

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



**MAMOGRAFİ GÖRÜNTÜLERİNİN DEĞERLENDİRİLMESİNDE
KULLANILAN YENİ BİR KARAR DESTEK SİSTEMİ
TASARIMI**

Ramazan ALİOĞLU

Doktora Tezi

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Elektrik Elektronik Mühendisliği Teknolojileri Programı

Kontrol ve Kumanda Sistemleri Bilim Dalı

OCAK 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik Elektronik Mühendisliği Anabilim Dalı
Elektrik Elektronik Mühendisliği Teknolojileri Programı

Doktora Tezi

MAMOGRAFİ GÖRÜNTÜLERİNİN DEĞERLENDİRİLMESİNDE KULLANILAN YENİ BİR KARAR DESTEK SİSTEMİ TASARIMI

Tez Yazarı
Ramazan ALİOĞLU

Danışman
Doç. Dr. Çetin GENÇER

OCAK 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik Elektronik Mühendisliği Anabilim Dalı
Elektrik Elektronik Mühendisliği Teknolojileri Programı

Doktora Tezi

Başlığı:	Mamografi Görüntülerinin Değerlendirilmesinde Kullanılan Yeni Bir Karar Destek Sistemi Tasarımı
Yazarı:	Ramazan ALİOĞLU
İlk Teslim Tarihi:	14.12.2021
Savunma Tarihi:	21.01.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Çetin GENÇER Fırat Üniversitesi, Teknoloji Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Mehmet GEDİKPINAR Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Prof. Dr. Abdulkadir ŞENGÜR Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Doç. Dr. Ömer Faruk ALÇİN Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Muzaffer ASLAN Bingöl Üniversitesi, Mühendislik Mimarlık Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Mamografi Görüntülerinin Değerlendirilmesinde Kullanılan Yeni Bir Karar Destek Sistemi Tasarımı” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

21.01.2022

Ramazan ALİOĞLU



ÖNSÖZ

Kadınlarda en fazla görülen kanser meme kanseri olup yüksek oranda ölümlere sebep olmaktadır. Ülkemizde kadınlarda görülen tüm kanser vakalarının yaklaşık %23,9' unu meme kanseri oluşturmaktadır. Meme kanseri ölümlerini azaltmak için en etkili yöntem erken teşhis ve tedavidir. Özel bir röntgen tekniği olan mamografi günümüzde meme kanserinin tanısı için kullanılan en etkili yöntemdir. Mamogramların yorumlanması deneyimli radyologlar tarafından yapılır. Ancak çeşitli faktörler, radyologlar tarafından mamogramların yanlış yorumlanmasına yol açabilir. Mamografi görüntüsünün eksik veya hatalı değerlendirilmesini en aza indirmek için BKDS (Bilgisayarlı Karar Destek Sistemi) üzerine birçok çalışma yapılmaktadır. Özellikle derin sinir ağlarının kullanıldığı bu çalışmalarda yeterli etiketlenmiş veriye ulaşmadaki kısıtlılığa değinilmektedir.

Henüz gelişmekte olan bu alana katkı sunmak amacıyla MIAS, DDSM, INBREAST ve Fethi Sekin Şehir Hastanesi (FSSH)'nden alınan mamografi görüntüleri ile daha geniş bir veri havuzu oluşturularak yeni bir BKDS tasarlanmasına ihtiyaç duyulmuştur.

Danışmanım Doç. Dr. Çetin GENCER' e rehberliği için teşekkürlerimi sunmak isterim. Ayrıca Prof. Dr. Abdulkadir ŞENGÜR, Prof. Dr. İbrahim TÜRKOĞLU'na tavsiye ve yardımları için teşekkür ederim. Fethi Sekin Şehir Hastanesi'nden temin edilen mamografi görüntüleri için bu çalışmada bilgilerini benimle paylaşan Uzman Radyolog Mustafa YILDIRIM' a da teşekkür ederim.

Son olarak aileme, sabrı ve cesaretlendirmesi ile tezime destek olduğu için minnettarım.

Çalışmalar Fırat Üniversitesi 04.02.2021 tarih ve 2021/02 -46 sayılı etik kurulu izni ile gerçekleştirilmiştir.

Ramazan ALİOĞLU
ELAZIĞ, 2022

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Literatür Araştırması.....	2
1.2. Çalışmanın Literatüre Katkısı.....	6
2. MEME YAPISI VE MEME KANSERİ.....	8
2.1. Meme Yapısı	8
2.2. Meme Kanseri	9
2.3. Mamografi	10
2.4. Bilgisayarlı Karar Destek Sistemi	12
3. MATERYAL VE METOT	14
3.1. Çalışmada Kullanılan Görüntülerin Temin Edildiği Kaynaklar	14
3.1.1. MIAS Veri Tabanından Alınan Mamografi Görüntüleri.....	14
3.1.2. DDSM Veri Tabanından Alınan Mamografi Görüntüleri	16
3.1.3. INBREAST Veri Tabanından Alınan Mamografi Görüntüleri	17
3.1.4. FSSH Veri Tabanından Alınan Mamografi Görüntüleri	18
3.2. Mamografi Görüntülerinin Gürültülerden Arındırılması	19
3.2.1. Görüntü Ön İşleme	20
3.2.2. Morfolojik Görüntü İşleme Yöntemleri	21
3.2.3. Görüntü Bölütleme	25
3.3. Öz nitelik Çıkarma	27
3.4. Derin Öğrenme	28
3.5. Sınıflandırma	35
3.5.1. Tam Bağlı Katman	36
3.5.2. Softmax Fonksiyonu	36
3.6. Çalışmada Kullanılan Derin Öğrenme Modelleri	37
3.6.1. AlexNet	37
3.6.2. GoogLeNet.....	38
3.6.3. MKESAS.....	41
4. DENEYSEL ÇALIŞMALAR	43
4.1. AlexNet ESA Modeli Eğitim Sonuçları.....	44
4.2. GoogLeNet ESA Modeli Eğitim Sonuçları	48
4.3. MKESAS Modeli Eğitim Sonuçları	51
4.4. MKESAS Modelinin Daha Az Sayıda Veri ile Eğitilmesi	56
4.5. Uygulamada Kullanılan ESA Modellerinin Karşılaştırılması	58

5. TARTIřMA.....	60
6. SONUÇ VE ÖNERİLER.....	63
KAYNAKLAR.....	66
ÖZGEÇMİř	



ÖZET

Mamografi Görüntülerinin Değerlendirilmesinde Kullanılan Yeni Bir Karar Destek Sistemi Tasarımı

Ramazan ALİOĞLU

Doktora Tezi

FIRAT ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Teknolojileri Programı

Ocak 2022, Sayfa: xxii + 72

Meme kanseri, kadınlarda kansere bağlı ölümlerde ilk sırada yer almaktadır. Dünya genelinde kadınların yakalandığı kanser hastalıklarının yaklaşık %24,5'ini, ülkemizde ise %23,9'unu meme kanseri oluşturmaktadır. Hastalığın erken teşhisi, tedavi için en hayati adımdır.

Mamografi cihazı ile elde edilen radyografik görüntüler, meme kanserinin erken teşhisinde en sık kullanılan yöntemlerden biridir. Fakat çekimlerde kullanılan teknoloji, radyoloğun tecrübesi, yoğunluk, meme yapısı, çekim esnasındaki hatalar gibi birçok nedenden kaynaklı teşhisle ilgili yanlış değerlendirmeler yapılabilmektedir. Böyle durumlarda teşhisle ilgili çelişkiye düşülmekte, ikinci bir uzman görüşüne ihtiyaç duyulmaktadır.

Günümüzde mamografi görüntüleri ile daha doğru karar vermeye yardımcı olacak Bilgisayarlı Karar Destek Sistemi (BKDS) üzerinde birçok çalışma yapılmaktadır. Bu çalışmada da meme kanserinin tanısı ve teşhisinde radyoloji uzmanına ikinci bir görüş sunarak yardımcı olabilecek bir BKDS geliştirilmiştir. Son kararın radyoloji uzmanı tarafından verileceği bu sistem ile insan kaynaklı hata oranının azaltılması amaçlanmaktadır.

Günümüzde görüntü işleme çalışmalarında özellikle geleneksel yöntemlerden uzaklaşılarak derin mimarilerde çalışmaların yoğunlaştığı görülmektedir. Derin öğrenme yöntemleri özellikle görüntü sınıflandırma problemlerinde iyi sonuçlar verse de, genellikle kullandıkları Evrişimsel Sinir Ağları (ESA) eğitim için çok sayıda etiketlenmiş veriye ihtiyaç duymaktadır. Doğru şekilde etiketlenmiş veriye ulaşımındaki kısıtlılık bu tür çalışmaları zorlaştırmaktadır. Bu sebeple daha önce bu alanda yapılan çalışmaların büyük çoğunluğu oldukça az sayıda mamografi görüntüsü ile yapılmıştır. Bu çalışmada kullanılan mamografi görüntüleri FSSH, INBREAST, DDSM ve MIAS olmak üzere 4 farklı kaynaktan alınmıştır.

Çalışmanın ilk aşamasında görüntüler morfolojik görüntü işleme yöntemleri ile ön işlemden geçirilerek istenmeyen verilerden arındırılmıştır. Meme dokusuna ait alanlardan 224x224 ve 227x227 piksel boyutlarında kesitler kırılarak 3 farklı sınıf (kist, kalsifikasyon ve normal) oluşturulmuştur. Her sınıfta 1000 adet, toplamda 3000 adet kesit ile 3 farklı sinir ağı modeli eğitilmiştir. Küçük kesitlere ayrılarak nispeten daha basit hale getirilen görüntüler ile eğitilen AlexNet modelinde %95,55, GoogLeNet modelinde %96, tez çalışması kapsamında geliştirilen MKESAS modelinde %98,71 doğruluk oranına ulaşılmıştır.

Anahtar Kelimeler: Meme kanseri, evrişimsel sinir ağları, biyomedikal görüntü işleme, görüntü sınıflandırma.

ABSTRACT

A New Decision Support System Design Used in the Evaluation of Mammography Images

Ramazan ALİOĞLU

Ph.D. Thesis

FIRAT UNIVERSITY

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Electrical and Electronics Engineering Technologies

January 2022, Pages: xxii + 72

Breast cancer is the leading cause of deaths related with cancer among women. Breast cancer makes up approximately 24,5% of cancer diseases in the world, and 23,9% in Türkiye. Early diagnosis of the disease is the most effective step for treatment.

Mammography is one of the most used method in the early diagnosis of breast cancer. However, misdiagnosis can be made due to some reasons such as used technologies, experience of the radiologists, breast density, breast structure and shooting errors. Therefore, a second radiologist's diagnosis is needed to reduce ambiguity in the diagnosis of the mammography image.

Recently, many studies have been carried out on the Computerized Decision Support System (CDSS) which help for the most accurate diagnosis with mammography images. In this thesis, a CDSS is designed in order to contribute the radiologist by providing a second opinion for the diagnosis of breast cancer. The main aim of this system, in which the final decision will be made by the radiologist, is to reduce the rate of human error.

Today, deep neural networks are preferred more than traditional methods in image processing studies. Although deep learning methods are successful in especially image classification problems, it need a lot of labeled data for training. Limitations in accessing correctly labeled mammography data makes these types of studies difficult. Because of this, most of the former studies in this area were carried out with too limited mammography images. The mammography images used in this study were got from 4 different sources: Elazig Fethi Sekin Research Hospital, INBREAST, DDSM and MIAS.

In the study, first, the images were preprocessed by using morphological image processing methods to eliminate labels and noises in the images. Then, 224x224 and 227x227 pixels of sections from the breast tissue areas were cropped and 3 different classes (cyst, calcification and normal) consisting of relatively simple and small images were created. MKESAS model which was developed for this study, AlexNet and GoogLeNet models were trained with these images. The results show that the MKESAS is the most accurate model with 98,71%. GoogLeNet network is more accurate (96%) than AlexNet network (95,55%).

Keywords: Breast cancer, convolutional neural networks, biomedical image processing, image classification.

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1. Meme anatomisi (1- Göğüs duvarı, 2- Pektoral kas, 3- Süt bezleri, 4- Meme başı, 5- Areola, 6- Süt kanalları, 7- Yağ dokusu, 8- Cilt)	8
Şekil 2.2. Mikro kalsifikasyon içeren mamografi görüntüsü ve ilgili bölgenin kesiti	10
Şekil 2.3. Mamografi cihazı	11
Şekil 2.4. Örnek mamogram görüntüleri: a) Sağ MLO görünüm b) Sol MLO görünüm c) Sağ CC görünüm d) Sol CC görünüm	12
Şekil 3.1. MIAS veri tabanından alınan mamografi görüntüsü (mdb001.jpg)	15
Şekil 3.2. DDSM veri tabanından alınan mamografi görüntüsü (C_0208_1.RIGHT_MLO) ve kist bölgesini gösteren maske (C_0208_1.RIGHT_MLO_Mask)	17
Şekil 3.3. INBREAST veri tabanından alınan: a) Örnek mamogram, b) Kitleyi gösteren maske, c) Mikrokalsifikasyonu gösteren maske	18
Şekil 3.4. Fethi Sekin Şehir Hastanesi'nden alınan mamografi görüntüsü ve etiketlenmiş örneği	19
Şekil 3.5. Mamografi görüntüsünden çıkarılması gereken alanlar	20
Şekil 3.6. 3x3 boyutunda yapısal eleman örnekleri	21
Şekil 3.7. Aşındırma işlemi	22
Şekil 3.8. Genişleme işlemi	22
Şekil 3.9. a) 5x5 boyutunda yapı elemanı, b) 8x8 piksellik görüntünün sayısal gösterimi	23
Şekil 3.10. a) MIAS veri tabanından alınan mamografi görüntüsü, b) Aşındırma yöntemi ile etiketlerden arındırılmış görüntü	24
Şekil 3.11. a) Kenarları aşınmış binary görüntü, b) Aşınan kenarları geri kazanılmış binary görüntü	24
Şekil 3.12. Arka plan gürültülerinden ve etiket bilgilerinden arındırılmış mamografi görüntüsü	25
Şekil 3.13. Kayan pencere işlemi	26
Şekil 3.14. Kayan pencere yöntemi ile kesitlere ayrılan görüntü	27
Şekil 3.15. Yapay zekâ, makine öğrenmesi, derin öğrenme	28
Şekil 3.16. Makine öğrenmesi ve derin öğrenme yöntemlerinde görüntü sınıflandırma	29
Şekil 3.17. ESA yapısı	30
Şekil 3.18. Evrişim katmanı işlemi	31
Şekil 3.19. ReLU aktivasyon fonksiyonu	32
Şekil 3.20. MaxPooling ile havuzlama örneği	32
Şekil 3.21. Batchnormalization yapısı	33
Şekil 3.22. Örnek bir evrişimsel katman takımı	35
Şekil 3.23. Tam bağlı katman yapısı	36
Şekil 3.24. AlexNet ağ mimarisi	38

Şekil 3.25. GoogLeNet ağ mimarisi (ilk seri katmanlar ve ilk insepction)	40
Şekil 3.26. MKESAS ağ mimarisi.....	42
Şekil 4.1. 224x224 piksel boyutunda örnek kesitler(kalsifikasyon-kist-normal)	44
Şekil 4.2. AlexNet eğitim süreci grafiği	47
Şekil 4.3. GoogLeNet eğitim süreci grafiği.....	50
Şekil 4.4. MKESAS eğitim süreci grafiği	53
Şekil 4.5. Sığlaştırılmış MKESAS eğitim süreci grafiği	55
Şekil 4.6. Azaltılmış veri ile MKESAS eğitim süreci grafiği.....	57



TABLolar LİSTESİ

	Sayfa
Tablo 1.1. Xi. ve arkadaşlarının uygulama sonuçları.....	5
Tablo 3.1. Örnek MIAS görüntülerine ait bilgiler	15
Tablo 4.1. Veri tabanlarından alınan görüntü sayıları.....	43
Tablo 4.2. Revize edilen AlexNet ağ analizi.....	45
Tablo 4.3. Revize edilen GoogLeNet network analizi	48
Tablo 4.4. MKESAS ağ analizi.....	51
Tablo 4.5. Sığlaştırılmış MKESAS modelinin ağ analizi	54
Tablo 4.6. Uygulamaların doğruluk oranları.....	58
Tablo 4.7. Uygulamaların Eğitim Süreleri	58
Tablo 5.1. Literatürdeki çalışmalara ait veriler	60
Tablo 6.1. Uygulama sonuçları	64

SİMGELER VE KISALTMALAR

Kısaltmalar

BKDS	: Bilgisayarlı Karar Destek Sistemi
BSAG	: Binary Şablonla Aşındırma ve Genişletme
B/M	: Benign/Malign (İyi Huylu/Kötü Huylu)
CC	: Kraniokaudal – Yukarıdan Aşağıya
CDSS	: Computerized Decision Support System
CNN	: Convolutional Neural Network
DDSM	: Digital Database for Screening Mammography
ESA	: Evrişimsel Sinir Ağları
FASTER R-CNN	: Hızlı Bölgesel Evrişimsel Yapay Sinir Ağı
FNN	: İleri Beslemeli Yapay Sinir Ağı
FSSH	: Fethi Sekin Şehir Hastanesi
MKESAS	: Magografi Kesitlerinin Evrişimsel Sinir Ağlarıyla Sınıflandırılması
MIAS	: Mammographic Image Analysis Society
MLO	: Mediolateral Oblik – Yan Oblik
LSTM	: Long Short-Term Memory
R-CNN	: Bölgesel Evrişimsel Yapay Sinir Ağı
ReLU	: Rectifier Fonksiyonu
RNN	: Recurrent Neural Network
ROI	: Region Of Interest
N/A	: Normal/Anormal
TANH	: Tanjant Hiperbolik Fonksiyon
YSA	: Yapay Sinir Ağı

1. GİRİŞ

Kanser, tüm dünyada yaygın bir hastalık türüdür. Dünya Sağlık Örgütüne bağlı Uluslararası Kanser Araştırma Ajansı'nın 2020 yılında yayınladığı rapora göre, dünya genelinde yaklaşık 19,3 milyon kanser vakasının, 10 milyonu ölümle sonuçlanmıştır [1]. Türkiye verilerine bakıldığında 2020 yılında yaklaşık 234 bin kanser vakasının 126 bini ölümle sonuçlanmıştır [2]. Her geçen yıl artan kanser vakalarının 2040 yılında 28.4 milyona ulaşacağı tahmin edilmektedir [3].

Genel olarak en sık karşılaşılan kanser vakaları meme (%11,7), akciğer (%11,4), kolon (%10), prostat (%7,3) ve mide (%5,6) kanseridir [4]. Meme kanseri, kadınlar arasında en ölümcül kanser türlerinden biridir [1,5,6]. Meme kanserinden kaynaklanan ölümlerin çoğu, esas olarak kanserin yanlış veya geç değerlendirilmesinden kaynaklanmaktadır [5,7,8]. Meme kanserinin erken teşhisi, meme kanserinden etkilenen bir kadının korunması ve hayatta kalması için anahtar faktördür [9–13]. Meme kanserinin erken tespiti için birçok yöntem bulunmaktadır. Günümüzde meme tümörü taraması, en çok mamografi ile yapılmaktadır [14]. Mamografi görüntülerinin değerlendirilmesi radyoloji uzmanı doktorlar tarafından yapılmaktadır. Meme kanserinin erken aşamada tespitinde ve bu hastalıkla mücadelede etkili bir araç olabilmesi için mamografinin doğru okunması gerekmektedir [15]. Meme kanserlerinin yaklaşık %85-90'ı mamografi incelemelerinde görülse de; insan gözünün kısıtlılığı, çekim hataları, iş yükü ve meme dokusunun yapısı gibi nedenlerle mamogramlarda tümörlerin yaklaşık %10-15'i gözden kaçırılmaktadır [16–18]. Bu problemin önüne geçebilmek amacıyla günümüzde radyoloji uzmanlarına yardımcı olmak ve gözden kaçırmaları minimize etmek için otomatik algılama sistemleri geliştirilmektedir [5,19]. Bilgisayarlı Karar Destek Sistemi (BKDS) olarak bilinen bu sistemlerle, meme kanseri teşhisinin yanlış veya eksik yorumlanmasına yol açabilecek vakaların azaltılması amaçlanmaktadır [20–22]. Son zamanlarda bu alanda birçok çalışma yapılmaktadır. Radyolog için ikinci bir görüş olarak düşünülen bu sistemlerde memedeki anormallikleri tespit etmek için çeşitli görüntü işleme algoritmaları kullanılmaktadır [23]. Bu çalışmada, mamografi görüntülerini doğru bir şekilde sınıflandırabilmek için, Evrişimsel Sinir Ağları (ESA) kullanılarak yeni bir BKDS geliştirilmiştir.

