risk factors in breast cancer. *Journal of the National Cancer Institute*, 92(14), 1126–1135. doi:10.1093/jnci/92.14.1126
- Maruyama, T., Hayashi, N., Sato, Y., Hyuga, S., Wakayama, Y., Watanabe, H., ... & Ogura, T. 2018. Comparison of medical image classification accuracy among three machine learning methods. *Journal of X-ray Science and Technology*, 26(6), 885-893.
- Mattmann, C. 2020. *Machine Learning with TensorFlow*, Second Edition.
- McLelland, R., Hendrick, R. E., Zininger, M. D. ve Wilcox, P. A. 1991. The American College of Radiology Mammography Accreditation Program. *American Journal of Roentgenology*, 157(3), 473–479. doi:10.2214/ajr.157.3.1872231
- Moghadas-Dastjerdi, H., Sannachi, L., Wright, F. C., Gandhi, S., Trudeau, M. E., Sadeghi-Naini, A., & Czarnota, G. J. 2021. Prediction of chemotherapy response in breast cancer patients at pre-treatment using second derivative texture of CT images and machine learning. *Translational Oncology*, 14(10), 101183.
- Mojabi, P., Khoshdel, V., & Lovetri, J. 2020. Tissue-type classification with uncertainty quantification of microwave and ultrasound breast imaging: A deep learning approach. *IEEE Access*, 8, 182092-182104.
- Mouhssine, R., Otman, A. ve Khatir, E. 2020. Performance Analysis of Machine Learning Techniques for Smart Agriculture: Comparison of Supervised Classification Approaches. *International Journal of Advanced Computer Science and Applications*, 11(3). doi:10.14569/IJACSA.2020.0110377
- Nguyen, K., Fookes, C., Ross, A. ve Sridharan, S. 2017. Iris Recognition with Off-the-Shelf CNN Features: A Deep Learning Perspective. *IEEE Access*, 6, 18848–18855. doi:10.1109/ACCESS.2017.2784352
- Öner, G. 2018. Neoadjuvan kemoterapi alan lokal ileri meme kanserli hastalarda Pdl-1 ekspresyonunun prediktif ve prognostik önemi. *İstanbul Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi*.
- Ongsulee, P. 2018. Artificial intelligence, machine learning and deep learning. *International Conference on ICT and Knowledge Engineering*, 1–6. doi:10.1109/ICTKE.2017.8259629

- Orel, S. G. ve Schnall, M. D. 2001. MR Imaging of the Breast for the Detection, Diagnosis, and Staging of Breast Cancer. *Radiology*, 220(1), 13–30. doi:10.1148/radiology.220.1.r01jl3113
- Özdemir, Ş., & Kılınç, D. 2019. *Geleceğin meslekleri*. İstanbul: Abaküs Yayınları.
- Özkan, Y. 2021. *Uygulamalı Derin Öğrenme*. İstanbul: Papatya Bilim Yayınları.
- Pak, M. ve Kim, S. 2017. A review of deep learning in image recognition. 2017 4th International Conference on Computer Applications and Information Processing Technology (CAIPT), 1–3. doi:10.1109/CAIPT.2017.8320684
- Pang, T., Wong, J. H. D., Ng, W. L., & Chan, C. S. 2020. Deep learning radiomics in breast cancer with different modalities: Overview and future. *Expert Systems with Applications*, 158, 113501.
- Pap, K., & Hrnčić, M. 2019. Implementation of intelligent model for pneumonia detection. *Tehnički glasnik*, 13(4), 315-322.
- Pathak, A. R., Pandey, M. ve Rautaray, S. 2018. Application of Deep Learning for Object Detection. *Procedia Computer Science*, 132, 1706–1717. doi:10.1016/J.PROCS.2018.05.144
- Pitale, R., Kale, H., Kshirsagar, S., & Rajput, H. 2021. A Schematic Review on Applications of Deep Learning and Computer Vision. In 2021 Asian Conference on Innovation in Technology (ASIANCON), 1-6.
- Prakash, R. M. ve Kumari, R. S. S. 2019. Classification of MR brain images for detection of tumor with transfer learning from pre-trained CNN models. 2019 International Conference on Wireless Communications, Signal Processing and Networking, WiSPNET 2019, 508–511. doi:10.1109/WISPNET45539.2019.9032811
- Principal component analysis explained visually. <https://setosa.io/ev/principal-component-analysis/>, Erişim Tarihi: 2022-05-29.
- Rahimpour, M., Goffin, K. ve Koole, M. 2019. Convolutional Neural Networks for Brain Tumor Segmentation Using Different Sets of MRI Sequences. 2019 IEEE Nuclear Science Symposium and Medical Imaging Conference, NSS/MIC 2019. doi:10.1109/NSS/MIC42101.2019.9059769
- Rajaraman, S., Candemir, S., Kim, I., Thoma, G., & Antani, S. 2018. Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. *Applied Sciences*, 8(10), 1715.
- Rajpurkar, P., Irvin, J., Ball, R. L., Zhu, K., Yang, B., Mehta, H., ... & Lungren, M. P. 2018. Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLoS medicine*, 15(11).
- Ramírez, E., Sánchez, C., & Gil, D. 2019. Localizing Pulmonary Lesions Using Fuzzy Deep Learning. In 2019 21st International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC), 290-294.
- Rashidi, H. H., Tran, N. K., Betts, E. V., Howell, L. P. ve Green, R. 2019. Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods. *Academic Pathology*, 6. doi:10.1177/2374289519873088

