

KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
DOKTORA TEZİ

DİNAMİK KONTRASTLI MANYETİK REZONANS  
GÖRÜNTÜLERİNDE BİLGİSAYARLI  
MEME KANSERİ SINIFLANDIRMASI

Ahmet Haşim YURTTAKAL

MAYIS 2019

**KIRIKKALE ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**DİNAMİK KONTRASTLI MANYETİK REZONANS**  
**GÖRÜNTÜLERİNDE BİLGİSAYARLI**  
**MEME KANSERİ SINIFLANDIRMASI**

**2019**  
**KIRIKKALE**

## ONAY SAYFASI

**Bilgisayar Mühendisliği Anabilim Dalında** Ahmet Haşim YURTTAKAL tarafından hazırlanan **DİNAMİK KONTRASTLI MANYETİK REZONANS GÖRÜNTÜLERİNDE BİLGİSAYARLI MEME KANSERİ SINIFLANDIRMASI** adlı Doktora Tezinin Anabilim Dalı standartlarına uygun olduğunu onaylarım.

Prof. Dr. Hasan ERBAY  
Anabilim Dalı Başkanı

Bu tezi okuduğumu ve tezin **Doktora Tezi** olarak bütün gereklilikleri yerine getirdiğini onaylarım.

Prof. Dr. Hasan ERBAY  
Danışman

### Jüri Üyeleri

Başkan : Prof. Dr. Adem Alpaslan ALTUN \_\_\_\_\_  
Üye (Danışman) : Prof. Dr. Hasan ERBAY \_\_\_\_\_  
Üye : Dr. Öğr. Üyesi Bülent Gürsel EMİROĞLU \_\_\_\_\_  
Üye : Dr. Öğr. Üyesi Cenker BIÇER \_\_\_\_\_  
Üye : Dr. Öğr. Üyesi Hakan KÖR \_\_\_\_\_

30/05/2019

Bu tez ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Doktora derecesini onaylamıştır.

Prof. Dr. Recep ÇALIN  
Fen Bilimleri Enstitüsü Müdürü

## ÖZET

### DİNAMİK KONTRASTLI MANYETİK REZONANS GÖRÜNTÜLERİNDE BİLGİSAYARLI MEME KANSERİ SINIFLANDIRMASI

YURTTAKAL, Ahmet Haşim

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı, Doktora tezi

Danışman: Prof. Dr. Hasan ERBAY

Mayıs 2019, 100 sayfa

Meme kanseri, meme dokusundaki hücrelerde gelişen kanser türüdür. Kadınlarda en sık görülen kanser türüdür. Meme kanseri tümörünün erken teşhisi, tedavi sürecinde hayati öneme sahiptir. Mamografi, fiziksel belirtiler gelişmeden önce meme kanserini erken bir aşamada tanımlamak için değerli bir araçtır. Meme görüntülerini oluşturmak için X ışınlarını kullanan, memenin özel bir radyografisidir. Mamografide yanlış-negatif teşhisi azaltmak için, % 2'den daha fazla habis tümör şüphesi olma ihtimali olan lezyonlar için biyopsi önerilmektedir ve bunların arasında % 30'dan daha azının habis olduğu tespit edilmiştir. Gereksiz biyopsileri azaltmak için, son zamanlarda, Manyetik Rezonans Görüntüleme (MRG) de meme kanseri tanısı için kullanılmıştır. MRG, meme kanseri tümörlerini tespit etmek, izlemek ve lezyonlu bölgeleri yorumlamak için önerilen bir testtir çünkü yumuşak doku görüntüleme için mükemmel bir kabiliyete sahiptir. Doku görüntüsünü oluştururken, biyolojik olarak zararlı kabul edilen iyonlaştırıcı radyasyon yerine yüksek manyetik alanlar ve radyo frekansında sinyaller kullanılmaktadır. Bununla birlikte, deneyimli bir radyolog ve zaman alıcı bir süreç gerektirmektedir.

Öte yandan, Evrişimsel Sinir Ağları (ESA) görüntü sınıflandırmada makine öğrenmesi tabanlı yöntemlerle karşılaştırıldığında görüntü sınıflandırmada daha iyi performans göstermiştir.