Derin Sinir Ağları (DSA), görüntü sınıflandırmadaki başarısından dolayı özellikle biyomedikal görüntü işleme çalışmalarında ilgi odağı haline gelmiştir [24]. Literatür incelendiğinde, veri seti olarak halka açık veri tabanlarındaki mamografi görüntülerinin kullanıldığı göze çarpmaktadır. Bazı çalışmalarda DSA'nın eğitiminde yeteri kadar etiketlenmiş veriye ulaşılamadığından, diğer bir ifadeyle veri yetersizliğinden dolayı bu alandaki çalışmaları olumsuz etkilediğine değinilmiştir [25–29]. Bu tez çalışmasında veri çeşitliliğini ve miktarını arttırmak için MIAS, DDMS, INBREAST ve Fethi Sekin Şehir Hastanesi (FSSH) olmak üzere 4 farklı kaynaktan mamografi görüntüleri elde edilmiştir. Bu sayede tez çalışmasında önerilen sistemin sınıflandırma başarısının yükseltilmesi amaçlanmıştır.

Temel olarak ESA'nın kullanıldığı çalışmanın ilk aşamasında mamografi görüntüleri, morfolojik görüntü işleme temelli Binary Şablonla Aşındırma ve Genişletme (BSAG) yöntemi ile ön işlemden geçirilerek istenmeyen verilerden arındırılmıştır. Mamografi görüntülerindeki kist, kalsifikasyon ve normal olan bölgelerden 224x224 ve 227x227 piksel boyutlarında kesitler kırılmıştır. Her sınıfta 1000 adet kesit olacak şekilde toplam 3000 adet kesit veri seti olarak kullanılmıştır. Sonraki aşamada, hazırlanan veri seti ile çalışmada önerilen Mamografi Kesitlerinin Evrışimsel Sinir Ağlarıyla Sınıflandırılması (MKESAS) modeli eğitilerek %98,71 doğruluk oranına ulaşılmıştır. Önerilen sistemin geçerliliğini test etmek için aynı veri seti ile farklı ESA modelleri eğitilerek doğruluk oranları karşılaştırılmıştır. Elde edilen verilere göre AlexNet modelinde %95,55 ve GoogLeNet modelinde ise %96 doğruluk oranına ulaşılmıştır.

Bu veriler ışığında çalışmada önerilen ve kısmen daha sık bir model olan MKESAS modelinin %98,71 doğruluk oranı ile diğer ESA modellerinden daha yüksek bir performans gösterdiği gözlenmiştir.

1.1. Literatür Araştırması

Meme kanserinin bilgisayarlı tanısı ile ilgili literatürde birçok çalışma bulunmaktadır. Zhang ve arkadaşları [21], MVNN adını verdikleri ESA modeli ile iki aşamalı (Normal/Anormal ve İyi huylu/Kötü huylu) bir sınıflandırma yapmışlardır. Yaptıkları çalışmada veri seti olarak mamografi görüntülerinin halka açık olduğu Digital Database for Screening Mammography (DDSM) veri tabanından elde ettikleri mamografi görüntülerini kullanmışlardır. Sınıflandırma için DenseNet derin sinir ağı yapısını omurga olarak kullandıkları modelle normal ve anormal mamogram sınıflandırmasında %96,52 duyarlılık, %94,92 doğruluk değerlerine ulaşırken iyi huylu ve kötü huylu mamogram sınıflandırmasında %96,11 duyarlılık, %95,24 doğruluk değerlerine ulaşmışlardır.

Li ve arkadaşları [30], mamografi görüntülerindeki anormalliği iyi huylu, kötü huylu şeklinde sınıflandırmak için bir ESA modeli üzerinde çalışma yapmışlardır. Yaptıkları çalışmada sinir ağı derinliğinin ve gizli katmanların sınıflandırma başarısına olan etkisini araştırmak için dört farklı evrışimsel ağ modeli inşa etmişlerdir. Aynı zamanda çalışmalarında AlexNet ESA ve VggNet-16 ESA modellerinin de sınıflandırma başarısını test etmişlerdir. Dört evrişim katmanından oluşan CNN-4D modeli geliştirdikleri modeller içinde en iyi performansı göstermiştir. CNN-4D modelinde aşırı öğrenmeyi engellemek için dropout katmanı da (dropout katsayısı 0,7 olarak uygulanmıştır) kullanmışlardır. ESA modellerinin eğitim ve testi için kullandıkları veri setini de MIAS veri tabanından elde etmişlerdir. En iyi sınıflandırma başarısına ulaştıkları CNN-4D modeli ile %89,05 doğruluk, %90,63 hassaslık oranına ulaşmışlardır.

Sulaiman ve arkadaşları [31] yaptıkları çalışmayı, mamogram görüntülerinin ön işlemden geçirilmesi, görüntüdeki kitlelerin tespiti ve tespit edilen kitlenin sınıflandırılması şeklinde üç temel aşamada gerçekleştirmişlerdir. Görüntü işleme çalışmalarında sıklıkla kullanılan, her biri birer ESA modeli olan VggNet-19, InceptionV3 ve MatConvNet modellerini kullanmışlar ve bu modellerin başarılarını karşılaştırmışlardır. Uygulamada kullandıkları modelleri eğitmek ve test etmek için MIAS veri tabanından aldıkları mamografi görüntülerini kullanmışlardır. Sonuç olarak tasarladıkları BKDS ile mamografi görüntülerindeki kitle konumunu %97,04 genel doğrulukla tespit edebilmişlerdir.

Yu ve Guan [32], dijital mamogramlarda küme mikro kalsifikasyonlarını otomatik olarak tespit etmek için bilgisayarlı teşhis sistemi geliştirmişlerdir. Geliştirdikleri sistemin ilk adımında mikro kireçlenme piksellerini gri seviye istatistikleri ve dalgacık özelliklerini kullanarak ayırmışlar ve olası mikro kalsifikasyonları etiketlemişlerdir. Dört seviyeli dalgacık ayrıştırma ve yeniden yapılandırma algoritması kullanarak dalgacık özellikleri oluşturmuşlar. Gri seviyenin istatistiksel özellikleri olarak medyan kontrastı ve normalize gri seviye değeri kullanmışlar. Bu dalgacık özelliklerini ve istatistiksel gri tonlama özelliklerini ileri beslemeli bir Yapay Sinir Ağı (YSA) sınıflandırıcısına uygulayarak, olası mikro kalsifikasyon piksellerinin bir olasılık haritasını oluşturmuşlardır. Bu aşamada tespit edilen olası mikro kalsifikasyonlar arasından doğru mikro kalsifikasyonları belirlemek için ikinci ayırt edici, yani sınıflandırıcı aşamaya geçilmiştir. Bu aşamada işaretlenen olası mikro kalsifikasyonlardan ayırt edici özellikler çıkarılmıştır. Sıralı ileriye seçim ve sıralı geriye seçim yöntemi kullanarak çıkarılan ayırt edici özellikler içinden en ayırt edici özellikleri belirlemişlerdir. En ayırt edici özellikleri sınıflandırıcılara giriş olarak uygulayarak sınıflandırma işlemini gerçekleştirmişler ve sınıflandırıcının başarı sonuçlarını karşılaştırmışlardır. Geliştirilen sistemi 150 mikro kalsifikasyon içeren toplamda 40 mamografi görüntüsüne uygulamışlardır. Serbest tepkili işlem karakteristikleri eğrisi kullanarak sistemin performansını değerlendirmişler ve en iyi sınıflandırma başarısını %90 ortalama doğru pozitif tespit oranı ile sıralı geriye seçim yöntemiyle seçilen özellikler kullanıldığında elde etmişlerdir.

Ertosun ve Rubin [33], mamografi görüntülerinde lezyonların otomatik olarak taranması ve lokalizasyonu için derin öğrenmeye dayalı bir görsel tarama sistemi geliştirmişler. Geliştirdikleri sistemin eğitim ve testi için kullandıkları veri setini DDSM veri tabanından almışlardır. Geliştirdikleri sistem sınıflandırma ve lokalizasyon olmak üzere iki aşamadan oluşmaktadır. Derin öğrenme sınıflandırıcısı kullanarak kitleli veya kitlesiz olarak mamografi görüntülerini sınıflandırmışlardır. Derin öğrenme ağına dayalı bölgesel bir olasılık yaklaşımı kullanarak kitle içeren görüntüleri belirlemede %85 doğruluk elde etmişlerdir. Kitle içeren görüntülerde kitlenin yerinin tespitinde de yine ortalama %85 doğruluk oranına ulaşmışlardır. Aynı çalışmada AlexNet, VggNet-16 ve GoogLeNet ile uygulamalar yapılmış kitleli veya kitlesiz olarak mamografi

görüntüleri sınıflandırılmış, bu sınıflandırmada sırasıyla %84, %82, %85 doğruluk oranlarına ulaşılmıştır.

Wang ve arkadaşları [34], mikro kalsifikasyonların tanınal doğruluğunu iyileştirmek için büyük veri kümelerinde derin öğrenme algoritmasının performansını değerlendirmişlerdir. Hem meme lezyonlarını sınıflandırmak hem de mikro kalsifikasyonların ve meme kitlelerinin ayırma/birleştirmedeki doğruluğunu değerlendirmek için bir sınıflandırma modeli oluşturmuşlardır. Mikro kalsifikasyonlar ve kitlelerin derin öğrenme modeli ile kombinasyonundan %89,7'lik bir doğruluk elde etmişlerdir.

Selvathi ve Poornila [35], derin öğrenmeye dayalı denetimsiz bir teknik kullanarak mamografi görüntülerinden meme kanserini tespit etmek için bir sistem önermişlerdir. Denetimsiz derin öğrenme tekniklerini kullanarak, küçük kitleleri daha doğru bir şekilde bulmaya çalışmışlar. Derin öğrenmenin etkinliğini arttırmak için önce görüntülerdeki arka plan, pektoral kas ve diğer gürültüleri kaldırmışlardır. Mini MIAS veri tabanından elde ettikleri mamografi görüntülerinin sınıflandırılmasında %98,5'e varan doğruluk elde etmişlerdir.

Han ve arkadaşları [36], tasarladıkları Class Structure-based Deep Convolutional Neural Network (CSDCNN) adında bir derin öğrenme modelini kullanarak meme kanseri çoklu sınıflandırma yöntemi önermişlerdir. Modelin eğitimi ve testi için BreaKHis veritabanından alınan histopatolojik görüntüleri kullanmışlardır. Yapılandırılmış derin öğrenme modeli ile ortalama %93,2 doğruluk elde etmişlerdir.

Reiazi ve arkadaşları [37], yaptıkları çalışma ile MIAS veri tabanını kullanarak mamografi kist tespiti için ESA ve FASTER R-CNN detektörünün performansını değerlendirmişlerdir. Kullandıkları yöntemle çok az eğitim verisi ile (102 görüntü) makul bir algılama hassasiyetine ulaştıklarını belirtmişlerdir.

Dubrovina ve arkadaşları [38], önerdikleri yöntemde mamografi görüntülerinde ayırt edici özellikleri otomatik olarak öğrenmek için ESA kullanmışlardır. Veri seti olarak, bir uzman tarafından manuel olarak dört bölgeye (fibroglandular doku, meme başı, meme dokusu ve pektoral kas) ayrılmış, MLO pozisyonunda 40 dijital mamografi görüntüsü kullanmışlardır. Piksel yöntemli otomatik sınıf tahminini hızlandırmak için, klasik tam bağlı katmanlar yerine evrişim katmanları kullanmışlar ve bu yaklaşımla, sınıflandırma doğruluğunu korurken önemli ölçüde daha hızlı hesaplama sağlamışlardır.

Xi ve arkadaşları [39], mamogram görüntülerinde kalsifikasyonları ve kitleleri sınıflandırmak için farklı ESA modelleri üzerinde çalışmalar yapmış, veri seti olarak DDSM verilerini kullanmışlardır. Sinir ağının ezber yapmasının önüne geçmek için görüntüleri 0-360 derece arasında rasgele döndürerek kullanmışlardır. AlexNet, VggNet, GoogLeNet ve ResNet modelleri ile yapılan uygulamaların kalsifikasyon ve kistleri sınıflandırmadaki doğruluk oranları

Tablo 1.1’de verilmiştir. Uygulamalar sonucunda en iyi genel doğruluğa VggNet modelinin %92,53’lük oranıyla ulaşılmıştır.

Tablo 1.1. Xi. ve arkadaşlarının uygulama sonuçları [39]

Model	Kalsifikasyon	Kist	Genel
AlexNet	%88,81	%93,64	%91,23
VggNet	%92,42	%92,64	%92,53
GoogLeNet	%87,14	%95,06	%91,1
ResNet	%90,22	%93,39	%91,8

Perre ve arkadaşları [40], mamografi görüntülerindeki lezyonları sınıflandırmak için ESA modeli kullanmışlardır. İhtiyaç duyulan büyük veri kümesi için Imagenet veri kümesi kullanılarak daha önceden eğitilmiş 3 farklı sinir ağı modeli CNN-F, CNN-M ve Caffe ile uygulamalar yapılmıştır. Veri seti olarak Breast Cancer Dıgital Repository- Film Mammography (BCDR-FM) veri tabanından alınan mamografi görüntüleri kullanılmıştır. Daha önceden eğitilmiş ESA’nın mamogramlardaki lezyonların sınıflandırılması için iki tip görüntü normalizasyonun performansını araştırmışlardır. En iyi sonuçlar, görüntü normalizasyonu olmadan ESA için Caffe referans modeli kullanılarak elde edilmiştir.

Moon ve arkadaşları [41], meme ultrasonu kullanarak tümörleri iyi huylu veya kötü huylu olarak sınıflandırabilen bir bilgisayar destekli tanı sistemi önermişlerdir. Yaptıkları çalışmada görüntü füzyon yöntemi kullanarak, ultrason görüntüleri üzerinde farklı ESA mimarilerini bir araya getiren bir bilgisayar destekli tanı sistemi kullanmışlardır. Çalışmada önerdikleri ESA tabanlı yöntemler olan VggNet, ResNet ve DenseNet olmuştur. 953 iyi huylu ve 734 kötü huylu olmak üzere toplam 1687 tümör kullandıkları çalışmada %91,1 doğruluk oranına ulaşmışlardır.

Malebary ve arkadaşları [42], mamografi görüntülerindeki anlamsal özelliklerin belirsizliği, mevcut görüntülerdeki analiz sınırlılığı, düşük kontrastlı görüntülerdeki kayıp özellikler ve segmentasyondaki belirsizlikler, hesaplama maliyeti gibi bazı sorunlardan dolayı ESA’lara dayalı geliştirilen sistemlerin hala yetersiz kaldığını savunmaktadırlar. Bu sorunları çözmek ve düşük kontrasttaki mamografi görüntülerini sınıflandırmanın doğruluğunu artırmak için, Breast Mass Classification (BMC) adlı yeni bir meme kitle sınıflandırma sistemi önermişlerdir. Meme kitlesini iyi huylu, kötü huylu ve normal olarak sınıflandırmak için önerdikleri yöntem K- Mean Clustering, LSTM of RNN, ESA, random forests gibi artırma tekniklerinin bir kombinasyonuna dayanan bir mimariye sahiptir. DDSM ve MIAS’ dan alınan veriler kullanılmış ve sonuçlar ayrı ayrı değerlendirilmiştir. Genel olarak %94-98 oranında doğruluk oranına ulaşıldığı ifade edilmiştir.

1.2. Çalışmanın Literatüre Katkısı

Bu tez çalışmasında, mamografi görüntülerinin kist, kalsifikasyon ve normal doku olarak sınıflandırılabilmesi için mamografi görüntüleri öncelikle çalışma kapsamında geliştirilen BSAG yöntemi kullanılarak mamografi görüntülerindeki etiket bilgileri ve gürültüler çıkarılmıştır. Morfolojik görüntü işleme tekniklerini temel alan BSAG yöntemi ile meme dokusu haricindeki unsurlardan arındırılan mamografi görüntüleri bir sonraki aşamada kesitlere ayrılarak basitleştirilmiştir. Kesitlere ayrılan görüntüler kist, kalsifikasyon ve normal doku olarak her bir sınıfta 1000 adet görüntü olacak şekilde 3 sınıfa ayrılmıştır. Böylece derin öğrenme tabanlı karar destek sisteminin doğruluk oranı yüksek sonuçlar üretmesi mümkün olmuştur. Oluşturulan veri kümeleri ile AlexNet, GoogLeNet ve önerilen MKESAS modeli eğitilmiştir. 3 sinir ağı modelinin de %95 üzerinde doğruluk oranına ulaştığı gözlemlenmiştir. Çalışmada önerilen ve diğer derin ağ modellerine göre kısmen daha sık olan MKESAS modeli ile 2 dakikalık bir eğitim sürecinde %98,71 doğruluk oranına ulaşılmıştır.

Literatürdeki benzer çalışmaların bir kısmında sadece mikro kalsifikasyon içeren bölgeler kullanılırken bir kısmında sadece kist içeren bölgeler kullanılmıştır. Geliştirilen sistem ile meme kanserinin belirtileri olarak bilinen mikro kalsifikasyon, kist ve normal olmak üzere her üç bölgeyi değerlendirerek sınıflandırma yapan bir sistem tasarlanmıştır. Geliştirilen sistem üç aşamalı olarak tasarlanmıştır. Öncelikle görüntüdeki istenmeyen alanlar (gürültüler, etiketler, arka plan) morfolojik görüntü işleme yöntemleri kullanılarak görüntüden çıkarılmıştır. Görüntüde bulunan gürültü ve etiketler sinir ağının eğitimine olumsuz etkisi olduğundan bu alanlar çıkarıldığında sınıflandırma başarısında artış olduğuna dair sonuçlar daha önceki birçok bilimsel çalışmada ele alınmıştır[18,35]. İkinci aşamada ise görüntüdeki meme dokusunu kapsayan bölgelerdeki ilgili kesitler kırılarak kesitlere ayrılmıştır. Böylece mamografi görüntüsündeki kist, mikro kalsifikasyon ya da normal sınıfı temsil eden ilgili alanlar (ROI) sistemin eğitiminde kullanılacak veriler daha da basitleştirilmiştir. Basitleştirilen, toplam 3 sınıf ve 3000 adet mamografi kesitlerinden oluşan bu veri seti kullanılarak, 2 dakikalık sürede eğitilen ESA modeli ile %98,71 doğruluk oranına ulaşılmıştır. Aynı veri kümesi ile AlexNet ve GoogLeNet ESA modelleri de eğitilerek elde edilen sonuçlar karşılaştırılmıştır. AlexNet ESA mimarisi eğitildiğinde 2 dakika 12 saniyede %95,55, GoogLeNet ESA mimarisi eğitildiğinde 5 dakika 42 saniyede %96 doğruluk oranına ulaşılmıştır.