- Razzak, M. I., Imran, M. ve Xu, G. 2019. Efficient Brain Tumor Segmentation with Multiscale Two-Pathway-Group Conventional Neural Networks. *IEEE Journal of Biomedical and Health Informatics*, 23(5), 1911–1919. doi:10.1109/JBHI.2018.2874033
- Razzak, M. I., Naz, S., & Zaib, A. 2018. Deep learning for medical image processing: Overview, challenges and the future. *Classification in BioApps*, 323-350.
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A. 2015. You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-December, 779–788. doi:10.48550/arxiv.1506.02640
- Ruder, S. 2016. An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Sakallı, M. 2011. Meme kanserinin neoadjuvan kemoterapisinde taksanların etkinliğinin araştırılması. *Uludağ Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi*.
- Salin, E. D. ve Winston, P. H. 1992. Machine Learning and Artificial Intelligence an Introduction. *Analytical Chemistry* (C. 64). doi:10.1021/ac00025a742
- Shafiee, M. J., Chywl, B., Li, F. ve Wong, A. 2017. Fast YOLO: A Fast You Only Look Once System for Real-time Embedded Object Detection in Video. *Journal of Computational Vision and Imaging Systems*, 3(1). doi:10.48550/arxiv.1709.05943
- Sirazitdinov, I., Kholiavchenko, M., Mustafaev, T., Yixuan, Y., Kuleev, R., & Ibragimov, B. 2019. Deep neural network ensemble for pneumonia localization from a large-scale chest x-ray database. *Computers & electrical engineering*, 78, 388-399.
- Sırma, T. 2019. İleri evre over kanserlerinde neoadjuvan kemoterapi ile primer sitoredüksiyonun morbidite, mortalite, rekürrens zamanı ve sağkalım açısından karşılaştırılması. *Ankara Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi*.
- Smart, C. R., Byrne, C., Smith, R. A., Garfinkel, L., Letton, A. H., Dodd, G. D. ve Beahrs, O. H. 1997. Twenty-year follow-up of the breast cancers diagnosed during the Breast Cancer Detection Demonstration Project. *CA: A Cancer Journal for Clinicians*, 47(3), 134–149. doi:10.3322/canjclin.47.3.134
- Sobhaninia, Z., Rezaei, S., Karimi, N., Emami, A., & Samavi, S. 2020. Brain tumor segmentation by cascaded deep neural networks using multiple image scales. In *2020 28th Iranian Conference on Electrical Engineering (ICEE)*, 1-4.
- Softmax as activation function. <https://python-course.eu/machine-learning/softmax-as-activation-function.php>, Erişim Tarihi: 2022-05-29.
- Softmax function. <https://deeptai.org/machine-learning-glossary-and-terms/softmax-layer>, Erişim Tarihi: 2022-05-29.
- Somasundaram, S. ve Gobinath, R. 2019. Current Trends on Deep Learning Models for Brain Tumor Segmentation and Detection - A Review. *Proceedings of the International Conference on Machine Learning, Big Data, Cloud and Parallel Computing: Trends, Prespectives and Prospects, COMITCon 2019*, 217–221. doi:10.1109/COMITCON.2019.8862209