Bu tez çalışmasında, MRG görüntüleri kullanarak meme kanseri tümörünü teşhis etmek için ESA'lar kullanılmaktadır. Yalnızca piksel bilgilerini kullanarak, çevrimiçi veri artışına sahip, çok katmanlı bir ESA modeli tasarlanmıştır. Önerilen ESA modelinin doğruluğu %98.33, hata oranı 0.0167 duyarlılığı 1.0, özgüllüğü %96.88 iken kesinlik değeri %96.55'tir. Doğruluk, hata oranı, hassasiyet, duyarlılık, özgüllük gibi performans ölçümleri, ağın umut verici olduğunu göstermektedir.

**Anahtar kelimeler:** Meme kanseri, evrimsel sinir ağları, sınıflandırma, veri artırma, Manyetik rezonans görüntüleme.



## **ABSTRACT**

### **COMPUTERIZED BREAST CANCER CLASSIFICATION IN DYNAMIC CONTRAST MAGNETIC RESONANCE IMAGES**

**YURTTAKAL, Ahmet Haşim**

**Kırıkkale University**

**Graduate School of Natural and Applied Sciences**

**Department of Computer Engineering, Ph. D. Thesis**

**Supervisor: Prof. Dr. Hasan ERBAY**

**Mayıs 2019, 100 pages**

Breast cancer is the type of cancer that develops from cells in the breast tissue. It is the most common type of cancer in women. Early detection of the breast cancer tumor is vital in the treatment process. Mammography is a valuable tool to identify breast cancer at an early stage before physical symptoms develop. It is a special radiography of the breast that uses X-rays to produce the breast images. To reduce false-negative diagnosis in mammography, a biopsy is recommended for lesions with greater than a 2% chance of having suspected malignant tumors and, among them, less than 30 percent are found to have malignancy. To decrease unnecessary biopsies, recently, Magnetic Resonance Imaging (MRI) has also been used for the diagnosis of breast cancer. MRI is the highly recommended test for detecting and monitoring breast cancer tumors and interpreting lesioned regions since it has an excellent capability for soft tissue imaging. It uses high magnetic fields and radio-frequency signals instead of ionizing radiation, which is considered biologically harmful, to produce the tissue image. However, it requires an experienced radiologist and time-consuming process.

On the other hand, Convolutional Neural Networks (CNNs) have demonstrated better performance in image classification compared to machine learning based methods

In this thesis, CNNs were used to diagnose breast cancer tumor using MRI images. Using only pixel information, a multi-layer CNN model was designed with online

data augmentation. The accuracy of the proposed network was %98.33, the error rate was 0.0167, sensitivity was 1.0, specificity was 0.9688 whereas precision was 0.9655. The performance metrics such as accuracy, error rate, sensitivity, specificity, and precision state that the network is promising

**Key Words:** Breast cancer, convolutional neural network, classification, data augmentation, magnetic resonance imaging.



## TEŐEKKÜR

Tezimin hazırlanması esnasında bilimsel konularda yardımcı esirgemeyen ve biz genç arařtırmacılara büyük destek olan, tez danışmanım, Sayın Prof. Dr. Hasan ERBAY'a, istatistiki konularda desteęini gördüğüm, Sayın Dr. Öğretim Üyesi Cenker BİÇER'e, tez çalışmalarım esnasında, tıbbi konularda daima yardımcı gördüğüm Sayın Doç. Dr. Seyhan KARAÇAVUŐ'a ve Sayın Dr. Öğretim Üyesi Türkan İKİZCELİ'ye ve son olarak bana birçok konuda olduęu gibi, tezimi hazırlamam esnasında da yardımlarını esirgemeyen sevgili eşime teşekkür ederim.