Yapılan çalışma ile ilgili literatür incelendiğinde genellikle halka açık veri tabanı olan MIAS ve DDSM veri tabanları kullanıldığı görülmektedir. Derin sinir ağlarının klasik makine öğrenmesinden en belirgin farkı eğitimde kullanılan veri setinin büyüklüğüdür. Bu sebeple konuyla ilgili literatürdeki çalışmaların birçoğunda veri kısıtlılığına değinilmiştir. Bu amaçla veri çeşitliliğini ve miktarını arttırmak için halka açık MIAS, DDSM veri tabanlarına ek olarak farklı kaynaklardan da mamografi görüntüleri temin edilmiştir. Halka açık olmayan INBREAST veri

tabanındaki görüntülerin temin edilebilmesi için ilgililerle gerekli görüşmeler yapılmış ve veri tabanına bağlantı izni alınmıştır. Ayrıca FSSH'nden temin edilen mamografi görüntüleri de geliştirilen sistemin eğitiminde kullanılmıştır. Böylece literatürdeki çalışmalardan farklı olarak daha geniş ve çeşitli veri tabanlarına ulaşılmış böylece daha çeşitli ve fazla veri elde edilmiştir. Bu farklılık da geliştirdiğimiz sistemin başarısını önemli ölçüde arttırmıştır.




2. MEME YAPISI VE MEME KANSERİ

Bu bölümde meme yapısı, meme kanseri ve mamografi görüntüleme sistemi alt başlıklar halinde açıklanmıştır:

2.1. Meme Yapısı

Özünde kas dokusu olmayan meme yapısı göğüs duvarındaki pektoral kasların üzerinde bulunur [43,44]. Meme dokusu süt bezleri (lobüller), ve bu süt bezlerinde üretilen sütü taşıyan süt kanalları (duktuslar) ve bunların arasındaki yağ, sinir, kan, lenf damarları gibi destek dokularından oluşur [45]. Her bir memede üzüm salkımına benzeyen 15-20 adet lop vardır. Meme başına doğru birleşerek gelen süt kanalları ve meme ortasındaki areola denilen meme başı bölgesindeki koyu renkli pigmentli alanda toplanırlar [43]. Memenin büyüklüğü ve şekli aynı kişide her iki memede bile farklılık gösterebilmektedir [18,20]. Meme yapısındaki göğüz duvarı, pektoral kas, süt bezleri, meme başı, areola, süt kanalları, yağ dokusu ve cilt Şekil 2.1’de görülmektedir.



Şekil 2.1. Meme anatomisi (1- Göğüs duvarı, 2- Pektoral kas, 3- Süt bezleri, 4- Meme başı, 5- Areola, 6-Süt kanalları, 7- Yağ dokusu, 8- Cilt) [46]

Meme, kadın vücudunun hayatı boyunca en büyük değişikliklere uğrayan organlarından biri olarak kabul edilmektedir. Menopoz dönemine kadar meme, adet döngüsüne paralel olarak ortaya çıkan ve kandaki hormonların seviyesine bağlı olarak aylık değişikliklere uğrayan bir organdır [47,48]. Bu şekilde meme bezleri her ay aktif hale gelmekte meme dokusu da haliyle şişmektedir. Hormon seviyeleri normale döndüğünde meme bezleri pasif hale gelmektedir [47]. Bu nedenle adet döngüsü öncesinde ve sırasında memelerde şişlik ve hassasiyet oluşmaktadır [49].

2.2. Meme Kanseri


Meme dokusunu oluşturan bazı hücre gruplarının kontrolsüz çoğalmasıyla oluşan tümör meme kanseri olarak tanımlanmaktadır. Yakın çevresine ve lenf bezlerine doğru yayılan tümör erken tespit edilip tedavi edilmez ise tedavi zorlaşır hatta imkânsızlaşır [50]. Meme kanserine, tıpkı diğer kanser türlerinde olduğu gibi, genetik bir anormallik neden olur. Esas olarak yaşlılığa bağlı olan aşınma ve yıpranma bu hastalığın ana nedenidir [51,52]. Bununla birlikte, diğer ana nedenler çevresel faktörler, beslenme ve kötü alışkanlıklardır [53]. Günümüzde bu hastalığı tamamen önleyen bir yöntem bulunmamaktadır. Bu hastalıkla mücadelede en etkili yöntem hastalığın erken tanısı ve erken tedavisidir [54]. Hastalığın erken tanısı için düzenli olarak tarama yapılmalıdır. Tarama yöntemi için 20 yaş üstü kadınlar için kendi kendine ayda 1 kez elle muayene, 20-40 yaş aralığındaki kadınlar için yılda 1 kez klinik muayene, 40 yaş üstü kadınlar için 2 yılda 1 kez mamografi ile tarama programı önerilmektedir. Kadınlarda meme kanserini klinik sonuçlar ortaya çıkmadan erken bir aşamada tespit etmek için uygulanan tarama programının amacı, kuşkusuz erken tanı ve muayene ile meme kanserinden kaynaklanan ölümleri azaltmak ve kurtarılan meme sayısını artırmaktır [55].

Meme kanserinin elle muayenesinde tespit edilebilecek bazı belirtiler vardır bu belirtileri şu şekilde sıralayabiliriz [54]:

- Memenin portakal kabuğuna benzer görünümü
- Meme ucunun içe çekilmesi
- Memeden kanlı/kansız sıvı gelmesi
- Deride kızarıklık, şişlik, ödem
- Memede kitle oluşması
- Kolda ödem ve şişlik

Kadınlarda oldukça yaygın olan meme kanserinin ne kadar tehlikeli bir noktaya ulaştığını anlamak için kanser evresinin de belirlenmesi gerekmektedir. Meme kanserinin evresini belirlemek için ilk aşamada kanserin boyutu, tümörün boyutu ve hacmi, hormon reseptörlerinin varlığı gibi temel özellikler kontrol edilir. En düşük aşama olan evre 0, agresif olmayan fakat izleme gerektiren kanser hücrelerini gösterir. En yüksek aşama olan evre 4 ise diğer alanlara yayılan agresif kanseri gösterir [56].

Meme kanserinin erken teşhisi için mikro kalsifikasyonlar da güçlü bir uyarıcıdır [6,57,58]. Mikro kalsifikasyonlar sadece meme kanserinin erken teşhisi için uyarıcı değil, aynı zamanda biyopsi yerinin belirlenmesine de yardımcı olur [6,8,59]. Mikro kalsifikasyonlar, küçük beyaz noktalar veya taneler olarak görünür. Çoğu mikro kalsifikasyon vakası iyi huyludur. Bununla birlikte, belirli özelliklere sahiplerse, meme kanserine işaret edebilirler [60,61]. Mikro kalsifikasyon içeren bir mamografi görüntüsü Şekil 2.2’de görülmektedir.




Şekil 2.2. Mikro kalsifikasyon içeren mamografi görüntüsü ve ilgili bölgenin kesiti [62]

2.3. Mamografi

Radyologlar tarafından meme kanserini teşhis etmek için kullanılan en yaygın yöntem mamografidir [28,63]. Diğer yöntemler, manyetik rezonans (MR) ve ultrasondur. Mamografi, sıkıştırılmış bir memenin X-ışını görüntüsüdür ve kanserin erken teşhisi için etkili bir yöntemdir [43]. Diğer yöntemlere göre başlıca avantajı düşük radyasyonu, düşük maliyeti ve görüntü kalitesidir.

Çekim esnasında, memenin sıkıştırılması ile meme kalınlığı azalmakta ve görüntü netliği artmaktadır. Ayrıca, memeyi sabit tutarak hareket kaynaklı görüntü bulanıklığını azaltmakta,

görüntülenen meme dokusu miktarının en üst seviyede olmasına katkı sağlamaktadır [43]. Mamografi çekiminde kullanılan dijital mamografi cihazı Şekil 2.3’de verilmiştir.



Şekil 2.3. Mamografi cihazı [64,65]

Tarama ve teşhis amaçlı görüntüleme olarak iki tür mamografi muayenesi vardır. Hastalık belirtisi olmayan risk altındaki kadınlar (40 yaş üstü kadınlar) için tarama mamografisi, erken teşhis ve hastalık başlamadan önce önlem amaçlı yapılır [66]. Tedavinin başarısı ve yaşamın uzaması, hastalığın erken teşhisi ile doğru orantılıdır [43,67]. Tarama işlemi sırasında görüntü dört şekilde işlenir. Bu, her iki memenin Mediolateral Oblik – yan oblik (MLO) ve Kraniokaudal – yukarıdan aşağıya (CC) görünümüdür.

Her iki memenin ikişer farklı görünümü (MLO ve CC) Şekil 2.4’de örnek olarak verilmiştir.



Şekil 2.4. Örnek mamogram görüntüleri: a) Sağ MLO görünüm b) Sol MLO görünüm
c) Sağ CC görünüm d) Sol CC görünüm [63,68]

Bu görünüm, anormal meme yapılarının daha iyi görülebilmesi için tasarlanmıştır [69]. Teşhis amaçlı çekilen mamografi ise görüntüleme bulunan şüpheli bir alanın derinlemesine taraması veya biyopsi ihtiyacını tespit etmek için yapılmaktadır [54]. Yani meme şikâyeti olan veya anormal tarama materyali olan kadınlarda mamografi kullanımına tanısal mamografi denilmektedir. Anomalinin tam yeri ve kapsamı belirlemeye çalışılır ve lezyonda kanser belirtisi olup olmadığı tespit edilir [43].

2.4. Bilgisayarlı Karar Destek Sistemi

Mamografi görüntülerinin düşük kontrastlı yapısı en büyük dezavantajıdır. Görüntünün bu özelliği, iş yoğunluğu, uzmanın yoğunluğu ve tecrübesi ve buna benzer nedenler birçok tümör ve kalsifikasyonun uzmanlar tarafından gözden kaçırılmasına veya yanlış değerlendirilmesine sebep olmaktadır [11,54]. Buna çözüm olarak bazı sağlık kurumları aynı mamografi görüntüsünü birden fazla radyoloğa okutarak hatalı okumaları azaltma yoluna gitmiştir. Bu işlemle hatalar kısmen azalmakta fakat maliyet ve iş yoğunluğu daha da artmaktadır [54]. Bu nedenle gözden kaçırılan mamografi görüntülerinin ve yanlış teşhis oranının azaltılması için konuyla ilgili BKDS tasarımına ve kullanımına ihtiyaç duyulmaktadır.

Günümüzde radyoloji uzmanları için ikinci bir göz olarak değerlendirilebilecek, hatalı okuma oranlarını, iş yoğunluğunu azaltacak, yorgunluk, yoğunluk, tecrübe gibi nicel özelliklerden

etkilenmeden karar verebilecek otomatik sistemler üzerinde çalışmalar yapılmaktadır. Genellikle BKDS olarak tanımlanan bu otomatik algılama, sınıflandırma sistemleri ileri görüntü işleme yöntemleri kullanan bilgisayar yazılımlarıdır. Bu yazılımlarla kanserli bölgenin tespiti ve görüntünün (pozitif/negatif, iyi huylu/kötü huylu, kist/mikro kalsifikasyon/normal) sınıflandırılması yapılabilmektedir.

Son zamanlarda görüntü işlemedeki başarısıyla ön plana çıkan DSA, biyomedikal görüntülerin işlenmesi için tasarlanan BKDS çalışmalarında da ilgi odağı olmuştur. Bilgisayar donanımlarının artan kabiliyetleri, büyük veri havuzları DSA modellerinin gelişmesine çok büyük katkılar sunmuştur. Literatürdeki güncel çalışmalar da incelendiğinde DSA modellerini kullanan konuyla ilgili BKDS'nin oldukça başarılı sonuçlar ürettiği görülmektedir.

Çalışma kapsamında geliştirilen BKDS ile kesitlere ayrılan mamografi görüntüleri kist, mikro kalsifikasyon ve normal olarak %98,71 doğruluk oranı ile sınıflandırılmıştır.

3. MATERYAL VE METOT

Yapılan bu tez çalışmasında geliştirilen BKDS'nin eğitimi ve testi için daha önceden konunun uzmanları tarafından etiketlenmiş mamografi görüntüleri kullanılmıştır.


3.1. Çalışmada Kullanılan Görüntülerin Temin Edildiği Kaynaklar

Literatürdeki benzer çalışmalarda mamografi görüntüleri genellikle halka açık olan ve herhangi bir erişim izni gerektirmeyen MIAS ve DDSM veri tabanlarından temin edilmiştir. Yapılan ESA tabanlı çalışmalarda çok fazla etiketlenmiş mamografi görüntüsüne ihtiyaç olduğu fakat bu verilere erişimdeki kısıtlılık nedeniyle bu alandaki çalışmaların zorlaştığı ifade edilmiştir. Yapılan bu tez çalışmasında veri çeşitliliğini ve miktarını arttırmak için benzer çalışmalarda sıklıkla kullanılan MIAS ve DDSM veri tabanlarının yanı sıra özel erişim izni gerektiren INBREAST veri tabanı ve FSSH veri tabanı da kullanılmıştır. Çalışmada kullanılan görüntülerin temin edildiği kaynaklar alt başlıklar halinde tanıtılmıştır.

3.1.1. MIAS Veri Tabanından Alınan Mamografi Görüntüleri

Bu çalışmada geliştirilen karar destek sisteminin eğitimi ve testi için ihtiyaç duyulan mamografi görüntülerinin 185 adeti mini-MIAS [62] veri tabanından alınmıştır. MIAS veri tabanı bir İngiliz araştırma ekibinin bir çalışmasıyla oluşturulmuştur. MIAS veri tabanındaki veriler İngiliz Ulusal Meme Taraması Programı'ndan elde edilmiş toplam 161 hastaya ait 322 adet 1024x1024 piksel çözünürlüğünde mamografi görüntüsünden oluşmaktadır [62]. Bu veri tabanında bulunan tüm mamografi görüntüleri uzman radyologlar tarafından etiketlenmiştir.

Şekil 3.1’de MIAS veri tabanından alınan bir mamografi görüntüsü örnek olarak verilmiştir.



Şekil 3.1. MIAS veri tabanından alınan mamografi görüntüsü (mdb001.jpg) [62]

Görüntülerdeki anormalliğin türü, meme dokusunun yapısı, anormal bölgenin çapı ve merkez koordinatı gibi bilgiler de veri tabanında verilmiştir. MIAS veri tabanından elde edilen beş adet görüntüye ait bilgiler örnek olarak Tablo 3.1 de gösterilmiştir.

Tablo 3.1. Örnek MIAS görüntülerine ait bilgiler

I	II	III	IV	V	VI	VII
mdb001	G	CIRC	B	535	425	197
mdb003	D	NORM				
mdb028	F	CIRC	M	338	314	56
mdb032	G	MISC	B	388	742	66
mdb081	G	ASYM	B	492	473	131

Tablo 3.1 deki örnek olarak verilmiş MIAS veri tabanından temin edilen görüntülere ait veriler aşağıda açıklanmıştır [62]:

I. Sütun: İlgili görüntünün dosya adı,

II. Sütun: Meme dokusunun özelliğini,

F: Yağlı

D: Yoğun - Glandüler

G: Yağlı - Glandüler

III. Sütun: Anormalliğin sınıfını,

CIRC: İyi tanımlanmış kitleler

CALC: Kalsifikasyon içeren

MISC: Kötü tanımlanmış kitleler

SPIC: Şüpheli kitleler

ARCH: Yapısal bozulma

NORM: Normal görüntü

ASYM: Asimetri içeren görüntü

IV. Sütun: Anormallik çeşidini,

B: İyi huylu

M: Kötü huylu

V. ve VI. Sütun: Anormalliğin koordinatlarını,

VII. Sütun: Anormalliğin yarıçapını, vermektedir.


3.1.2. DDSM Veri Tabanından Alınan Mamografi Görüntüleri

DDSM veri tabanı konuyla ilgili çalışmaları desteklemek için Massachusetts General Hastanesi (D. Kopans, R. Moore), Güney Florida Üniversitesi (K. Bowyer) ve Sandia Ulusal Laboratuvarı'nın (P. Kegelmeyer) ortaklaşa kurdukları bir çalışmadır [70].

Yaklaşık 2500 görüntü ile DDSM veri tabanı her memeye ait 2 görüntü (MLO ve CC) ile beraber bu görüntülere ait radyologlar tarafından belirlenmiş teknik bilgiler de (yağ, anormallik derecesi, anormallik bölgesi) içermektedir.

Bu tez çalışması kapsamında, DDSM veri tabanında bulunan mamografi görüntülerden 213 âdeti kullanılmıştır.

Şekil 3.2 de DDSM veri tabanından alınan bir mamografi görüntüsü ve bu görüntüdeki kist bölgesini gösteren şablon örnek olarak verilmiştir. (Şekil 3.2 için kullanılan kist bölgesini gösteren şablondaki sınırlar belirginleştirilmek için kalınlaştırılmıştır).




Şekil 3.2. DDSM veri tabanından alınan mamografi görüntüsü (C_0208_1.RIGHT_MLO) ve kist bölgesini gösteren maske (C_0208_1.RIGHT_MLO_Mask) [71]

3.1.3. INBREAST Veri Tabanından Alınan Mamografi Görüntüleri

Bu çalışmada geliştirilen karar destek sisteminin eğitimi ve testi için ihtiyaç duyulan mamografi görüntülerinin bir kısmı INBREAST veri tabanından alınmıştır. Halka açık olmayan INBREAST veri tabanındaki görüntülerin temin edilebilmesi için ilgililerle gerekli görüşmeler yapılmış ve veri tabanına bağlantı izni alınmıştır.

INBREAST veri tabanında, 115 vakadan elde edilmiş 410 adet mamografi görüntüsü vardır. Görüntüler içinde 108 adet kitle, 308 adet mikro kalsifikasyon, 3 adet mimari bozulma, 14 adet asimetrik bozulma vakası mevcuttur [72]. Görüntüler radyoloji uzmanları tarafından etiketlenmiş mikro kalsifikasyonların ve kitlelerin konumlarını gösteren maskeler ayrı klasörler altında sunulmuştur.

INBREAST veri tabanından alınan örnek bir mamografi görüntüsü, kitleyi ve mikro kalsifikasyonu gösteren maske Şekil 3.3’de verilmiştir.




Şekil 3.3. INBREAST veri tabanından alınan: a) Örnek mamogram, b) Kitleyi gösteren maske, c) Mikrokalsifikasyonu gösteren maske

Bu çalışmada kullanılmak üzere INBREAST veri tabanından toplam 140 mamografi görüntüsü temin edilmiştir. Bu görüntülerden 40 adeti normal, 50 adeti kist, 50 adeti mikro kalsifikasyon içermektedir.

3.1.4. FSSH Veri Tabanından Alınan Mamografi Görüntüleri

Literatürdeki çalışmalarda genellikle halka açık veri tabanları kullanılmaktadır. Bu tez çalışmasında 3 veri tabanının yanı sıra bir de yerel bir hastaneden temin edilen (Fethi Sekin Şehir Hastanesi) uzman radyologlar tarafından etiketlenmiş 91 adet mamografi görüntüsü de kullanılmıştır.

Fethi Sekin Şehir Hastanesi'nden alınan etiketlenmiş mamografi görüntülerine bir örnek Şekil 3.4'de verilmiştir.




Şekil 3.4. Fethi Sekin Şehir Hastanesi'nden alınan mamografi görüntüsü ve etiketlenmiş örneği

Bu verileri kullanabilmek için Fırat Üniversitesi 04.02.2021 tarih ve 2021/02 -46 sayılı etik kurul izni alınmıştır.