- Storm, H. H., Andersson, M., Boice, J. D., Blettner, M., Stovall, M., Mouridsen, H. T., ... Pedersen, M. 1992. Adjuvant Radiotherapy and Risk of Contralateral Breast Cancer. *JNCI Journal of the National Cancer Institute*, 84(16), 1245–1250. doi:10.1093/jnci/84.16.1245
- Suzuki, K. 2017. Overview of deep learning in medical imaging. *Radiological Physics and Technology*, 10(3), 257–273. doi:10.1007/s12194-017-0406-5
- Tabár, L., Dean, P. B., Kaufman, C. S., Duffy, S. W. ve Chen, H.-H. (2000). A New Era in the Diagnosis of Breast Cancer. *Surgical Oncology Clinics of North America*, 9(2), 233–277. doi:10.1016/S1055-3207(18)30153-4
- Tairi, H. 2020. Segmentation of medical images for the extraction of brain tumors: A comparative study between the Hidden Markov and Deep Learning approaches. In 2020 International Conference on Intelligent Systems and Computer Vision (ISCV), 1-5.
- Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning, 6105-6114.
- Targ, S., Almeida, D., & Lyman, K. 2016. Resnet in resnet: Generalizing residual architectures. arXiv preprint arXiv:1603.08029.
- Tesic, V., Kolaric, B., Znaor, A., Kuna, S. K. ve Brkljacic, B. 2013. Mammographic density and estimation of breast cancer risk in intermediate risk population. *The breast journal*, 19(1), 71–78. doi:10.1111/TBJ.12051
- Thrall, J. H., Li, X., Li, Q., Cruz, C., Do, S., Dreyer, K. ve Brink, J. 2018. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *Journal of the American College of Radiology*, 15(3), 504–508. doi:10.1016/j.jacr.2017.12.026
- Uyan, M. 2013. Meme kanserinde neoadjuvan kemoterapinin aksiller lenf nodu sayısı ve pozitifliğine etkisi. Ondokuz Mayıs Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Valero, V., Buzdar, A. U. ve Hortobagyi, G. N. 1996. Locally Advanced Breast Cancer. *The Oncologist*, 1(1–2), 8–17. doi:10.1634/theoncologist.
- Wikipedi, https://tr.wikipedia.org/wiki/Alan_Turing, Erişim Tarihi: 2022-05-29.
- Vinoth, R., Venkatesh, C. 2018. Segmentation and Detection of Tumor in MRI images Using CNN and SVM Classification. *Proc. IEEE Conference on Emerging Devices and Smart Systems, ICEDSS 2018*, 21–25. doi:10.1109/ICEDSS.2018.8544306
- WHO | World Health Organization. <https://www.who.int>, Erişim Tarihi: 2022-05-29.
- Wu, P., & Chang, Q. 2020. Brain tumor segmentation on multimodal 3D-MRI using deep learning method. In 2020 13th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), 635-639.
- Yarbaş, G. 2020. Metastatik olmayan luminal subtipli neoadjuvan kemoterapi alan meme kanseri tanili hastaların retrospektif değerlendirilmesi. Bursa Uludağ Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.

- Yaseen, Z. M., Tran, M. T., Kim, S., Bakhshpoori, T., Deo, R. C. 2018. Shear strength prediction of steel fiber reinforced concrete beam using hybrid intelligence models: A new approach. *Engineering Structures*, 177, 244–255. doi:10.1016/j.engstruct.2018.09.074
- Yıldız, R. S. 2017. Neoadjuvan kemoterapi alan meme kanserli hastalarda serum m30 ve m65 düzeylerinin klinik ve patolojik prognostik parametrelerle ilişkisi ve prediktif değeri. Bezmialem Vakıf Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Yılmaz, M. B. K. (2019). Neoadjuvan kemoterapi alan meme kanseri hastalarında mir216b ve mir134'ün ekspresyonlarının araştırılması. Sağlık Bilimleri Üniversitesi, Tıp Fakültesi, Uzmanlık Tezi.
- Yue, Z., Ma, L. ve Zhang, R. 2020. Comparison and Validation of Deep Learning Models for the Diagnosis of Pneumonia. *Computational Intelligence and Neuroscience*, 2020. doi:10.1155/2020/8876798
- Yurtsever, S. (2000). Kronik hastalıklarda yorgunluk ve hemşirelik bakımı. *CÜ Hemşirelik Yüksekokulu Dergisi*, 4(1), 16-20.
- Zhao, Z.-Q., Zheng, P., Xu, S.-T. ve Wu, X. 2019. Object Detection With Deep Learning: A Review. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3212–3232. doi:10.1109/TNNLS.2018.2876865
- Zheng, J., Lin, D., Gao, Z., Wang, S., He, M. ve Fan, J. 2020. Deep Learning Assisted Efficient AdaBoost Algorithm for Breast Cancer Detection and Early Diagnosis. *IEEE Access*, 8, 96946–96954. doi:10.1109/ACCESS.2020.2993536
- Zheng, J., Lin, D., Gao, Z., Wang, S., He, M., & Fan, J. 2020. Deep learning assisted efficient AdaBoost algorithm for breast cancer detection and early diagnosis. *IEEE Access*, 8, 96946-96954.