# İÇİNDEKİLER DİZİNİ

Sayfa

<b>ÖZET</b> .....	<b>iii</b>
<b>ABSTRACT</b> .....	<b>v</b>
<b>TEŞEKKÜR</b> .....	<b>vii</b>
<b>İÇİNDEKİLER DİZİNİ</b> .....	<b>viii</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>x</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>xii</b>
<b>SİMGELER DİZİNİ</b> .....	<b>xiii</b>
<b>KISALTMALAR DİZİNİ</b> .....	<b>xiv</b>
<b>1 GİRİŞ</b> .....	<b>1</b>
1.1. Motivasyon.....	1
1.2. Problem Formülasyonu .....	2
1.3. Tezin amacı ve organizasyonu .....	2
<b>2 LİTERATÜR TARAMASI</b> .....	<b>4</b>
2.1. Bilgisayar Destekli Tanı Sistemleri .....	4
2.2. Makine Öğrenmesi Tabanlı Bilgisayar Destekli Tanı Sistemleri .....	6
2.3. Derin Öğrenme Tabanlı Bilgisayar Destekli Tanı Sistemleri .....	9
<b>3 MATERYAL VE METOD</b> .....	<b>11</b>
3.1. Meme Kanseri .....	11
3.1.1. Meme kanseri türleri.....	12
3.1.2. Meme kanseri evreleri .....	13
3.2. Biyomedikal Görüntüleme .....	14
3.2.1. Meme görüntüleme teknikleri .....	14
3.2.2. Dinamik kontrastlı manyetik rezonans görüntüleme.....	16
3.3. Derin Öğrenme.....	17
3.4. Evrişimsel Sinir Ağı.....	21
3.4.1. Veri ön işleme.....	22
3.4.2. Veri artırma .....	24
3.4.3. Ağ katmanları .....	25
3.4.3.1. Evrişim katmanı (Convolution Layer).....	25
3.4.3.2. Küme normalizasyonu (Batch Normalization).....	27
3.4.3.3. Aktivasyon katmanı (Activation Layer) .....	29

3.4.3.4.	Havuzlama katmanı (Pooling Layer).....	37
3.4.3.5.	Seyreltme katmanı (Dropout Layer).....	38
3.4.3.6.	Tamamen bağı katman (Fully Connected Layer).....	38
3.5.	Sinir Ağı Eğitme .....	39
3.5.1.	Ağ ağırlığı başlatma .....	39
3.5.2.	Düzenleştirme.....	41
3.5.3.	Kayıp Fonksiyon .....	42
3.5.4.	Optimizasyon.....	44
3.5.5.	Hiper parametreler.....	47
3.6.	Görselleştirme .....	47
3.7.	Sinir Ağı Değerlendirme.....	48
3.7.1.	Aşırı öğrenme ve yetersiz öğrenme durumları .....	48
3.7.2.	Doğrulama süreci .....	49
3.7.3.	Performans metrikleri.....	50
<b>4</b>	<b>ARAŞTIRMA BULGULARI VE TARTIŞMA.....</b>	<b>54</b>
4.2.	Veri seti .....	54
4.3.	İlgili tümör bölgesinin belirlenmesi ve önışlem .....	56
4.4.	Veri artırma .....	58
4.5.	Önerilen ESA modeli .....	58
4.6.	Önerilen modelin eğitilmesi.....	63
4.7.	Önerilen modelin performansının değerlendirilmesi .....	65
<b>5</b>	<b>SONUÇ VE ÖNERİLER.....</b>	<b>69</b>
	<b>KAYNAKÇA .....</b>	<b>71</b>
	<b>EKLER.....</b>	<b>82</b>

## ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
2.1. Makine öğrenmesi ve derin öğrenme.....	4
2.2. Görüntüleme türlerine göre meme kanseri BDT sistemleri .....	5
2.3. Sınıflandırma tekniklerine göre meme kanseri BDT sistemleri.....	6
3.1. Meme yapısı .....	11
3.2. Yapay zekâ türleri arasındaki ilişki.....	18
3.3. Çok katmanlı perseptron .....	19
3.4. Boltzmann makinesi.....	19
3.5. Kısıtlı boltzmann makinesi .....	20
3.6. Derin inanç ağı .....	20
3.7. Oto-kodlayıcılar .....	21
3.8. Tekrarlayıcı sinir ağı .....	21
3.9. Evrişimsel sinir ağı.....	22
3.10. Normalizasyon türleri.....	23
3.11. Temel bileşen analizi ve beyazlatma.....	24
3.12. Örnek ağ katmanları.....	25
3.13. Evrişim katmanında filtrenin uygulanışı.....	26
3.14. Basamak fonksiyon .....	30
3.15. Doğrusal fonksiyon .....	31
3.16. Sigmoid fonksiyon .....	32
3.17. Hiperbolik tanjant fonksiyon.....	33
3.18. Softmax fonksiyon .....	34
3.19. Relu fonksiyon .....	35
3.20. Prelu fonksiyon .....	36
3.21. Elu fonksiyon .....	37
3.22. Havuzlama işlemi.....	38
3.23. Seyreltme işlemi.....	38
3.24. Ağırlıkların güncellenmesi.....	43
3.25. Genelleştirme hatası.....	48
3.26. Karışıklık matrisi.....	50
4.1. Veri setindeki orijinal iyi huylu tümör örnekleri .....	55