3.2. Mamografi Görüntülerinin Gürültülerden Arındırılması

Birçok görüntüde olduğu gibi mamografi görüntülerinde de görüntüyü bozan gürültüler vardır [73–75]. Görüntüdeki bu bozulmalar, gürültüler çekim esnasında hareket, görüntü sıkıştırma, çekim hataları, çekim ortamı ve benzeri nedenlerden kaynaklanmaktadır [76]. Ayrıca mamografi görüntülerinde çeşitli numaralar ve etiket bilgileri bulunmaktadır [77,78]. Mamografi görüntülerinin DSA modelleri kullanılarak sınıflandırılmasında meme dokusu haricindeki bilgilerin sınıflandırmaya olumsuz etkisi olmaktadır. Bu olumsuz etkiyi ortadan kaldırmak için benzer çalışmalarda olduğu gibi yapılan bu çalışmada da meme yapısı haricindeki etiket bilgisi, gürültüler ve diğer arka plan görüntüleri otomatik olarak mamografi görüntüsünden çıkartılmıştır.

Görüntü ön işleme aşamasında mamografi görüntüsünden çıkartılması gereken gürültü ve etiket bilgilerini içeren örnek bir mamografi görüntüsü Şekil 3.5’de verilmiştir.



Şekil 3.5. Mamografi görüntüsünden çıkarılması gereken alanlar
a) Etiket bilgileri, b-c) Çekim hatası kaynaklı gürültüler [62]

Bu çalışmada çekim hatalarından, çekim ortamından ve benzeri nedenlerden kaynaklanan gürültüler gibi etiket bilgileri de gürültü olarak değerlendirilip arka planla birlikte görüntü ön işleme aşamasında mamografi görüntüsünden çıkartılmıştır. Bu aşamada kullanılan görüntü ön işleme, morfolojik görüntü işleme, görüntü bölütleme kavramları alt başlıklar halinde açıklanmıştır:

3.2.1. Görüntü Ön İşleme

Sayısal görüntü işleme, sayısal görüntülerin bilgisayarlar ve bir algoritma kullanılarak işlenmesidir. Sayısal bir görüntü, belirli bir konuma ve değere sahip sınırlı sayıda elemandan oluşmakta ve bu elemanlara piksel adı verilmektedir [79,80]. M sütun ve N satırdan oluşan dijital bir görüntü, $M \times N$ piksel içermektedir.

Bütün biyomedikal görüntüleme sistemlerinde olduğu gibi mamografi görüntüleri de farklı kaynaklardan etkilenecek gürültü içerebilir. Mamografi görüntülerin içerdiği bu gürültüler hem uzmanları hem de BKDS’ni yanıltabilir. Bu nedenle mamografi görüntülerindeki oluşabilecek gürültüler önceden işlenerek giderilmesi gerekmektedir. Bu amaçla, görüntü özelliklerine göre çeşitli ön işleme yöntemleri uygulanabilir. Ön işlemede, literatürde alçak geçiren filtre, ortalama filtre, gauss filtresi, gabor filtresi, histogram eşitleme, normalizasyon, weiner filtresi ve benzeri filtreleme yöntemleri uygulanmaktadır [81,82]. Bu tez çalışması kapsamında geliştirilen BSAG yöntemi kullanılarak mamografi görüntülerindeki etiket bilgileri ve gürültüler çıkarılmıştır.

Morfolojik görüntü işleme tekniklerini temel alan BSAG yöntemi çalışmanın ilerleyen kısmında ayrıntılı olarak açıklanacaktır.

3.2.2. Morfolojik Görüntü İşleme Yöntemleri

Morfoloji kelimesi genellikle hayvanların ve bitkilerin şeklini ve yapısını inceleyen biyoloji dalını ifade etmektedir. Matematiksel morfoloji veya basitçe morfoloji, uzamsal yapıları analiz eden bir teori olarak tanımlanabilir [83,84]. Morfoloji olarak tanımlanmasının sebebi, nesneleri şekil açısından analiz etmesidir.


Erozyon (aşınma-erosion) ve genişleme (dilation) işlemleri, morfolojik görüntü işlemenin temelini oluşturmaktadır. Çoğu morfolojik algoritma bu iki işleme dayanmaktadır. Basitçe aşındırma, bir görüntüdeki nesnelerin küçültülmesi, inceltilmesi diğer bir ifadeyle aşındırılması işlemidir [85]. Aşındırma işlemi resim içerisindeki nesneler hacimsel olarak daralır, delik mevcutsa genişler, birbirine bağlı nesneler birbirinden kopmaya eğilim gösterirler [86,87].

Aşındırma işlemini denklemle ifade etmek gerekirse:

Z bir tamsayılar kümesi olsun ve Z 'nin içerisinde X kümesi olsun. X 'in B yapılandırma elemanı ile aşınması $X \ominus B$ ile gösterilir ve Eşitlik 3.1'deki gibi z kadar ötelendiğinde B yapılandırma elemanının X içinde olabilecek tüm z noktalar kümesi olarak ifade edilir.


$$X \ominus B = \{Z | (B)Z \subseteq X\} \quad (3.1)$$

B yapılandırma elemanı farklı yapılarda olabilir. 3×3 'lük çeşitli yapısal elemanların örnekleri Şekil 3.6'da verilmiştir.




Şekil 3.6. 3×3 boyutunda yapısal eleman örnekleri

Daha anlaşılır bir şekilde ifade edilecek olursa B yapılandırma elemanının X ile tamamen çakıştığı durumlarda yapılandırma elemanın merkezinin bulunduğu alan işlemde geriye kalan alan, tamamen çakışmayan alanlarda aşındırılan alanlardır. Şekil 3.7'de örnek bir resmin aşındırma işlemi sonucu verilmiştir.



Şekil 3.7. Aşındırma işlemi [85,87–89]

Genişleme işlemi de nesnenin büyütülmesi ve kalınlaştırılması işlemidir. Aşındırma işleminin tersi olarak da düşünülebilir. Bu aşındırma ve genişletme süreçleri, yapılandırma elemanı adı verilen bir model tarafından kontrol edilmektedir. Basitçe genişleme işlemi resim içerisindeki nesneler boyutsal olarak genişler, delik varsa küçülür, birbirinden ayrı nesneler birbirine bağlanma eğilimi gösterir [86,87]. Şekil 3.8’de genişleme işlemi uygulanmış bir örnek verilmiştir.



Şekil 3.8. Genişleme işlemi [85,87–89]

Çalışmada, meme dokusu ile ilgili olmayan etiket üzerindeki ve diğer gürültülerin aşındırılarak yok edilmesi için 50x50 boyutunda yapı elemanı kullanılmıştır. Bu piksel aralığında yapı elemanı kullanılmasının nedeni 1024x1024 boyutundaki mamografi görüntüsündeki yok edilmesi gereken gürültülerin en fazla 100x100 piksel olarak kabul edilmiş olmasıdır. Her piksel için yeni değer, yapı elemanı ile örtüşen/kesişen piksel değerlerine göre belirlenmiştir. Yapı

elemanı ile kesişen/örtüşen alan küçükten büyüğe sıralanmış ve tuz biber adı verilen gürültüleri elimine etmek amacı ile ilk değer kullanılmamış yerine onuncu sıradaki değer atanmıştır. Bu yöntemle <100 piksel genişliğinde veya yüksekliğindeki arka planın ortasında kalan istenmeyen alanlar aşındırma ile yok edilmiştir.

Uygulanan yöntemi açıklamak amacıyla Şekil 3.9.a'da 5x5 boyutunda bir yapı elemanı, Şekil 3.9.b'de 8x8 boyutundaki görüntüye ait değerler verilmiştir. Verilen bu örnekle tez çalışmasında kullanılan görüntüyü ön işleme aşaması açıklanmıştır.

1	1	1	1	1
1	1	1	1	1
1	1	1	1	1
1	1	1	1	1
1	1	1	1	1

a

2	3	2	2	4	4	4	4
3	3	5	22	223	223	223	223
5	5	<u>155</u>	22	221	221	221	221
5	4	5	22	221	221	221	221
5	4	4	11	222	222	222	222
2	4	4	11	222	222	222	222
2	3	3	10	232	232	232	232
3	3	3	33	232	232	232	232


b

Şekil 3.9. a) 5x5 boyutunda yapı elemanı, b) 8x8 piksellik görüntünün sayısal gösterimi


155 değerinin olduğu piksel belirlenirken yapı elemanın (a) altında kalan (kırmızı tablo) değerler aşağıdaki gibi sıralandığı düşünülürse:

2, 2, 2, **3**, 3, 3, 4, 4, 4, 4, 4, 5, 5, 5, 5, 5, 5, 11, 22, 22, 22, 155, 221, 221, 222, 223

25 adet sayının içinde birinci sıradakini almak yerine dördüncü sıradaki alınarak 15 değerine sahip ilgili piksel 3 değeri ile güncellenir. Böylece mamografi görüntüsündeki arka planı belirten siyah kısımların içindeki küçük parçalar aşındırılarak yok edilir. Bu yöntemle aşındırılarak meme dokusu haricindeki gürültüleri yok edilmiş örnek bir mamografi görüntüsü Şekil 3.10.b'de verilmiştir.



a




b


Şekil 3.10. a) MIAS veri tabanından alınan mamografi görüntüsü, b) Aşındırma yöntemi ile etiketlerden arındırılmış görüntü [62]

Etiket bilgisi çıkartılan görüntü (Şekil 3.10.b) eşik değeri uygulanıp binary görüntüsü elde edilmiştir. Elde edilen bu binary görüntü kullanılarak kenarları aşınmış memenin aşınan kenarları geri kazanılmıştır.

Etiket bilgisi çıkartılmış ve binary formata dönüştürülmüş görüntü Şekil 3.11’de verilmiştir.



a




b

Şekil 3.11. a) Kenarları aşınmış binary görüntü, b) Aşınan kenarları geri kazanılmış binary görüntü

Aşındırma işleminde kullanılan aynı yapı elemanı ile genişletme işlemi uygulayarak aşınan kenarlar, aşındığı miktar kadar geri kazanılmıştır. Genişletme işlemi esnasında yine tuz-biber gürültülerinden etkilenmemek için en yüksek değeri yerine en yüksek değere yakın onuncu değer kullanılmıştır. Son aşamada Şekil 3.11.b de verilen binary şablon kullanılarak işlenmemiş mamografi görüntüsü eşlenerek arka planda bulunan tüm gürültüler yok edilmiştir.

Meme dokusu dışındaki istenmeyen alanları yok edilen örnek bir mamografi görüntüsü Şekil 3.12’de verilmiştir.



Şekil 3.12. Arka plan gürültülerinden ve etiket bilgilerinden arındırılmış mamografi görüntüsü [62]


3.2.3. Görüntü Bölütleme

Karmaşık görüntüler için bölütleme süreci, görüntü işlemenin en önemli adımlarından biridir. Görüntü bölütleme kavramı, görüntüyü kendi içinde farklı nitelikleri barındıran anlamlı parçalara ayırmak olarak tanımlanabilir [72]. Görüntü bölütleme görüntünün bir veya daha fazla kriteri ile bağlantılı olabilen çeşitli bölgelere bölünmesi olarak tarif edilebilir. Görüntü bölütleme, genellikle resimlerdeki nesneleri ve sınırları bulmak için kullanılmaktadır [72]. Örneğin görüntü içindeki birbirine benzer parlaklıklar mevcut olabilir. Bu parlak yapılar görüntünün birbirinden farklı kısımlarındaki nesneleri işaret edebilmektedir. Bölütleme algoritmaları genellikle görüntü yoğunluğu değerlerine bağlı olan iki ana özelliğe dayanır. Biri süreksizlik (discontinuity), diğeri benzerliktir (similarity) [90]. Süreksizliğe bağlı bölütleme, bir görüntüdeki yoğunluk değerlerinin,

ani deęişimine dayanırken, benzerliğe dayalı bölümleme, önceden tanımlanmış kurallara göre görüntünün bölümlemesine dayanmaktadır.

Çalışmada mamografi görüntüleri, görüntü yoğunluęuna baęlı kalmaksızın hekim tarafından şüpheli görülen bölgenin seçilmesiyle kırpılır. Hekim tarafından işaretlenen nokta merkez alınarak 224x224 piksel boyutunda pencerenin altında kalan alanın kırılması ile bölütleme işlemi gerçekleştirilir. Şüpheli görülen alan daha önceden eğitilmiş sinir aęı tarafından sınıflandırılması istenir. Böylece hekim tarafından seçilen bölge sinir aęı tarafından kistli bölge, kalsifikasyon içeren bölge, ya da normal bölge olarak sınıflandırılır.

Sinir aęı girdisi olarak kullanılan görüntüler kayan pencere yöntemi ile tamamen meme bölgesini içeren alanlar bütünüyle seçilebilir. Tüm seçilen alanlar sinir aęı tarafından sınıflandırılması istenebilir. Şekil 3.13’de kayan pencere modeli verilmiştir.



Şekil 3.13. Kayan pencere işlemi [91]

224x224 piksellik pencerenin içinde arka plan yer almayan bölütler kırılarak sinir aęı girdisi olarak kullanılır.

Şekil 3.14’de verilen resimde kırmızı ve mavi pencere altında kalan alan arka plan bölgesi içerdiği için kullanılmamıştır. Yeşil olarak işaretlenmiş pencerenin altında kalan alan arka plan bölgesi içermediği için sinir ağı girdisi olarak kullanılmak üzere kırılmıştır.



Şekil 3.14. Kayan pencere yöntemi ile kesitlere ayrılan görüntü

3.3. Öznitelik Çıkarma

Görüntü hakkında bilgi veren; görüntüdeki gözlemlenebilir her türlü veri o görüntünün bir özniteliğidir. Bu öznitelikler görüntüdeki doku, istatistiksel ve yapısal özellikler olabilir. Sınıflandırmanın başarısı, görüntüyü en iyi temsil eden özniteliklerin çıkartılmasına (extraction) bağlıdır.

Mamogramlardaki anormallikler için birçok öznitelik çıkarılmıştır. Doku özelliğinin özniteliklerinin çıkarılması, mamogramların doğası gereği anormalliklerinin tespit edilmesinde çok önemlidir. Doku özelliklerinin, kitleleri ve normal meme dokularını ayırt etmede faydalı olduğu kanıtlanmıştır [92]. Bu alanda yapılan çalışmalarda kitle teşhisi için birçok farklı yapıda öznitelik önerilmiştir [93]. Bu çalışmalar incelendiğinde kitle sınıflandırmak için kullanılan temel özelliklerin genellikle doku ve şekil özellikleri olduğu görülmektedir.

Çalışmada mamografi görüntüleri yapay sinir ağları kullanılarak normal, kist içeren veya kalsifikasyon içeren şekilde sınıflandırılmıştır. Özellikle görüntü işlemede derin öğrenme modellerini ön plana çıkaran özelliğin sınıflandırmayla birlikte öznitelik çıkarmayı da kendi içinde

yapabiliyor olmasıdır. Bu çalışmada da öz nitelik çıkarma işlemi sunulan derin öğrenme modeli ile yapılmaktadır.

3.4. Derin Öğrenme

Derin öğrenme; beyindeki nöron yapısını taklit ederek, görüntü işleme problemleri başta olmak üzere birçok problemin çözümünde farklı derin sinir ağı mimarilerini kullanan bir makine öğrenme dalıdır [94].


Makine, farklı katmanları kullanarak verilerden öğrenmek ister. Modeldeki katman sayısı Modelin derinliğini belirler. Derin öğrenme kavramı, yapay zekânın en son teknoloji olarak tanımlanabilir. Derin öğrenmede, öğrenme aşaması bir sinir ağı aracılığıyla yapılır. Derin sinir ağları öğrenmenin gerçekleştiği sinir ağı katmanların üst üste yığılması ile oluşturulan bir mimaridir. Yapay zeka, makine öğrenmesi, derin öğrenme kavramları arasındaki ilişki Şekil 3.15’de verilmiştir.



Şekil 3.15. Yapay zekâ, makine öğrenmesi, derin öğrenme

Derin sinir ağı eğitiminin temel yapısı; ağın her katmanının ön eğitime ve bu katmanın çıktısının sonraki katmanda girdi olarak kullanılmasına dayanmaktadır [95]. Makine öğrenmesinde sınıflandırma için gerekli olan özellikler manuel olarak tanımlanırken derin öğrenmede bu özellikler otomatik olarak öğrenilir.

Şekil 3.16’da makine öğrenmesi ve derin öğrenmeyi temsil eden bir şema verilmiştir [96].




Şekil 3.16. Makine öğrenmesi ve derin öğrenme yöntemlerinde görüntü sınıflandırma [96,97]

Günümüzde görüntü işleme çözümlerinde derin öğrenme algoritmaları ön plana çıkmıştır. Bu tez çalışmasında derin öğrenmenin bir alt kategorisi olan ve özellikle görüntü işlemede kullanılan ESA ile öznelilik seçimi ve sınıflandırma işlemi yapılmıştır.

ESA, YSA’nın bir kategorisi olarak ifade edilebilir. Görüntü tabanlı nesne tanıma uygulamalarında yüksek sınıflandırma başarısıyla günümüzde oldukça yaygındır [98–100]. Uçtan uca öğrenme mimarisi ile hem özellik çıkarma, hem de sınıflandırma imkânı sağlamaktadır [98].

Genel olarak, ESA mimarisi evrişim (convolution), havuzlama (pooling) ve tam bağlantılı katmanlar (fully connected layers) olmak üzere üç temel katman içermektedir [101].




Şekil 3.17. ESA yapısı [102,103]

Şekil 3.17’de verilen ESA yapısında eğitim, geleneksel geri yayılma algoritması ile gerçekleştirilmekte ve sınıflandırma da tam bağlı katmanda yapılmaktadır. Makine öğrenmesine kıyasla daha fazla eğitim verisine, daha gelişmiş donanıma, daha uzun eğitim süresine ihtiyaç duyulmaktadır [99,104]. ESA’nda kullanılan katmanları ve özelliklerini kısaca tanımlayacak olursak:

Evrişimsel katman (convolutional layer) özelliklerin tespit edilmesi için kullanılır. ESA’nın en temel yapısı olarak değerlendirilmektedir. Bu katmanda giriş görüntüsüne çeşitli filtreler uygulanarak görüntünün farklı özellikleri çıkartılır. Filtre uygulanarak elde edilen yeni matrislere özellik haritası (feature map) denir [98].

Şekil 3.18’de girdi resmine uygulanan filtre (kernel) ile oluşturulan özellik haritası örnek olarak verilmiştir.



Şekil 3.18. Evrişim katmanı işlemi [129]

Genelde ilk katmanda daha basit özellikler tespit edilirken sonraki katmanlarda daha özellikli nitelikler tespit edilir. Bu özellikler bu katmanda kullanılan her biri farklı özelliği ortaya çıkaran çeşitli filtreler kullanılarak yapılır [104].


Aktivasyon Katmanı (Non-Linearity Layer) genellikle evrişimsel katmandan sonra kullanılır [105]. Derin sinir ağındaki tüm katmanlar doğrusal bir fonksiyon olabildiğinden, sonuç çıktıların lineer bir kombinasyonu olarak hesaplanabilir. Gerçek dünyanın doğrusal olmayan özelliklerini yapay sinir ağlarına dâhil etmek için doğrusal olmayan bir aktivasyon fonksiyonuna ihtiyaç duyulmaktadır. Eğer ağına çıkışına aktarılan değere aktivasyon fonksiyonu kullanılmazsa çıkıştaki sinyal doğrusal bir fonksiyon olur [105]. Bu durumda sinir ağı kısıtlı öğrenme yetisine sahip olacaktır. Böylece sinir ağı lineer regression davranışı gösterecektir.