ÖZGEÇMİŞ

Adı Soyadı : Yasin KIRELLİ

ÖĞRENİM DURUMU

Derece	Eğitim Birimi	Mezuniyet Yılı
Doktora	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Endüstri Mühendisliği	Devam ediyor
Yüksek Lisans	İstanbul Ticaret Üniversitesi / Fen Bilimleri Enstitüsü / Bilgisayar Mühendisliği	2016
Lisans	Kocaeli Üniversitesi / Mühendislik Fakültesi / Bilgisayar Mühendisliği	2012
Lise	İlgın Anadolu Lisesi	2007

İŞ DENEYİMİ

Yıl	Yer	Görev
2020 - Halen	İstinye Üniversitesi	Araştırma Görevlisi
2019 - 2020	Digiturk	Veri Mühendisi
2015 - 2019	TRT World	Veri Mühendisi

YABANCI DİL

İngilizce

ESERLER

Uluslararası hakemli dergilerde yayınlanan makaleler (SCI & SSCI & Arts and Humanities)

Kirelli, Y. ve Arslankaya, S. (2020). Sentiment Analysis of Shared Tweets on Global Warming on Twitter with Data Mining Methods: A Case Study on Turkish Language. Computational Intelligence and Neuroscience, 2020. doi:10.1155/2020/1904172

Malidarre, R. B., Arslankaya, S., Nar, M., Kirelli, Y., Erdamar, I. Y. D., Karpuz, N., ... Malidarreh, P. B. (2022). Deep Learning Prediction for gamma-ray attenuation behavior of the KNN-LMN based lead-free ceramics. <https://doi.org/10.1680/jemmr.22.00012>, 11(2), 1–6. doi:10.1680/JEMMR.22.00012

Yazılan uluslararası kitaplar veya kitaplarda bölümler

Kirelli, Y., Arslankaya, S. ve Alcan, P. (2022). MRI Image Analysis with Deep Learning Methods in Brain Tumor Diagnosis. Lecture Notes in Mechanical Engineering, 35–42. doi:10.1007/978-981-16-7164-7_4

Ulusal hakemli dergilerde yayınlanan makaleler (TR Dizin)

Kirelli, Y., Arslankaya, S. ve Taha Zeren, M. (2020). Detection of Credit Card Fraud in E-Commerce Using Data Mining. European Journal of Science and Technology, 20(20), 522–529. doi:10.31590/EJOSAT.747399

Zeren, M., Kerem Aytulun, S. ve Kirelli, Y. (2020). Comparison of SSD and Faster R-CNN Algorithms to Detect the Airports with Data Set Which Obtained From Unmanned Aerial Vehicles and Satellite Images. European Journal of Science and Technology, 19(19), 643–658. doi:10.31590/EJOSAT.742789

Kirelli, Y. ve Özdemir, Ş. (2021). Sentiment Classification Performance Analysis Based on Glove Word Embedding. Sakarya University Journal of Science, 25(3), 639–646. doi:10.16984/aufenbilder.886583

Uluslararası bilimsel toplantılarda sunulan ve bildiri kitabında (Proceedings) basılan bildiriler

Özdemir, Ş., Çömlekçi, M., Kirelli, Y., Aydın, G., Tunçer, A., Kaya, F. ve Baydur, A. (2021). 13.Bölüm: Yapay Zekâ ve Engelli Bireyler: Veri Bazlı Sorunlar ve Önyargı. ENGELSİZ BİLİŞİM

Aydın, G., Kirelli, Y., Özdemir, Ş. ve Özuyar, P. G. (2021). The Concept of Artificial Intelligence-Based Sustainability on Biodiversity. 7. International Istanbul Scientific Research Congress (393–397).