4.2. Veri setindeki orijinal habis tümör örnekleri .....	56
4.3. Orijinal görüntü .....	57
4.4. (a) Kırılmış orijinal tümörlü bölge (b) Yeniden boyutlandırılarak ön işlemden geçmiş tümörlü bölge .....	57
4.5. Veri kümesinde önışlemden geçmiş tümör örnekleri.....	57
4.6. Sınıflandırma süreci .....	58
4.7. Önerilen ESA modeli .....	59
4.8. Önerilen ESA modelinin doğruluk grafiđi.....	63
4.9. Önerilen ESA modelinin kayıp grafiđi .....	64
4.10. Birinci evrişim katmanında öğrenilen özellikler.....	65
4.11. Özelliklerin Şekil 4.4.(b)'ye uygulanması .....	65
4.12. Önerilen modelin karışıklık matrisi .....	66

## ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
3.1. Meme kanseri evreleri.....	14
4.1. Veri seti özellikleri.....	55
4.2. Önerilen ağ mimarisindeki katmanlar.....	59
4.3. Önerilen ağ mimarisinin parametre sayıları.....	61
4.4. Hiper parametreler.....	62
4.5. Eğitim ve kontrol grupları.....	63
4.6. Performans ölçütleri.....	66
4.7. Literatür karşılaştırması.....	67

## SİMGELER DİZİNİ

I	Giriş Görüntüsü
K	Filtre
O	Özellik Haritası
p	Piksel Ekleme Parametresi
s	Kaydırma Adımı Parametresi
$\mu$	Küme Ortalaması
$\sigma$	Varyans
$\varepsilon$	Epsilon
$\gamma$	Ölçeklendirme Parametresi
$\beta$	Ofset Kaydırma Parametresi
$\lambda$	Düzenleştirme Parametresi
$\ell$	İterasyon Sayısı
$\alpha$	Öğrenme Oranı
$\theta$	Parametre Vektörü
$E(\theta)$	Kayıp Fonksiyon
$\nabla E(\theta_\ell)$	Kayıp Fonksiyonun Gradyanı
$\beta_1$	Gradyan Bozulma Oranı
$\beta_2$	Kare Gradyan Bozulma Oranı
$v_\ell$	Hareketli ortalama

## KISALTMALAR DİZİNİ

MRG	Manyetik Rezonans Görüntüleme
MR	Manyetik Rezonans
ESA	Evrışimsel Sinir Ağı
BI-RADS	Meme Görüntüleme ve Veri Sistemi
BDT	Bilgisayar Destekli Tanı
DK-MRG	Dinamik Kontrastlı Manyetik Rezonans Görüntüleme
DBN	Derin İnanç Ağı
AJCC	Amerika Kanseri Ortak Komitesi
MG	Mamografi
US	Ultrason
BT	Bilgisayarlı Tomografi
X-Ray	Radyografi
DCIS	Duktal Karsinoma In Situ
MLP	Çok Katmanlı Perseptron
DNN	Derin Sinir Ağı
BM	Boltzmann Makinesi
RBM	Kısıtlı Boltzmann Makinesi
RNN	Tekrarlayıcı sinir ağı
RELU	Doğrultulmuş Lineer Birim
PRELU	Parametrik Doğrultulmuş Lineer Birim
ELU	Üstel Lineer Birim
TP	Gerçek Pozitif
TN	Gerçek Negatif
FP	Yanlış Pozitif
FN	Yanlış Negatif
TNR	Doğru negatif oran
NPV	Negatif tahmini değer
FPR	Yanlış pozitif oranı
FDR	Yanlış keşif oranı
FNR	Yanlış negatif oranı
MCC	Matthews Korelasyon Katsayısı