Genellikle sigmoid, tanjant hiperbolik fonksiyonu (tanh), rectifier fonksiyonu (ReLU) ve türevleri gibi doğrusal olmayan aktivasyon fonksiyonlarından biri tercih edilir. Günümüzde görüntü işleme çalışmalarında aktivasyon fonksiyonu olarak genellikle hızlı ile ön plana çıkan ReLU tercih edilmektedir [99,106].

ReLU fonksiyonu negatif ekseninde 0 değerini aldığından sigmoid fonksiyonu benzeri fonksiyonlara göre ağı daha hızlı çalışmasını sağlar [107]. Bu da hesaplama yükünün bir hayli fazla olduğu görüntü işleme çalışmalarında ReLU aktivasyon fonksiyonunu oldukça popüler hale getirmiştir.

Eşitlik 3.2'deki gibi ifade edilen ReLU fonksiyonuna ait grafik Şekil 3.19'da verilmiştir.


$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.2)$$



Şekil 3.19. ReLU aktivasyon fonksiyonu [108,109]

Havuzlama(Pooling) katmanı ile ağ içindeki parametreler ve hesaplama sayısının azaltılması amaçlanmaktadır. Genel olarak her evrimsel katmanın sonunda kullanılmaktadır. Average pooling, ve L2-norm pooling gibi birçok havuzlama yöntemi olsa da özellikle görüntü işlemede en sık kullanılan maxpooling yöntemidir [110–112]. Bu tez çalışmasında da maxpooling yöntemi kullanılmıştır.

Maxpooling yönteminde matrisin altında kalan görüntüye ait en büyük değer seçilir. Böylelikle görüntüden temsili değerler alınarak görüntü boyutu daha da küçültülerek örneklenmiş olur. Şekil 3.20'de MaxPooling işlemini temsilen bir şema verilmiştir.




Şekil 3.20. MaxPooling ile havuzlama örneği [113]

Batchnormalization, modern sinir ağılarında her katman girişinden önce verileri normalize etmek için kullanılan bir görüntü ön işleme yöntemidir [100]. Düzenleyici etkiye ek olarak, eğitim sırasında YSA'nın tükenme gradyanına karşı koyarak, eğitim süresini kısaltabilmekte ve model performansını arttırmaktadır [114].

Şekil 3.21'de verilen batchnormalization yapısının formülünü Eşitlik 3.3'deki gibi tanımlayabiliriz:

$$z^N = \left(\frac{z - m_z}{s_z} \right) \quad (3.3)$$

m_z nöron çıktısının ortalamasını, s_z nöron çıktısının standart sapmasını, z nöronun çıktısını, z^N normalize edilmiş nöron çıktısını ifade etmektedir.



Şekil 3.21. Batchnormalization yapısı

Batchnormalization olmadan nöronlar Eşitlik 3.4 ve Eşitlik 3.5 ile hesaplanmaktadır.

$$z = g(w, x) + b \quad (3.4)$$

$$a = f(z) \quad (3.5)$$

$g()$: nöronun lineer dönüşümünü, w : nöronun ağırlıklarını, b : bias değerini, $f()$: aktivasyon fonksiyonunu göstermektedir.

Batchnormalization ile hesaplama Eşitlik 3.6-8 ile hesaplanmaktadır:

$$z = g(w, x) \quad (3.6)$$


$$z^N = \left(\frac{z - m_z}{s_z} \right) \gamma + \beta \quad (3.7)$$

$$a = f(z^N) \quad (3.8)$$

z^N : batch normalizasyonun çıktısını, m_z : nöron çıktısının ortalamasını, s_z : nöron çıktısının standart sapmasını, γ ve β öğrenme parametrelerini gösterir.

ESA'nda birden fazla evrişimsel katman kullanılır. Her evrişimsel katmandan sonra katman çıktısı aktivasyon, normalizasyon, havuzlama ve benzeri fonksiyonlarla bir sonraki katman için hazırlanır.

Sadece bir evrişimsel katmanı ve sonrasında kullanılan fonksiyonları temsil eden şema Şekil 3.22’de verilmiştir.



Şekil 3.22. Örnek bir evrişimsel katman takımı


Çalışmada, bu alandaki en etkili DSA yapılarından olan AlexNet ve GoogLeNet ile birlikte çalışma kapsamında geliştirilen MKESAS modeli kullanılarak sınıflandırma başarıları karşılaştırılmıştır. Kullanılan modellerin ağ yapıları ve sınıflandırma başarıları tezin ilerleyen bölümlerinde ayrıntılı olarak anlatılmıştır.

3.5. Sınıflandırma

Sınıflandırma, verinin sahip olduğu özelliklerle farklı özellikte olanlardan ayırt edilmesi şeklinde tanımlanmaktadır. Çalışmada mamografi kesitleri normal, kist, kalsifikasyon şeklinde sınıflandırılmıştır. Evrişimsel katmanda öznetelikleri çıkartılan verinin sınıflandırma işlemi bu katmanda yapılır.

3.5.1. Tam Bağlı Katman

Tam bağlı katman (Fully-Connected Layer) sınıflandırma için kullanılan en son aşamadaki standart sinir ağı katmanıdır. Şekil 3.23’de de görüldüğü gibi bu katmandaki nöronların hepsi önceki katmandaki aktivasyonların bütününe tamamen bağlı durumdadır [115]. Sınıflandırmayı sağlayacak olan özneliklerin hangi sınıfla ilgili olduğu bu katmanla belirlenmektedir [116,117].



Şekil 3.23. Tam bağlı katman yapısı [118]

Çalışmada 1024x1024x3 piksel boyutundaki mamografi görüntülerinden alınan 224x224x3 ve 227x227x3 piksel boyutundaki kesitler ESA’ya sunulan girdi verisidir. Tam bağlı katman bu verilerin çeşitli filtreler kullanılarak çıkartılan özneliklerine göre sınıflara ayrıldığı katmandır.

3.5.2. Softmax Fonksiyonu

Softmax fonksiyonu yapı olarak Sigmoid fonksiyonuna çok benzer. Tıpkı sigmoid gibi bir sınıflandırıcı olarak kullanıldığında oldukça iyi sonuçlar üretir [119]. 0 ile 1 aralığında değerler üreterek belirli bir sınıfa ait bir girdinin olasılığını belirler [120]. Yani olasılıksal bir yorum gerçekleştirir. Softmax işlevi, N boyutlu bir girdi vektörünü alır ve (0, 1) aralığında toplam 1.0'a kadar gerçek değerlere sahip başka bir N boyutlu çıktı vektörü üretmektedir [121]. Eşitlik 3.9 ve Eşitlik 3.10 ‘da verilen denklemlerle ifade edilmektedir.

$$S(a) : \begin{bmatrix} a_1 \\ a_2 \\ \dots \\ a_N \end{bmatrix} \rightarrow \begin{bmatrix} S_1 \\ S_2 \\ \dots \\ S_N \end{bmatrix} \quad (3.9)$$

$$S_j = \left(\frac{e^{a_j}}{\sum_{k=1}^N e^{a_k}} \right) \quad (3.10)$$


3.6. Çalışmada Kullanılan Derin Öğrenme Modelleri

Bu çalışmada görüntü işlemede oldukça yaygın olarak kullanılan AlexNet, GoogLeNet derin öğrenme modellerinin yanı sıra çalışma kapsamında geliştirilen MKESAS modeli kullanılmıştır. Kullanılan ağ modelleri alt başlıklar halinde açıklanmıştır:

3.6.1. AlexNet

2012 yılındaki IMAGENET yarışmasının kazananı büyük bir farkla AlexNet derin öğrenme modeli olmuştur. Yapılan çalışma “ImageNet Classification with Deep Convolutional Networks” (Krizhevsky, Sutskever et al. 2012) isimli makale ile yayınlanmıştır. Alex Krizhevsky, Ilya Sutskever and Geoffrey Hinton tarafından geliştirilen bu derin öğrenme modeli ile görüntü sınıflandırma probleminde bir kırılma noktası olmuş ve ESA görüntü işlemede popülerlik kazanmıştır [122,123]. Temel olarak birbirini takip eden evrişim ve havuzlama katmanlarından oluşmaktadır.

Aktivasyon fonksiyonu olarak ReLU, havuzlama katmanlarında da max-pooling kullanılan AlexNet mimarisi Şekil 3.24’de verilmiştir.



Şekil 3.24. AlexNet ağ mimarisi [124]

Şekil 3.24’de görüldüğü gibi mevcut AlexNet modeli ile 1000 ayrı sınıflandırma yapılmaktadır. Bu çalışmada 3 ayrı sınıflandırma yaptığımızdan mevcut modelin son katmanları da 3 sınıflandırma yapacak şekilde revize edilmiştir.

3.6.2. GoogLeNet


GoogLeNet mimarisi, AlexNet ve benzeri mimarilerden çok farklıdır. 1×1 evrişim ve daha derin bir mimari oluşturmasını sağlayan küresel ortalama havuzlama gibi birçok farklı yöntem kullanılmaktadır.

GoogLeNet Inception modüllerinden dolayı karmaşık bir yapıya sahiptir. Inception modülü, GoogLeNet’i AlexNet gibi önceki modellerin mimarilerden ayıran en önemli özelliğidir. Bu mimaride her katman için sabit bir evrişim (1×1 , 3×3 , 5×5 evrişim ve 3×3 max pooling) boyutu vardır. Farklı boyutlardaki evrişim filtrelerinin arkasındaki fikir, nesneleri birden çok ölçekte daha iyi işleyecek olmasıdır [125].

GoogLeNet, sıralı şekilde gelen evrişimsel katmanların üst üste istiflenmesiyle oluşturulan klasik DSA modellerinden oldukça farklı ESA mimarilerinden birisidir. Katmanların hepsini istiflemek ve birçok filtre eklemek, hesaplama yükünü ve bellek ihtiyacını arttıracığından GoogLeNet paralel olarak birbirine bağlı filtreler kullanarak kısmen bu durumun üstesinden gelmiştir. 22 katmandan oluşan GoogLeNet %5,7 hatayla 2014 yılındaki ImageNet birincisidir [126].



Şekil 3.25’de GoogLeNet ağ mimarisinin ilk seri katmanları ve ilk insepction yapısı verilmiştir. Ağ çok geniş olduğundan burada tamamı verilememiştir. Ağın tamamına uygulamada kullandığımız Matlab R2020 Deep Learning Toolbox ile ulaşılabilir.



Şekil 3.25. GoogLeNet ağ mimarisi (ilk seri katmanlar ve ilk insepction)


3.6.3. MKESAS

Mamografi kesitlerinin sınıflandırılması için bu çalışmada geliştirilen sinir ağı modeli eğitilmiş ve sınıflandırma başarısı uygulaması yapılan diğer modellerle karşılaştırılmıştır. MKESAS modeli ile yapılan uygulamada AlexNet, GoogLeNet gibi diğer ESA modellerine kıyasla daha kısa sürede daha yüksek doğruluk elde edilmiştir. Ağ modellerinin eğitim sonuçları tezin ilerleyen kısımlarında verildiğinden bu kısımda sonuçlarla ilgili detaylara yer verilmemiştir.

Tasarlanan MKESAS modelinde aşırı öğrenmeyi engellemek için 2 tam bağlı katman arasında dropout katmanı kullanılmıştır. Her evrişimsel katmandan sonra aktivasyon fonksiyonu olarak ReLU fonksiyonu kullanılmıştır. İlk iki evrişimsel katmanın sonunda havuzlama katmanı olarak da maxpooling tercih edilmiştir.



Temel olarak 4 farklı evrişimsel katman, her katmanda batchnormalization, ReLuLayer; ilk iki katmanda da Maxpooling katmanının yer aldığı MKESAS ağ mimarisinin görseli Şekil 3.26’da verilmiştir.



Şekil 3.26. MKESAS ağ mimarisi

4. DENEYSEL ÇALIŞMALAR

Meme kanserinin tespitinde hekimlere yardımcı olması amacıyla çalışma kapsamında geliştirilen BKDS'nin eğitimi ve testi için kullanılan mamografi görüntüleri MIAS, DDSM, INBREAST ve FSSH olmak üzere 4 farklı kaynaktan temin edilmiştir. Aynı zamanda bu görüntüler kullanılarak MKESAS ile birlikte AlexNet ve GoogLeNet sinir ağı modelleri de eğitilmiş doğruluk oranları, eğitim süreleri karşılaştırılmıştır.

Bu veri tabanlarından alınan mamografi görüntülerinin sayıları ve özellikleri Tablo 4.1 de verilmiştir.

Tablo 4.1. Veri tabanlarından alınan görüntü sayıları


Veri Tabanı	Kist İçeren	Kalsifikasyon İçeren	Normal	Toplam
MIAS	52	63	70	185
DDSM	67	60	80	207
INBREAST	50	50	40	140
FSSH	31	30	30	91
TOPLAM	200	203	220	623

Tablo 4.1'de de görüldüğü gibi 4 farklı veri tabanından 200 kist içeren görüntü, 203 kalsifikasyon içeren görüntü, 220 adet de normal görüntü olmak üzere toplamda 623 adet görüntü çalışmada kullanılmıştır.

Çalışmanın ön işleme adımında görüntülerin iyileştirilmesi ve istenmeyen bölgelerin (etiket bilgilerinin ve diğer gürültülerin) çıkartılması amacıyla çalışma kapsamında geliştirilen BSAG yöntemi kullanılmıştır. Kullanılan bu yöntem ile çalışmada kullanılan mamografi görüntülerinin tamamı etiket bilgisi ve gürültülerden arındırılmıştır. Materyal ve metot bölümünde anlatıldığı için BSAG yöntemine ilişkin detaylara bu bölümde yer verilmemiştir.

Her bir görüntü türünden 224x224x3 ve 227x227x3 piksel boyutunda kist, kalsifikasyon ya da normal bölge kırpılarak sinir ağının eğitimi için veri seti hazırlanmıştır. Görüntüyü kırpmak için kullanılan pencere, ilgili bölge merkeze alacak şekilde x, y koordinatlarında hareket ettirilerek ilgili bölgeden 4 ila 9 arasında görüntü kırpılmıştır. Kırpılan bu görüntüler ile kist, kalsifikasyon ve normal görüntülerin her birinden 1000 adet olmak üzere toplamda 3000 adet kesit sinir ağlarının eğitimi ve testi için kullanılmıştır. Eğitilen modellerde tüm verilerin %75'i eğitim, %25'i test için

kullanılmıştır. Sinir ağının eğitimi ve testi için kullanılan kırpılmış görüntüler Şekil 4.1 de örnek olarak verilmiştir. Şekil 4.1 de verilen örnek görüntülerin ilk dördü kalsifikasyon içeren, ikinci dördü kist içeren, son dördü normal olan görüntülerin örnekleridir.



Şekil 4.1. 224x224 piksel boyutunda örnek kesitler(kalsifikasyon-kist-normal)

Bu çalışmada 4 farklı veri tabanından toplam 623 adet mamografi görüntüsü kullanılmıştır. 3 ayrı sınıfın (kist, kalsifikasyon, normal) her birinde 1000 adet olacak şekilde toplam 3000 adet kesit 3 farklı sinir ağı modelinin eğitimi ve testi için kullanılmıştır. Bu çalışmalar Intel(R) Xeon(R) Gold 5120 CPU @ 2.20GHz 2.19 GHz (2 işlemci), 32GB Ram, Nvidia Geforce GTX 1650 ti 4GB GPU, 236 GB SSD – donanımlarına sahip bilgisayar üzerinde Matlab 2020 64 bit programı ile yapılmıştır. Elde edilen sonuçlar alt başlıklar halinde aşağıda verilmiştir.

4.1. AlexNet ESA Modeli Eğitim Sonuçları

AlexNet sinir ağı modelinde veri girişleri 227x227x3 piksel olduğu için yine aynı boyuttaki 3 kategorideki toplam 3000 adet kesit veri girişi olarak kullanılmıştır. Imagenet verileri ile eğitilen AlexNet, GoogLeNet ve benzeri modeller 1000 adet sınıflandırma yapabilecek şekilde tasarlanmıştır. Tez çalışması kapsamında gerçekleştirilen uygulamada verileri kist, mikro


kalsifikasyon ve normal olarak 3 ayrı sınıfa ayıracağımızdan bu modellerin sınıflandırma katmanlarının revize edilmesi gerekmektedir. AlexNet sinir ağının 1024 olan 2. tam bağlı katman değeri 27, 1000 olan son bağlı katman ve çıkış katman değeri 3 olarak revize edilmiştir. Böylece AlexNet ESA modeli mevcut verilerle sınıflandırma yapabilecek yeterliliğe getirilmiştir. Tablo 4.2 de revize edilen ağ modeli analizi, Şekil 4.2’de ESA modelinin eğitim sürecini gösteren grafik verilmiştir. 3 sınıflandırma yapabilecek şekilde uyarlanan AlexNet ağ modeli ile 2 dakika 12 saniyede %95,55 doğruluk oranına ulaşılmıştır.

Ayrıca ideal bir sinir ağının kayıp değerinin 0’a yaklaşması beklenir. Problemin gerçek değeri ile modelin tahmin ettiği değer arasındaki aralık olarak ifade edebileceğimiz kayıp değeri ne kadar 0’a yaklaşırsa modelin yaptığı tahminlerde o kadar küçük hatalar yapılmış demektir. Şekil 4.2 de AlexNet modelinin kayıp değerinin eğitim sonuna doğru 0,1 civarında olduğu görülmektedir.

Tablo 4.2. Revize edilen AlexNet ağ analizi

Sıra	Ağ İsmi	Ağ Tipi	Boyut
1	imageinput 227x227x3, zerocenter normalization	Giriş	227x227x3
2	conv_1 96 11x11x3 convolutions, stride [4 4], padding [1 1 1 1]	Evrişimsel Katman	55x55x96
3	relu_1	ReLU	55x55x96
4	norm_1	Cross Channel N.	55x55x96
5	maxpool_1 3x3 maxpooling, stride [2 2], padding [0 0 0 0]	Max Pooling	27x27x96
6	conv_2 2 grup, 128 5x5x48 convolutions, stride [1 1], padding [2 2 2 2]	Grup Evrişimsel Katman	27x27x256
	relu_2	ReLU	27x27x256
7	norm_2	Cross Channel N.	27x27x256
8	maxpool_2 3x3 maxpooling, stride [2 2], padding [0 0 0 0]	Max Pooling	13x13x256
9	conv_3 384 3x3x256 convolutions, stride [1 1], padding [1 1 1 1]	Evrişimsel Katman	13x13x384
10	relu_3	ReLU	13x13x384
11	conv_4 2 drup 192 3x3x192 convolutions, stride [1 1], padding [1 1 1 1]	Grup Evrişimsel Katman	13x13x384
12	relu_4	ReLU	13x13x384
13	conv_5 2 drup 128 3x3x192 convolutions, stride [1 1], padding [1 1 1 1]	Grup Evrişimsel Katman	13x13x256
14	relu_5	ReLU	13x13x256
15	batchnorm_5	Normalizasyon	8x8x32
16	maxpool_5 3x3 maxpooling, stride [2 2], padding [0 0 0 0]	Max Pooling	6x6x256
17	fc_6	Tam Bağlı Katman	1x1x4096

Sıra	Ağ İsmi	Ağ Tipi	Boyut
	4096 tam bağlı katman		
18	relu_6	ReLU	1x1x4096
19	dropout_6 %50 dropout	Dropout	1x1x4096
20	fc_7 27 tam bağlı katman	Tam Bağlı Katman	1x1x27
21	relu_7	ReLU	1x1x27
22	dropout_7 %50 dropout	Dropout	1x1x27
23	fc_8 3 tam bağlı katman	Tam Bağlı Katman	1x1x3
24	softmax	Softmax	1x1x3
25	classoutput kist, calc, normal	Sınıflandırma Katmanı	



Şekil 4.2. AlexNet eğitim süreci grafiği

4.2. GoogLeNet ESA Modeli Eğitim Sonuçları


GoogLeNet sinir ağı modelinde veri girişleri 224x224x3 piksel olduğu için yine aynı boyutlarda hazırlanmış mamografi görüntülerinden elde edilmiş 3000 adet kesit veri girişi olarak kullanılmıştır. AlexNet modelinde olduğu gibi GoogLeNet modelinin 1000 olan sınıflandırma katmanı (tam bağlı katman) ve çıkış katmanı 3 olarak revize edilmiştir. Tablo 4.3’de revize edilen GoogLeNet modelinin giriş katmanlarına ve ilk insepction katmanına ait ağ analizi verilmiştir.

3 sınıflandırma yapabilecek şekilde uyarlanan GoogLeNet ESA modeli kist, mikro kalsifikasyon ve normal dokulardan oluşan veri seti ile eğitilmiştir. Veri setinin %75’i eğitim, %25’i test için kullanılmıştır. 5 dakika 42 saniye süren eğitim sonucunda %96 doğruluk oranına ulaşılmıştır. Şekil 4.3 de GoogLeNet ESA modelinin eğitim sürecini gösteren grafik verilmiştir. Bu grafikte ayrıca 0’a yaklaşan (0,1 civarında) kayıp değeriyle AlexNet modeline yakın bir sonuç üretmiştir.

Tablo 4.3. Revize edilen GoogLeNet network analizi

Sıra	Ağ İsmi	Ağ Tipi	Boyut
1	imageinput 224x224x3, zerocenter normalization	Giriş	224x224x3
2	conv1-7x7_s2 64 7x7x3 convolutions, stride [2 2], padding [3 3 3 3]	Evrişimsel Katman	112x112x64
3	conv1_relu_7x7	ReLU	112x112x64
4	pool1_3x3_s2 3x3 maxpooling, stride [2 2], padding [0 1 0 1]	Max Pooling	56x56x64
5	pool1_norm1 128 10x10x32 convolutions, stride [1 1], padding ‘same’	Cross Chan. Norm	56x56x64
6	conv2-3x3_reduce 64 1x1x64 conv. stride [1 1], padding [1 1 1 1]	Evrişimsel Katman	56x56x64
7	conv2-relu_3x3_reduce	ReLU	56x56x64
8	conv2-3x3 192 3x3x64 maxpooling, stride [2 2], padding [0 0 0 0]	Evrişimsel Katman	56x56x192
9	conv2-relu_3x3	ReLU	56x56x192
10	conv2-norm2	Cross Chan. Norm	56x56x192
11	pool2-3x3_s2 3x3 maxpooling, stride [2 2], padding [0 1 0 1]	Max Pooling	28x28x192
12	insepction_3a-pool 3x3 maxpooling, stride [1 1], padding [1 1 1 1]	Max Pooling	28x28x192
13	insepction_3a-pool_proj 32 1x1x192 maxpooling, stride [1 1], padding [0 0 0 0]	Evrişimsel Katman	28x28x32
14	insepction_3a-5x5 reduce 16 1x1x192 stride [1 1], padding [0 0 0 0]	Evrişimsel Katman	28x28x16

Sıra	Ağ İsmi	Ağ Tipi	Boyut
15	inseption_3a-relu_5x5 reduce	ReLU	28x28x16
16	inseption_3a-5x5 32 5x5x16 stride [1 1], padding [2 2 2 2]	Evrişimsel Katman	28x28x32
17	inseption_3a-3x3_reduce 96 1x1x192 stride [1 1], padding [0 0 0 0]	Evrişimsel Katman	8x8x32
18	inseption_3a-relu_3x3 reduce	ReLU	28x28x96
19	inseption_3a-1x1_reduce 64 1x1x192 stride [1 1], padding [0 0 0 0]	Evrişimsel Katman	28x28x64
20	inseption_3a-relu_1x1	ReLU	28x28x64
21	inseption_3a-relu_5x5	ReLU	28x28x32
22	inseption_3a-3x3 128 3x3x96 conv. stride [1 1], padding [1 1 1 1]	Evrişimsel Katman	28x28x128
23	inseption_3a-relu_3x3	ReLU	28x28x128
24	inseption_3a-relu_pool_proj	ReLU	28x28x32
25	inseption_3a-output	Deep concatenation	
26...143	...	...	...
144	Sınıflandırma kist, kalsifikasyon, normal	Çıktı	



4.3. MKESAS Modeli Eğitim Sonuçları

224x224x3 piksel boyutlarındaki mamografi kesitlerinin başarıları kanıtlanmış AlexNet ve GoogLeNet ESA modellerine kıyasla daha kısa sürede eğitilebileceği daha sıkı bir sinir ağı modeli geliştirilmiştir. Tablo 4.4’de geliştirilen sinir ağı modelinin ağ analizi verilmiştir.


Tablo 4.4. MKESAS ağ analizi

Sıra	Ağ İsmi	Ağ Tipi	Boyut
1	imageinput 227x227x3, zerocenter normalization	Resim Girişi	227x227x3
2	conv_1 32 11x11x3 convolutions, stride [3 3], padding [1 1 1 1]	Evrişimsel Katman	73x73x32
3	batchnorm_1	Normalizasyon	73x73x32
4	relu_1	ReLU	73x73x32
5	maxpool_1 3x3 maxpooling, stride [2 2], padding [0 0 0 0]	Max Pooling	36x36x32
6	conv_2 128 10x10x32 convolutions, stride [1 1], padding ‘same’	Evrişimsel Katman	36x36x128
7	batchnorm_2	Normalizasyon	36x36x128
8	relu_2	ReLU	36x36x128
9	maxpool_2 3x3 maxpooling, stride [2 2], padding [0 0 0 0]	Max Pooling	17x17x128
10	conv_3 64 20x20x128 convolutions, stride [1 1], padding ‘same’	Evrişimsel Katman	17x17x64
11	batchnorm_3	Normalizasyon	17x17x64
12	relu_3	ReLU	17x17x64
13	maxpool_3 3x3 maxpooling, stride [2 2], padding [0 0 0 0]	Max Pooling	8x8x64
14	conv_4 32 5x5x64 convolutions, stride [1 1], padding ‘same’	Evrişimsel Katman	8x8x32
15	batchnorm_4	Normalizasyon	8x8x32
16	fc_1 12 tam bağlı katman	Tam Bağlı Katman	1x1x12
17	dropout %30 dropout	Dropout	1x1x12
18	fc_2 3 tam bağlı katman	Tam Bağlı Katman	1x1x3
19	softmax	Softmax	1x1x3
20	classoutput	Sınıflandırma Katmanı	

Tasarlanan MKESAS ESA modelinin çıkış katmanlarında 2 tam bağlı katman ve bu katmanlar arasında aşırı öğrenmenin önüne geçmek adına dropout katmanı kullanılmıştır.

4 evrişim katmanı olan bu ağ modeli ile 2 dakikalık bir sürede %98,71'lik bir doğruluk oranına ulaşılmıştır. Şekil 4.4'de modelin eğitim sürecini gösteren grafik verilmiştir. Yine aynı grafikte modelin diğer AlexNet ve GoogLeNet modellerine kıyasla daha düşük kayıp değeri ile eğitim sürecinin bittiği görülmektedir. Bu sonuç da MKESAS modelin daha küçük hatalarla tahminler yaptığını ortaya çıkarmaktadır.






Şekil 4.4. MKESAS eğitim süreci grafiği

Önerilen MKESAS modelinden daha sığ bir ağ modeli aynı verilerle eğitildiğinde ağın öğrenme performansı ölçmek için MKESAS modelindeki üçüncü evrişimsel katman ve devamındaki normalizasyon, aktivasyon ve havuzlama katmanı modelden çıkartılarak MKESAS modelinin derinliği azaltılmıştır. Ağ yapısı Tablo 4.5’de verilmiş olan sığlaştırılmış MKESAS modeli ile %94,68 doğruluk oranına ulaşılmıştır.

Tablo 4.5. Sığlaştırılmış MKESAS modelinin ağ analizi

Sıra	Ağ İsmi	Ağ Tipi	Boyut
1	imageinput 227x227x3, zerocenter normalization	Giriş	227x227x3
2	conv_1 32 11x11x3 convolutions, stride [3 3], padding [1 1 1 1]	Evrişimsel Katman	73x73x32
3	batchnorm_1	Normalizasyon	73x73x32
4	relu_1	ReLU	73x73x32
5	maxpool_1 3x3 maxpooling, stride [2 2], padding [0 0 0 0]	Max Pooling	36x36x32
6	conv_2 128 10x10x32 convolutions, stride [1 1], padding ‘same’	Evrişimsel Katman	36x36x128
7	batchnorm_2	Normalizasyon	36x36x128
8	relu_2	ReLU	36x36x128
9	maxpool_2 3x3 maxpooling, stride [2 2], padding [0 0 0 0]	Max Pooling	17x17x128
10	conv_4 32 5x5x64 convolutions, stride [1 1], padding ‘same’	Evrişimsel Katman	8x8x32
11	batchnorm_4	Normalizasyon	8x8x32
12	fc_1 12 tam bağlı katman	Tam Bağlı Katman	1x1x12
13	dropout %30 dropout	Dropout	1x1x12
14	fc_2 3 tam bağlı katman	Tam Bağlı Katman	1x1x3
15	softmax	Softmax	1x1x3
16	classoutput	Sınıflandırma Katmanı	

Şekil 4.5 de modelin eğitim süreci grafiğinde görüldüğü gibi kayıp değerinin de MKESAS modeline kıyasla daha yüksek (yaklaşık 0,2) olduğu görülmektedir.




Şekil 4.5. Sıglaştırılmış MKESAS eğitim süreci grafiği

4.4. MKESAS Modelinin Daha Az Sayıda Veri ile Eğitilmesi

Önerilen MKESAS modeli ve diğer 2 derin sinir ağı modeli 3000 adet kesit ile eğitildiği ve üç sinir ağı modeli ile de %95 üzerinde doğruluk oranına ulaşıldığı önceki bölümlerde ifade edilmişti. Diğer iki modele göre daha yüksek doğruluk oranına sahip MKESAS modelinin daha az sayıda veri ile eğitildiğinde eğitim sonuçlarını ölçmek amacıyla MKESAS modeli farklı bir veri seti ile tekrar eğitildi. Aynı veri kümesinden seçilmiş, her sınıfta 250 adet veri bulunan toplam 750 adet veri ile yapılan MKESAS modeli eğitiminde doğruluk oranının azaldığı gözlemlendi. Şekil 4.6'da MKESAS modelinin azaltılmış veri seti ile yapılan eğitim süreci grafiği verilmiştir. MKESAS modeli azaltılmış veri kümesi ile eğitildiğinde doğruluk oranının %94,83'e düştüğü, kayıp değerinde kayda değer bir değişiklik olmadığı gözlemlenmiştir.





Şekil 4.6. Azaltılmış veri ile MKESAS eğitim süreci grafiği

4.5. Uygulamada Kullanılan ESA Modellerinin Karşılaştırılması

Veri seti ile AlexNet, GoogLeNet ve MKESAS olmak üzere toplam 3 farklı ESA modeli eğitilmiş sonuç olarak tüm modellerde %95'in üstünde doğruluk oranlarına ulaşılmıştır. Eğitilen modellerin üçünün de havuzlama katmanlarında maxpooling kullanılmıştır. Modellerde kullanılan evrişimsel ve havuzlama katman sayıları ve doğruluk oranları Tablo 4.6'da verilmiştir.

Tablo 4.6. Uygulamaların doğruluk oranları

Model	Evrişimsel Katman	Tam bağlı Katman	Doğruluk Oranı
AlexNet	5	3	%95,55
GoogLeNet	21	1	%96
MKESAS	4	2	%98,71

Modellerin doğruluk oranlarını gösteren Tablo 4.6'da ve modellerin eğitim sürelerini gösteren Tablo 4.7'de görüldüğü gibi toplam 8 katmandan oluşan (5 evrişim katmanı + 3 sınıflandırma katmanı) AlexNet modeli ile çalışma kapsamında önerilen MKESAS modeline yakın bir sürede, %95,55 doğruluk oranına ulaşılmıştır. Yine GoogLeNet modeline kıyasla oldukça basit bir ağ yapısına sahip AlexNet modeli ile daha kısa eğitim süresinde yaklaşık olarak aynı doğruluk oranı elde edilmiştir.

Tablo 4.7. Uygulamaların Eğitim Süreleri

Model	Eğitim Süresi
AlexNet	2 dakika 12 saniye
GoogLeNet	5 dakika 42 saniye
MKESAS	2 dakika

GoogLeNet modelinin katmanlarında farklı olarak 9 inception modülü kullanılmıştır. GoogLeNet inception yapısıyla, diğer modellere kıyasla oldukça derin bir sinir ağına sahip

olmasına rağmen oldukça hızlı bir öğrenme hızına sahiptir[127]. Yapılan çalışmada da GoogLeNet makul bir eğitim süresinde %96 doğruluk oranına ulaşmıştır.

Önerilen MKESAS modelinin mevcut verilerle yapılan uygulama sonuçları, AlexNet ve GoogLeNet modellerinin sonuçlarıyla kıyaslandığında daha başarılı sonuçlar ürettiği görülmüştür. Her iki modelden de daha kısa sürede daha yüksek sınıflandırma başarısı elde edilmiştir.



5. TARTIŞMA

Mamografi görüntüleme, meme kanserinin erken aşamada tespitinde ve bu hastalıkla mücadelede en etkili yöntemdir [128]. Çalışmanın farklı alanlarında da bahsedildiği gibi mamografi görüntülerindeki kanser belirtileri zaman zaman gözden kaçırılmaktadır [11]. Sonuç olarak geç müdahaleyle tedavi süreci olumsuz etkilenmektedir [43,67]. Bu nedenle gözden kaçan tümör ya da kanser işaretçisi unsurların oranlarını azaltmak için konuyla ilgili BKDS tasarımına ve kullanımına ihtiyaç duyulmaktadır.

Mamografi görüntülerinin değerlendirilmesi için tasarlanan BKDS sistemleri dokulardaki anormal yapıları tespit ederek ya da sınıflandırarak konunun uzmanlarına yardımcı olmayı amaçlamaktadırlar. Çalışma kapsamında tasarlanan MKESAS modeli ile mamografi görüntülerindeki şüpheli görülen kesitler kist, mikro kalsifikasyon ve normal olarak sınıflandırılmaktadır.

DSA'nın görüntü işlemedeki başarısından dolayı literatürdeki konuyla ilgili çalışmalarda bu alana yoğunlaştığı görülmektedir. Tablo 5.1'de çalışmada sunduğumuz yöntemin ve konuyla ilgili diğer yapılan çalışmaların kullandıkları yöntemler, mamografi görüntülerinin alındığı kaynaklar, çalışmada kullanılan görüntü miktarı ve çalışma sonuçları karşılaştırmalı olarak verilmiştir.

Tablo 5.1. Literatürdeki çalışmalara ait veriler

Yazar	Önerilen Model İsmi	Yöntem	Veri Sayısı	Veri Kaynağı	Sınıflandırma Segmentasyon	Doğruluk Oranı
Zhang ve arkadaşları [21]	MVNN	ESA	5706	DDSM	N/A ve B/M 2 aşamalı sınıflandırma	N/A:%94,92 B/M:%95,24
Li ve arkadaşları [30]	CNN-4D	ESA	323	MIAS	B/M	%89,05
Sulaiman ve arkadaşları [31]	VggNet-19, InceptionV3, MatConvNet	ESA	322	MIAS	Kitle tespiti	%97,04
Yu ve Guan [32]		FNN	40	Nijmegen database	Mikro kalsifikasyon tespiti	TP: %90
Ertosun ve Rubin [33]		DSA		DDSM	Sınıflandırma (kitleli-kitlesiz) ve kitle tespiti	%85
Wang ve arkadaşları [34]	SAE	DSA	1204	-	Mikro kalsifikasyon tespiti ve sınıflandırılması	%89,7

Yazar	Önerilen Model İsmi	Yöntem	Veri Sayısı	Veri Kaynağı	Sınıflandırma Segmentasyon	Doğruluk Oranı
Selvathi ve Poornila[35]		DSA	323	MIAS	Kanserli doku tespiti	%98,5
Han ve arkadaşları [36]	CSDCNN	DSA		BreaKHis Histopatolojik görüntüler	Kanserli doku tespiti ve B/M sınıflandırma	%93,2
Xi ve arkadaşları [39]	VggNet	ESA		DDSM	Kalsifikasyon/ kitle sınıflandırması ve segmentasyonu	%92,53
Önerilen Çalışma	MKESAS	ESA	623 mamografiden elde edilmiş 3000 adet kesit	MIAS, DDSM, INBREAST ve FSSH.	Kalsifikasyon/ kitle ve normal doku sınıflandırması	%98,71

Tablo 5.1’de verilen konuyla ilgili çalışmalarda genellikle MIAS ve DDSM veri tabanlarından alınan oldukça az sayıda veri ile DSA alanında çalışmalar yapıldığı görülmektedir. Ayrıca literatürdeki bazı çalışmalarda AlexNet, GoogLeNet, VggNet ve benzeri ESA modelleri kullanılmış ve birbiri ile karşılaştırılmıştır. ESA modelleri kullanılarak yapılan çalışmaların sonuçlarına bakıldığında; kullanılan veri setine, veri miktarına, uygulanan modele göre başarı oranlarının değişiklik gösterdiği görülmektedir.

Farklı çalışmalarda ve özellikle de IMAGENET görüntü sınıflandırma yarışmasında GoogLeNet doğruluk oranı ile AlexNet ve benzeri birçok modelin açık bir farkla önüne geçmesine rağmen konuyla ilgili literatürdeki bazı çalışmalarda, bu sıralamanın değiştiği görülmektedir. Çalışmada kullandığımız veri seti ile daha sığ ESA modellerinde daha yüksek doğruluk oranı elde edilmiş, ağ derinleştikçe ve karmaşıklıklaştıkça eğitim süresinin arttığı ve doğruluk oranlarının da azaldığı gözlemlenmiştir. Ayrıca önerilen MKESAS modelinin katman sayıları azaltılarak yapılan ayrı bir eğitim sonunda da %94,54 doğruluk elde edilmiştir. Bu sonuç da bize ideal derinlikte ve yapıdaki ağ ile en doğru sonuçlara ulaşılabileceğini göstermektedir. Literatürde bu alanda yapılmış bazı çalışmaların sonuçları da sunduğumuz modelin sonuçlarını doğrular niteliktedir.

Veri setinin azaltılması ile MKESAS modelinin doğruluk oranının %94,83’e düştüğü görülmüştür. Literatürdeki çalışmalardan farklı olarak 4 farklı veri tabanından elde edilen daha geniş veri seti ile yapılmış olan bu çalışmada veri setinin artırılmasının ağırlık başarı oranına kayda değer bir olumlu etki yaptığını göstermektedir.

Ayrıca literatürdeki çalışmaların büyük çoğunluğunda kısıtlı veri tabanından alınan oldukça az sayıda veri ile çalışılmıştır. Bu çalışmada 4 farklı veri tabanından 623 adet mamografi görüntüsü

ve bu mamografi görüntülerinden alınan 3000 adet kesit kullanılarak ESA modelleri eğitilmiş ve %98,7'lik doğruluk oranına ulaşılmıştır.

Sinir ağının eğitim ve testinde kullanılan verilerdeki ayırt edici özellikler ne kadar fazla ve fark edilebilir olursa sınıflandırmadaki doğruluk da o kadar yüksek olmaktadır. Mamografi görüntüsünün ayırt edilebilir özelliklerinin sinir ağı tarafından daha kolay fark edilerek daha kolay ve hızlı sınıflandırma yapılabilmesi için ana görüntüdeki kist, kalsifikasyon ve normal dokulara ait alanlar görüntüden kırılarak veri seti oluşturulmuştur.



6. SONUÇ VE ÖNERİLER

Günümüzde mamografi görüntüleme yöntemi meme kanseri problemiyle mücadelede çok önemli bir tekniktir. Fakat mamografi görüntüleri zaman zaman yanlış değerlendirilebilmektedir [11]. Kanser ortalama %85-%90 mamografi incelemelerinde görülse de; insan gözünün kısıtlılığı, iş yükü, meme dokusunun yapısı, çekim hataları, hekim tecrübesi ve benzeri nedenlerle mamogramlardaki tümörlerin yaklaşık olarak %10-%15'i gözden kaçırılmaktadır [16]. Zaman zaman teşhisle ilgili şüpheye düşülebilmekte ve farklı bir uzmanında mamografi görüntüsünü değerlendirmesine ihtiyaç duyulmaktadır. Bilgisayarlı karar destek sistemleri şüpheli bölgeleri ön plana çıkaran, radyolog tarafından şüpheli görülen bölgeleri sınıflandıran, radyologlara ikinci bir görüş sunan sistemler olarak tasarlanmaktadır. Nihai kararın genellikle radyoloğa ait olduğu bu sistemlerle kanser belirtisi olabilecek tümör ve kalsifikasyonların gözden kaçmasını en aza indirmek amaçlanmaktadır. Bu amaçlar doğrultusunda geliştirilen bilgisayarlı karar destek sisteminde, öncelikle mamogramlar çalışma kapsamında geliştirilen, morfolojik görüntü işleme tekniklerini temel alan BSAG yöntemi kullanılarak ön işlemden geçirilmiştir. Ön işleme aşamasında mamografi görüntüleri istenmeyen etiket ve gürültülerden arındırılmıştır. Bu işlem meme bölgesine ait alanda hiçbir bozulmaya neden olmadan mamografi görüntülerinin tamamında başarılı bir şekilde gerçekleştirilmiştir.

Mamografi görüntüsüne ait bir binary şablon oluşturularak uygulanan BSAG yönteminin benzer görüntü işleme çalışmalarına da katkı sağlayacağı öngörülmektedir. Morfolojik görüntü işleme yöntemlerini esas alarak tasarlanan bu yöntemin en önemli avantajı görüntüdeki ana yapı haricindeki, belirli boyutlardaki görüntüler yok edilirken ana yapıda herhangi bir aşınma meydana gelmemesidir. Yöntemin farklı çalışmalarda kullanılması durumunda yöntemin uygulanacağı görüntülerin içeriği dikkate alınarak, kullanılan yapı elemanının boyutunun değiştirilmesi gerekmektedir.

Güncel görüntü işleme çalışmalarında ESA'nın sıklıkla kullanıldığı görülmektedir. ESA'lar görüntü sınıflandırma problemlerinde iyi sonuçlar verse de, eğitim için çok sayıda etiketlenmiş veriye ihtiyaç duymaktadır. Özellikle mamografi görüntülerinde doğru şekilde etiketlenmiş veriye ulaşımdaki kısıtlılık konuyla ilgili yapılan çalışmaları zorlaştırmaktadır [25–29]. Bu sebeple daha önce bu alanda yapılan çalışmaların büyük bir çoğunluğu MIAS ve DDSM veri tabanlarından aldıkları oldukça az sayıda mamografi görüntüsü ile yapılmıştır.

Bu çalışmada literatürdeki çalışmalardan farklı olarak 1 tanesi yerel bir hastane (FSSH) olmak üzere toplamda 4 farklı veri tabanından alınan görüntüler kullanılmıştır. Kullanılan mamografi görüntüleri FSSH, INBREAST, DDSM ve MIAS veri tabanlarından elde edilmiştir. Bu alanda yapılacak sonraki çalışmalar için veri çeşitliliğinin daha da arttırılması ile daha başarılı ve güvenilir sonuçlara ulaşılabileceği öngörülmektedir.

Bu çalışmada mamografi görüntüleri sınıflandırmayı kolaylaştırmak için kesitlere ayrılmış ve bu kesitlerle sinir ağı eğitilmiştir. Böylece basitleştirilmiş mamografi görüntüleri ile çok karmaşık olmayan sinir ağları daha kısa sürede eğitilerek, daha yüksek doğruluk oranlarına ulaşılabilceği anlaşılmıştır.

Kist, kalsifikasyon ve normal doku içeren her biri 1000 adet kesitten oluşan toplam 3000 adet görüntü kullanılarak, 3 farklı sinir ağı modeli ile uygulamalar yapılmıştır. Bu uygulamalarda AlexNet, GoogLeNet ve çalışma kapsamında geliştirilen MKESAS sinir ağı modelleri kullanılmıştır. Uygulamadaki doğruluk oranları Tablo 6.1 de verilmiştir.

Tablo 6.1. Uygulama sonuçları

Model	Doğruluk Oranı
AlexNet	%95,55
GoogLeNet	%96
MKESAS	%98,71

AlexNet bilinen derin sinir ağı modelleri içinde kısmen fazla derin ve karmaşık olmayan bir ESA modelidir. Bu alandaki çalışmalara ivme kazandıran AlexNet modeli ile 2 dakika 12 saniyelik sürede %95,55 doğruluk oranına ulaşılmıştır.

GoogLeNet 1x1 evrişim katmanları, bir hayli derin yapısı ve insepction modeli ile uygulamada kullanılan diğer modellere göre oldukça karmaşık bir yapıya sahiptir. Bu karmaşık yapısı ve derinliğine rağmen oldukça hızlı olan GoogLeNet modeli ile 5 dakika 42 saniyelik sürede %96 doğruluk oranına ulaşılmıştır.

Çalışma kapsamında geliştirilen ve diğer ESA modellerine göre kısmen daha sığ bir katman yapısına sahip MKESAS modeli ile 2 dakikalık eğitim süresi sonunda %98,71 doğruluk oranına ulaşılmıştır. Sonuç olarak mamografi görüntülerinin kesitleri normal, kist, kalsifikasyon şeklinde sınıflandırılmasında en başarılı sonuca MKESAS modeli ile ulaşılmıştır.

Ayrıca uygulamada kullanılan tüm modellerin eğitiminde ve testinde makul (yaklaşık 0,1) kayıp değerleri elde edilmiş olsa da MKESAS modelinin diğer modellere göre kısmen daha düşük kayıp değeri ile eğitim sürecini tamamladığı tespit edilmiştir. Bu bağlamda da MKESAS modelinin daha başarılı olduğu ifade edilebilir.

Mamografi kesitlerinin sınıflandırılması için tasarlanan BKDS, mamografi görüntüleri ile yapılan yanlış teşhislerin azaltılmasına katkı sağlayacaktır. Ayrıca önerilen BKDS'nin farklı biyomedikal görüntülere ait veri setleri ile eğitildiğinde farklı alanlarda da kullanılması mümkün olacaktır.

İleriki çalışmalarda veri seti artırılarak mevcut BKDS ile daha güvenilir ve daha yüksek doğruluk oranlarına ulaşılması planlanmaktadır. Ek olarak bu çalışma kapsamında tasarlanan MKESAS modeli kistlerin kendi içinde iyi huylu ve kötü huylu olarak sınıflandırılması gibi çalışmalar için de ön adım olacaktır.



KAYNAKLAR

- [1] All cancers, Glob. Cancer Obs. (2020). <https://gco.iarc.fr/today> (erişim 26 Kasım 2021).
- [2] Turkey Source: Globocan 2020, (2021). <https://gco.iarc.fr/today/data/factsheets/populations/792-turkey-fact-sheets.pdf> (erişim 26 Kasım 2021).
- [3] Latest global cancer data: Cancer burden rises to 19.3 million new cases and 10.0 million cancer deaths in 2020, (2020) 1–2. https://www.iarc.who.int/wpcontent/uploads/2020/12/pr292_E.pdf (erişim 26 Kasım 2021).
- [4] Cancer Today, (y.y.). https://gco.iarc.fr/today/online-analysis-pie?v=2020&mode=cancer&mode_population=continents&population=900&populations=900&key=total&sex=0&cancer=39&type=0&statistic=5&prevalence=0&population_group=0&ages_group%5B%5D=0&ages_group%5B%5D=17&nb_items=7&group_cancer=1&include_nmsc=1&include_nmsc_other=1&half_pie=0&donut=0 (erişim 09 Aralık 2021).
- [5] Guo Y., Şengür A., Tian J.W., (2016) A novel breast ultrasound image segmentation algorithm based on neutrosophic similarity score and level set, *Comput. Methods Programs Biomed.* 123. <https://doi.org/10.1016/j.cmpb.2015.09.007>.
- [6] Fanizzi A., Losurdo L., Basile T.M.A., Bellotti R., Bottigli U., et al. 2019. Fully automated support system for diagnosis of breast cancer in contrast-enhanced spectral mammography images, *J. Clin. Med.* 8). <https://doi.org/10.3390/jcm8060891>.
- [7] Hariraj V., Khairunizam W., Vikneswaran, Z. Ibrahim, A.B. Shahrman, Z.M. Razlan, T. Rajendran, R (2018) Fuzzy multi-layer SVM classification of breast cancer mammogram images, *Int. J. Mech. Eng. Technol.* 9.
- [8] Araujo T., Aresta G., Castro E., Rouco J., Aguiar P., Eloy C., et al. (2017) Classification of breast cancer histology images using convolutional neural networks, *PLoS One.* 12. <https://doi.org/10.1371/journal.pone.0177544>.
- [9] Zebari D.A., Zeebaree D.Q., Abdulazeez A.M., Haron H., Hamed H.N.A. (2020) Improved threshold based and trainable fully automated segmentation for breast cancer boundary and pectoral muscle in mammogram images, *IEEE Access.* 8. <https://doi.org/10.1109/ACCESS.2020.3036072>.
- [10] Zeebaree D.Q., Haron H., Abdulazeez A.M. 2018. Gene Selection and Classification of Microarray Data Using Convolutional Neural Network, içinde: *ICOASE 2018 - Int. Conf. Adv. Sci. Eng.*, <https://doi.org/10.1109/ICOASE.2018.8548836>.
- [11] Virmani J., Kriti, Thakur. S., 2019. Classification of breast tissue density patterns using SVM-based hierarchical classifier, içinde: *Adv. Intell. Syst. Comput.*, https://doi.org/10.1007/978-981-10-8848-3_18.
- [12] Solanki L.S., Singh S., Singh D. 2016 An ANN approach for false alarm detection in microwave breast cancer detection, içinde: *2016 IEEE Congr. Evol. Comput. CEC 2016*, <https://doi.org/10.1109/CEC.2016.7743948>.
- [13] Deniz E., Şengür A., Kadiroğlu Z., Guo Y., Bajaj V., Budak Ü. 2018. Transfer learning based histopathologic image classification for breast cancer detection, *Heal. Inf. Sci. Syst.* 6. <https://doi.org/10.1007/s13755-018-0057-x>.
- [14] Vijayarajeswari R., Parthasarathy P., S. Vivekanandan, A.A. Basha, (2019) Classification of mammogram for early detection of breast cancer using SVM classifier and Hough transform, *Meas. J. Int. Meas. Confed.* 146. <https://doi.org/10.1016/j.measurement.2019.05.083>.
- [15] H. Li, S. Zhuang, D. ao Li, J. Zhao, Y. Ma, (2019) Benign and malignant classification of mammogram images based on deep learning, *Biomed. Signal Process. Control.* 51. <https://doi.org/10.1016/j.bspc.2019.02.017>.
- [16] Kim H.E., Kim H.H., Han B.K, Kim K.H., Han K., Nam H., Lee E.H., Kim E. K., (2020) Changes in cancer detection and false-positive recall in mammography using artificial intelligence: a retrospective, multireader study, *Lancet Digit. Heal.* 2 e138–e148. [https://doi.org/https://doi.org/10.1016/S2589-7500\(20\)30003-0](https://doi.org/https://doi.org/10.1016/S2589-7500(20)30003-0).

- [17] Oral C., 2011. Sayısal Mamografi Görüntülerine Yapay Zeka Yöntemlerinin Uygulanması, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü.
- [18] Toz G., 2018. Görüntü İşleme Teknikleriyle Meme Kanserinin Teşhisi, Düzce Üniversitesi, Fen Bilimleri Enstitüsü.
- [19] Liu B., Cheng H.D., Huang J., Tian J., Tang X., Liu J., Fully automatic and segmentation-robust classification of breast tumors based on local texture analysis of ultrasound images, Pattern Recognit. 43 (2010). <https://doi.org/10.1016/j.patcog.2009.06.002>.
- [20] Cıvıkcı L., Görüntü Zenginleştirme ve Hücresel YSA Kullanarak Meme Kanseri Teşhisi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, 2013.
- [21] Zhang C., Zhao J., Niu J., D.Li, (2020). New convolutional neural network model for screening and diagnosis of mammograms, PLoS One. 15. <https://doi.org/10.1371/journal.pone.0237674>.
- [22] Parlar T., (2020). Meme Kanseri Teşhis ve Prognozunda Radiomics ile Yapay Zeka Yöntemleri Kullanımı Hakkında Bir İnceleme, Eur. J. Sci. Technol. <https://doi.org/10.31590/ejosat.780052>.
- [23] Lin D., Vasilakos A. V., Tang Y., Yao Y., 2016. Neural networks for computer-aided diagnosis in medicine: A review, Neurocomputing. 216. <https://doi.org/10.1016/j.neucom.2016.08.039>.
- [24] Biçakci M., Non-Small Cell Lung Cancer Tumor Characterisation Using Deep Learning, Fen Bilimleri Enstitüsü, 2021.
- [25] LeCun G., Bengio, Y., Hinton, Y., (2015) Deep learning. nature 521 (7553): 436, Nature. 521.
- [26] Weiss K., Khoshgoftaar T.M., Wang D.D., (2016) A survey of transfer learning, J. Big Data. 3. <https://doi.org/10.1186/s40537-016-0043-6>.
- [27] Abdelhafiz D., Yang C., Ammar, R.S. Nabavi, (2019) Deep convolutional neural networks for mammography: Advances, challenges and applications, BMC Bioinformatics. 20. <https://doi.org/10.1186/s12859-019-2823-4>.
- [28] Burt J.R., Torosdagli N., Khosravan N., Raviprakash, H. Mortazi, A. Tissavirasingham, F. (2018) Deep learning beyond cats and dogs: Recent advances in diagnosing breast cancer with deep neural networks, Br. J. Radiol. 91. <https://doi.org/10.1259/bjr.20170545>.
- [29] Zeiler M.D., Fergus R., 2013. Stochastic pooling for regularization of deep convolutional neural networks, içinde: 1st Int. Conf. Learn. Represent. ICLR 2013 - Conf. Track Proc.,
- [30] Li B., Ge, Y. Zhao, Y. Guan, E. Yan, W. (2018). Benign and malignant mammographic image classification based on Convolutional Neural Networks, ACM Int. Conf. Proceeding Ser. 247–251. <https://doi.org/10.1145/3195106.3195163>.
- [31] Sulaiman S.N., Hassan, N.A. Isa, I.S. Abdullah, M.F. Soh, Z.H.C. Jusman, Y. 2021. Mass Detection in Digital Mammogram Image using Convolutional Neural Network (CNN), içinde: Proc. - 2021 11th IEEE Int. Conf. Control Syst. Comput. Eng. ICCSCE 2021, <https://doi.org/10.1109/ICCSCE52189.2021.9530945>.
- [32] Yu, S. Guan, L. (2000). A CAD system for the automatic detection of clustered microcalcifications in digitized mammogram films, IEEE Trans. Med. Imaging. 19 <https://doi.org/10.1109/42.836371>.
- [33] Ertosun, M.G. Rubin, D.L. 2015. Probabilistic visual search for masses within mammography images using deep learning, içinde: Proc. - 2015 IEEE Int. Conf. Bioinforma. Biomed. BIBM, 2015.
- [34] Wang, J. Yang, X. Cai, H. Tan, W. Jin. C., Li L., Discrimination of Breast Cancer with Microcalcifications on Mammography by Deep Learning, Sci. Rep. 6 (2016).
- [35] Selvathi, D.A. Poornila, A. (2017). Breast cancer detection in mammogram images using deep learning technique, Middle-East J. Sci. Res. 25
- [36] Han, Z. Wei, B. Zheng, Y. Yin Y., Li, K. Li, S. (2017) Breast Cancer Multi-classification from Histopathological Images with Structured Deep Learning Model, Sci. Rep. 7. <https://doi.org/10.1038/s41598-017-04075-z>.
- [37] Reiazi, R. Paydar, R. Ardakani, A.A. Etedadialabadi, M. 2018. Mammography Lesion Detection Using Faster R-CNN Detector., <https://doi.org/10.5121/csit.2018.80212>.

- [38] Dubrovina, A. Kisilev, P. Ginsburg, B. Hashoul, S. Kimmel, R. (2018) Computational mammography using deep neural networks, *Comput. Methods Biomech. Biomed. Eng. Imaging Vis.* 6. <https://doi.org/10.1080/21681163.2015.1131197>.
- [39] Xi, P. Shu, C. Goubran, R. 2018. Abnormality Detection in Mammography using Deep Convolutional Neural Networks, içinde: *MeMeA 2018 - 2018 IEEE Int. Symp. Med. Meas. Appl. Proc.*, <https://doi.org/10.1109/MeMeA.2018.8438639>.
- [40] Perre, A.C. Alexandre, L.A. Freire, L.C. (2019). Lesion classification in mammograms using convolutional neural networks and transfer learning, *Comput. Methods Biomech. Biomed. Eng. Imaging Vis.* 7 <https://doi.org/10.1080/21681163.2018.1498392>.
- [41] Moon, W.K. Lee, Y.W. Ke, H.H. Lee, S.H. Huang, C.S. Chang, R.F. (2020). Computer-aided diagnosis of breast ultrasound images using ensemble learning from convolutional neural networks, *Comput. Methods Programs Biomed.* 190 <https://doi.org/10.1016/j.cmpb.2020.105361>.
- [42] Malebary, S.J. Hashmi, A. (2021) Automated Breast Mass Classification System Using Deep Learning and Ensemble Learning in Digital Mammogram, *IEEE Access.* 9. <https://doi.org/10.1109/ACCESS.2021.3071297>.
- [43] Cabioğlu, N. 2012. Memenin anatomisi ve fizyolojisi, Ankara,.
- [44] Yalçınöz B.H., 2008 Meme Kanseri ve Mamografiye İlişkin Sağlık İnançları ile Telefonla Hatırlatmanın Tekrar Mamografi Çektirmeye Etkisi, Atatürk Üniversitesi,.
- [45] Erel, S. Atahan, M.K. 2019. Genel Cerrahi Ders Kitabı, içinde: *Memenin Anat. Fizyol. ve Değerlendirilmesi*, Akademisyen Kitabevi,
- [46] Kireççi, O. Meme Kanserinde 3 Boyutlu Konformal Radyoterapi Ve Yoğunluk Ayarlı Radyoterapi Planlama Tekniklerinin Dozimetrik Karşılaştırılması, Antalya Üniversitesi, 2018.
- [47] Spanhol, F.A. Oliveira, L.S. Petitjean, C. Heutte, L.A (2016) Dataset for Breast Cancer Histopathological Image Classification, *IEEE Trans. Biomed. Eng.* 63.
- [48] Kosova, F. Arı, Z. Adipositokinler ve Meme Kanseri, (2008). <http://www.fusabil.org>.
- [49] Admoun, C. Mayrovitz, H. (2021). Choosing Mastectomy vs. Lumpectomy-With-Radiation: Experiences of Breast Cancer Survivors, *Cureus.* <https://doi.org/10.7759/cureus.18433>.
- [50] Meme Kanseri Nedir? Belirtileri ve Tedavi Yöntemleri Acıbadem, (y.y.). <https://www.acibadem.com.tr/ilgi-alani/meme-kanseri/> (erişim 26 Kasım 2021).
- [51] Meme Kanseri ve Genetik Kanser Polikliniği, (2021). <https://www.memorial.com.tr/saglik-rehberi/meme-kanseri-ve-genetik-kanser-poliklinigi> (erişim 26 Kasım 2021).
- [52] Walsh, T. Gulsuner, S. Lee, M.K. Troester, M.A. Olshan, A.F. Earp, H.S. et al., (2021). Inherited predisposition to breast cancer in the Carolina Breast Cancer Study, *npj Breast Cancer.* 7 <https://doi.org/10.1038/s41523-020-00214-4>.
- [53] Francies, F.Z. Hull, R. Khanyile, R. Dlamini, Z. Breast cancer in low-middle income countries: abnormality in splicing and lack of targeted treatment options, *Am J Cancer Res.* 10 (2020) 1568–1591. www.ajcr.us/ (erişim 12 Aralık 2021).
- [54] Gedik, N. 2013. Bilgisayar Destekli Teşhis Sistemi İle Mamografi Görüntülerinin Sınıflandırılması, Karadeniz Teknik Üniversitesi.
- [55] Meme Kanseri Korunma, Tarama, Tanı, Tedavi İzlem Klinik Rehberi, T.C. Sağlık Bakanl. (2020). <https://www.saglikaktuel.com/d/file/38131,memekanskr20200720pdf.pdf> (erişim 12 Aralık 2021).
- [56] Kim, R. Kawai, A. Wakisaka, M. Sawada, S. Shimoyama, M. Yasuda, N. Hidaka, M. Morita, Y. et al.. (2021) Arihiro, Immune factors associated with the pathological and therapeutic effects of preoperative chemotherapy in patients with breast cancer, *Transl. Oncol.* 14.
- [57] Azam, S. Eriksson, M. Sjölander, A. Gabrielson, M. Hellgren, R. Czene, K. Hall, P. (2021) Mammographic microcalcifications and risk of breast cancer, *Br. J. Cancer.* 125. <https://doi.org/10.1038/s41416-021-01459-x>.
- [58] Morgan, M.P. Cooke, M.M. McCarthy, G.M. (2005) Microcalcifications associated with breast cancer: An epiphenomenon or biologically significant feature of selected tumors?, *J. Mammary*

- Gland Biol. Neoplasia. 10. <https://doi.org/10.1007/s10911-005-5400-6>.
- [59] Lehman, C.D. Wellman, R.D. Buist, D.S.M. Kerlikowske, K. Tosteson, A.N.A., (2015) Diagnostic accuracy of digital screening mammography with and without computer-aided detection, JAMA Intern. Med. 175. <https://doi.org/10.1001/jamainternmed.2015.5231>.
- [60] Fischer, T. Grigoryev, M. Bossenz, S. Diekmann, F. Bick, U. Slowinski, T.A. (2012) Sonografische Mikrokalkdetektion - Potenzial einer neuen Methode, Ultraschall der Medizin. 33. <https://doi.org/10.1055/s-0031-1299128>.
- [61] Alsheh Ali M., Czene, K. Hall, P. Humphreys, K. (2019) Association of Microcalcification Clusters with Short-term Invasive Breast Cancer Risk and Breast Cancer Risk Factors, Sci. Rep. 9. <https://doi.org/10.1038/s41598-019-51186-w>.
- [62] Mamogramların mini MIAS veritabanı, (y.y.). <http://peipa.essex.ac.uk/info/mias.html> (erişim 27 Kasım 2021).
- [63] Karahaliou, A. Skiadopoulos, S. Boniatis, I. Sakellariopoulos, P. Likaki, E. Panayiotakis, G. Costaridou, L. Texture analysis of tissue surrounding microcalcifications on mammograms for breast cancer diagnosis, Br. J. Radiol. 80 (2007). <https://doi.org/10.1259/bjr/30415751>.
- [64] Mamografinin taranmasının taslak önerileri tartışmaları karıştırmaya devam ediyor - Harvard Health, (y.y.). <https://www.health.harvard.edu/blog/draft-recommendations-on-screening-mammography-continue-to-stir-debate-201505188016> (erişim 27 Kasım 2021).
- [65] İlk Mamogramınız Sırasında Neler Beklemeniz Gerekir?, (y.y.). <https://thesupermomlife.com/first-mammogram/> (erişim 27 Kasım 2021).
- [66] Kozan, R. Tokgöz, Y. 2016) Türkiye’de Meme Kanseri Farkındalığı ve Tarama Programı, Acibadem Univ. Sağlık Bilim. Derg. (.).
- [67] Yiğit, A. Erdem, R. (2017) Sağlık Teknolojisi Değerlendirme Kavramsal Bir Çerçeve, Süleyman Demirel Üniversitesi. 3 401–430.
- [68] GE Healthcare (United States), (2017). <https://www.gehealthcare.com/article/what-its-like-to-be-a-mammography-technologist> (erişim 09 Aralık 2021).
- [69] İşeri, İ. Mamogram Görüntülerinden Makine Öğrenmesi Yöntemleri İle Meme Kanseri Teşhisi, Sakarya Üniversitesi, 2014.
- [70] Heath, M. Bowyer, K. Kopans, D. Kegelmeyer, P. Moore, R. Chang, K. Munishkumaran, S. Current Status of the Digital Database for Screening Mammography, içinde: 1998. https://doi.org/10.1007/978-94-011-5318-8_75.
- [71] DDSM: Tarama Mamografisi için Dijital Veritabanı, (y.y.). <http://www.eng.usf.edu/cvprg/mammography/database.html> (erişim 27 Kasım 2021).
- [72] Moreira I.C., Amaral, I. Domingues, I. Cardoso, A. Cardoso, M.J. Cardoso, J.S. (2012) INbreast: Toward a Full-field Digital Mammographic Database., Acad. Radiol. 19. <https://doi.org/10.1016/j.acra.2011.09.014>.
- [73] Gedik, N. Mamografi Görüntülerinin Sınıflandırılması İçin Yeni Bir Özellik Çıkarımı Yaklaşımı, İleri Teknol. Bilim. Derg. 8 (2019) 45–53.
- [74] Abdoulaye, I.B.C. Demir, Ö. Demir, Ö. (2017). Mamografi Görüntülerinden Kitle Tespiti Amacıyla Öznitelik Çıkarımı, UBİCTÜS. (2017) 33–36.
- [75] Cura O.K., Sahin, S. Akan, A. Lesion detection from the mammography image using the Vision Development Module, içinde: 2017 Med. Technol. Natl. Conf. TIPTEKNO 2017, 2017. <https://doi.org/10.1109/TIPTEKNO.2017.8238045>.
- [76] Subramanian R., Rubi, D. Lakshmi, G.R. (2021). Breast Cancer Lesion Detection and Classification in Radiology Images using Deep Learning, Eur. J. Mol. & Clin. Med. 7 677–684. https://ejmcm.com/article_7057.html.
- [77] Alpaslan, N. Meme Kanseri Tanısı İçin Derin Öznitelik Tabanlı Karar Destek Sistemi, Selcuk Univ. J. Eng. ,Science Technol. 7 (2019). <https://doi.org/10.15317/scitech.2019.193>.
- [78] Shen, L. Margolies, L.R. Rothstein, J.H. Fluder, E. McBride, R. Sieh, W. (2019) Deep Learning to

- Improve Breast Cancer Detection on Screening Mammography, Sci. Rep. 9. <https://doi.org/10.1038/s41598-019-48995-4>.
- [79] Gonzalez, R. Woods, R. Eddins, S. 2009 Digital Image Processing using MATLAB, Second Edition,.
- [80] Balcı, H. 2017 BT Anjiografi İncelemelerinde İnförör Mezenterik Arterin Anatomik Özellik Ve İlişkilerinin Değerlendirilmesi, Hacettepe Üniversitesi,.
- [81] Cheng, J. Huang, W. Cao, S. Yang, R. Yang, W. Yun, Z. Wang, Z. Feng, Q. Enhanced performance of brain tumor classification via tumor region augmentation and partition, PLoS One. 10 (2015). <https://doi.org/10.1371/journal.pone.0140381>.
- [82] Ben Naceur, M. Saouli, R. Akil, M. Kachouri, R. Fully Automatic Brain Tumor Segmentation using End-To-End Incremental Deep Neural Networks in MRI images, Comput. Methods Programs Biomed. 166 (2018). <https://doi.org/10.1016/j.cmpb.2018.09.007>.
- [83] Soille, P. Morphological Image Analysis : Principles and Applications, 2004.
- [84] Yıldız, G. Yıldız, D. Morfolojik İşlemler ve Kenar Algılama Yöntemler Vasıtasıyla Beyin Tümör Yeri Tespiti ve Tümör Alan Hesabının Yapılması, Int. J. Multidiscip. Stud. 2 (2018) 39–42.
- [85] Poyraz, Y. Sevgen, S. GPU Programlama Tekniğı ile Yüksek Performanslı Araç Takibi, Bilişim Teknol. Derg. (2017). <https://doi.org/10.17671/gazibtd.331036>.
- [86] Mardiris, V. Chatzis, V. A Configurable Design for Morphological Erosion and Dilation Operations in Image Processing using Quantum-dot Cellular Automata, J. Eng. Sci. Technol. Rev. 9 (2016) 25–30. www.jestr.org (erişim 28 Kasım 2021).
- [87] Boztoprak, H. Gerçek Zamanlı Taşıt Plaka Tanıma Sistemi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, 2007.
- [88] Virtual Lab in Image Processing, (y.y.). <https://cse19-iiith.vlabs.ac.in/theory.php?exp=morph> (erişim 27 Kasım 2021).
- [89] Morphological Image Processing, (y.y.). <https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic4.htm> (erişim 27 Kasım 2021).
- [90] Gonzales, R.C. Woods, R.E. Digital Image Processing Fourth Edition, 2018.
- [91] ang, P. YClapworthy, G. Dong, F. Codreanu, V. Williams, D. Liu, B. Roerdink, J.B. Deng, Z. (2016) GSWO: A programming model for GPU-enabled parallelization of sliding window operations in image processing, Signal Process. Image Commun. 47 332–345. <https://doi.org/10.1016/J.IMAGE.2016.05.003>.
- [92] Sharma, M. Dubey, R. Gupta, S. (2012) Feature Extraction of Mammograms, Int. J. Adv. Comput. Res. 2 2249–2277. <https://www.researchgate.net/publication/321360881>.
- [93] Arora, R. Rai, P.K. Raman, B. Deep feature–based automatic classification of mammograms, Med. Biol. Eng. Comput. 58 (2020) 1199–1211. <https://doi.org/10.1007/s11517-020-02150-8>.
- [94] Mayo, M. 7 Steps to Understanding Deep Learning - KDnuggets, (2016). <https://www.kdnuggets.com/2016/01/seven-steps-deep-learning.html> (erişim 27 Kasım 2021).
- [95] Lu, J. Behbood, V. Hao, P. Zuo, H. Xue, S. Zhang, G. Transfer learning using computational intelligence: A survey, Knowledge-Based Syst. 80 (2015). <https://doi.org/10.1016/j.knosys.2015.01.010>.
- [96] AI vs Machine Learning vs Deep Learning: What’s the Difference?, (y.y.). <https://bigdatapath.wordpress.com/2019/09/13/ai-vs-machine-learning-vs-deep-learning-whats-the-difference/> (erişim 27 Kasım 2021).
- [97] Andrearczyk, V. Whelan, P.F. Deep learning in texture analysis and its application to tissue image classification, içinde: Biomed. Texture Anal. Fundam. Tools Challenges, 2017. <https://doi.org/10.1016/B978-0-12-812133-7.00004-1>.
- [98] Srinivas, S. Sarvadevabhatla, R.K. Mopuri, K.R. Prabhu, N. Kruthiventi, S.S.S. Babu, R.V. An Introduction to Deep Convolutional Neural Nets for Computer Vision, içinde: Deep Learn. Med.

- Image Anal., 2017. <https://doi.org/10.1016/B978-0-12-810408-8.00003-1>.
- [99] Krizhevsky, A. Sutskever, I. Hinton, G.E. ImageNet Classification with Deep Convolutional Neural Networks, içinde: F. Pereira, C.J.C. Burges, L. Bottou, K.Q. Weinberger (Ed.), Adv. Neural Inf. Process. Syst., Curran Associates, Inc., 2012: ss. 1106–1114. <https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>.
- [100] Simonyan, K. Zisserman, A. Very deep convolutional networks for large-scale image recognition, içinde: 3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc., 2015.
- [101] Sengur, A. Akbulut, Y. Guo, Y. Bajaj, V. Classification of amyotrophic lateral sclerosis disease based on convolutional neural network and reinforcement sample learning algorithm, Heal. Inf. Sci. Syst. 5 (2017). <https://doi.org/10.1007/s13755-017-0029-6>.
- [102] Gürbüz, F.B. Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)(CNN) , (2020). <https://medium.com/@batincangurbuz/konvolüsyonel-sinir-ağları-evrişimli-sinir-ağları-olarak-da-bilinir-convolutional-neural-4ecd2c5ad842> (erişim 27 Kasım 2021).
- [103] Konca, M.S. Evrişimli Sinir Ağları (Convolutional Neural Networks — CNN), (2020). <https://mustafaserdarkonca.medium.com/evrişimli-sinir-ağları-convolutional-neural-networks-cnn-74b3d4a567f9> (erişim 27 Kasım 2021).
- [104] Long, J. Shelhamer, E. Darrell T., 2015. Fully convolutional networks for semantic segmentation, içinde: Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., <https://doi.org/10.1109/CVPR.2015.7298965>.
- [105] Ramachandran, P. Zoph, B. Le, Q.V. (2017) Searching for Activation Functions,, <http://arxiv.org/abs/1710.05941>.
- [106] Bingham, G. Macke, W. Miikkulainen, R. Evolutionary Optimization of Deep Learning Activation Functions, (2020). <https://doi.org/10.1145/3377930>.
- [107] Kooi, T. Litjens, G. van Ginneken, B. A. Gubern-Mérida, C.I. Sánchez, R. Mann, A. et al. (2017) Large scale deep learning for computer aided detection of mammographic lesions, Med. Image Anal. 35; 303–312. <https://doi.org/10.1016/j.media.2016.07.007>.
- [108] Singh, J. (2020) Activation Function Breakthrough,, <https://inblog.in/ACTIVATION-FUNCTION-BREAKTHROUGH-VOYVXHTELU> (erişim 27 Kasım 2021).
- [109] Kızrak, A. Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması, (2019). <https://ayyucekizrak.medium.com/derin-öğrenme-için-aktivasyon-fonksiyonlarının-karşılaştırılması-cee17fd1d9cd> (erişim 27 Kasım 2021).
- [110] Dias, C. Bueno, J. Borges, E. Lucca, G. Santos, H. Dimuro, G. Bustince, H. et al. 2019. Palmeira, Simulating the Behaviour of Choquet-Like (pre) Aggregation Functions for Image Resizing in the Pooling Layer of Deep Learning Networks, içinde: Adv. Intell. Syst. Comput., ss. 224–236. https://doi.org/10.1007/978-3-030-21920-8_21.
- [111] Zhao, L. Huang, L. 2019. Exploring dynamic routing as a pooling layer, içinde: Proc. - 2019 Int. Conf. Comput. Vis. Work. ICCVW 2019., <https://doi.org/10.1109/ICCVW.2019.00095>.
- [112] Giusti, A. Cireşan, D.C. Masci, J. Gambardella, L.M. Schmidhuber, J. 2013 Fast image scanning with deep max-pooling convolutional neural networks, içinde: 2013 IEEE Int. Conf. Image Process., 4034–4038. <https://doi.org/10.1109/ICIP.2013.6738831>.
- [113] Lakkavaram, V. Raghuveer, L. Kumar, C. Sri, G. Habeeb, S. A review on Practical Diagnostic of Tomato Plant Diseases, (2019).
- [114] Brownlee, J. (2019). A Gentle Introduction to Batch Normalization for Deep Neural Networks,, <https://machinelearningmastery.com/batch-normalization-for-training-of-deep-neural-networks/> (erişim 01 Aralık 2021).
- [115] Pham, T.C. Hoang, V.D. Tran, C.T. Luu, M.S.K. Mai, D.A. Doucet, A. Luong, C.M. Improving binary skin cancer classification based on best model selection method combined with optimizing full connected layers of Deep CNN, içinde: 2020 Int. Conf. Multimed. Anal. Pattern Recognition, MAPR 2020, 2020. <https://doi.org/10.1109/MAPR49794.2020.9237778>.
- [116] Doğan, F. Türkoğlu, İ. (2019) Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme,

Dicle Üniversitesi Mühendislik Derg. 10. <https://doi.org/10.24012/dumf.411130>.

- [117] Wibisono A., Mursanto, P. Multi Region-Based Feature Connected Layer (RB-FCL) of deep learning models for bone age assessment, J. Big Data. 7 (2020). <https://doi.org/10.1186/s40537-020-00347-0>.
- [118] Keerthi, M. Building an image detector using Convolutional Neural Network, (y.y.). <https://mukul04-sk.medium.com/building-an-image-detector-using-convolutional-neural-network-1ba5ffc1090e> (erişim 27 Kasım 2021).
- [119] Wang, Y. Wang, Z. Feng, Y. Zhang, L. (2021). WDCCNet: Weighted Double-Classifer Constraint Neural Network for Mammographic Image Classification, IEEE Trans. Med. Imaging.. <https://doi.org/10.1109/tmi.2021.3117272>.
- [120] Agnes, S.A. Anitha, J. Pandian, S.I.A. Peter, J.D. Classification of Mammogram Images Using Multiscale all Convolutional Neural Network (MA-CNN), J. Med. Syst. 44 (2020). <https://doi.org/10.1007/s10916-019-1494-z>.
- [121] The Softmax function and its derivative, (2016). <https://eli.thegreenplace.net/2016/the-softmax-function-and-its-derivative/> (erişim 27 Kasım 2021).
- [122] Kızrak, M.A. Bolat, B. Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma, Bilişim Teknol. Derg. (2018). <https://doi.org/10.17671/gazibtd.419205>.
- [123] Yolcu Öztel, G. Yüz Analizine Dayalı Derin Öğrenme Tabanlı Bir İlgil Tespit Sisteminin Gerçekleştirilmesi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, 2019.
- [124] AlexNet (2012), (y.y.). <https://daeun-computer-uneasy.tistory.com/35?category=1005585> (erişim 27 Kasım 2021).
- [125] Geeksfor Geeks, (y.y.). <https://www.geeksforgeeks.org/understanding-GoogLeNet-model-cnn-architecture/> (erişim 27 Kasım 2021).
- [126] Yilmaz, E. Trocan, M.A modified version of GoogLeNet for melanoma diagnosis, J. Inf. Telecommun. 5 (2021). <https://doi.org/10.1080/24751839.2021.1893495>.
- [127] Szegedy, C. Liu, W. Jia, Y. Sermanet, P. Reed, S. Anguelov, D. Erhan, D. Vanhoucke, V. A. (2015) Rabinovich, Going Deeper with Convolutions, in Proc. IEEE Conf. Comput. Vis. pattern Recognit. 1–9.
- [128] Katzen, J. Dodelzon, K. (2018) A review of computer aided detection in mammography, Clin. Imaging. 52 305–309. <https://doi.org/10.1016/J.CLINIMAG.2018.08.014>.
- [129] Pavlovsky, V. (2017) Introduction To Convolutional Neural Networks,. <https://www.vojtech.net/posts/intro-convolutional-neural-networks/> (erişim 01 Aralık 2021).