# 1 GİRİŞ

## 1.1. Motivasyon

Meme kanseri, kadınlarda en sık görülen kanser türüdür. Meme kanseri, dünyada tüm kadın kanserlerinin % 23'ünü oluşturmaktadır [1]. Batı ülkelerinde, her sekiz ila dokuz kadından birinin yaşamı boyunca bir noktada meme kanseri vardır [2]. T.C. Sağlık Bakanlığı'nın yayınladığı 2014 verilerine göre, tanı konulan her 4 kadın kanserinden 1'i meme kanseridir. Ülkemizde meme kanseri tanısı alan kadınların %44,5'i 50-69 yaş arasında olduğu, %40,4'ünün ise 25-49 yaş aralığında yer aldığı görülmektedir [3].

Meme kanseri tümörünün erken teşhisi tedavi sürecinde çok önemlidir. Mamografi meme kanserini erken aşamada fiziksel semptomlar gelişmeden önce tanımlayabilmesi bakımından çok değerli bir görüntüleme yöntemidir. Ayrıca tarama mamografi meme kanseri nedeniyle ölümleri azalttığı kanıtlanmış tek testtir [4-7]. Mamografide yanlış-negatif teşhisi azaltmak için % 2'den fazla habis (*malign*) tümör şüphesi olan lezyonlar için bir biyopsi önerilmektedir [8]. Aralarında yüzde 30'dan daha azının habis olduğu bulunmuştur [9, 10].

Gereksiz biyopsileri azaltmak için, son zamanlarda, Manyetik Rezonans Görüntüleme (MRG) de meme kanseri teşhisinde kullanılmaktadır [11, 12]. Yumuşak doku görüntüleme mükemmel bir kabiliyete sahiptir. Ayrıca meme hastalıklarını saptamada hassas bir teknik olmasının yanında, potansiyel olarak tehlikeli radyasyon içermemektedir [13]. Fakat MR görüntülerini yorumlamak hem zaman alır hem de okuyucu deneyimi gerektirir. Ek olarak, mevcut standart teşhis MRG protokolünün alınması ve yüzlerce resim içermesi çok zaman alır. MRG'de kötü huylu lezyonun tespit edilmesinde boyut, odak sayısı vb. parametreler kullanılmaktadır. Yapılan bir meta analizde MR görüntülemenin pozitif öngörü değeri %62, negatif öngörü değeri %84 olarak bulunmuş, tedavi değişikliği %6 olguda gerekli görülmüştür [14]. Son yıllarda, anormal lezyonları tespit etmek ve tıbbi görüntülerde doku karakterizasyonunu belirlemek için bilgisayar destekli programlar geliştirilmiştir [15, 16].



Öte yandan evrişimsel sinir ağırları (ESA) [17] son yıllarda yaygın olarak kullanılan bir tekniktir ve tıbbi görüntüleme beyin tümörü bölütlemesi gibi alanlarda ümit verici performans göstermektedir [18]. Bilgisayarlı tomografi görüntülerinde pankreas segmentasyonu [19], ultrason görüntülerinde karotis intima media kalınlığı ölçümü [20], yanlış tanıyı azaltmak ve hastalıkların erken tespitini kolaylaştırmak amacıyla yapılmıştır. ESA'lar otomatik olarak eğitim görüntüsü setinden yüksek düzeyde temsili ve hiyerarşik özellikleri öğrenir [21]. ESA'lar ayrıca görüntüleri yüksek duyarlılık ve özgünlük ile sınıflandırmada popüler hale gelmiştir.

## 1.2. Problem Formülasyonu

Çalışmanın konusu, ESA'ların, iyi huylu ve habis tümörleri ayırt etmek için, tümörün biyolojik özellikleri, aşağıdaki gibi formüle edilebilecek farklılıkları yansıtsa bile, potansiyel kullanımını araştırmaktır:

*Bir dizi meme görüntüsü verildiğinde, dizinin tüm öğelerini iyi huylu veya kötü huylu tümörler olarak sınıflandırın.*

Problemin formülasyonunda, sınıflandırma kriterleri Meme MR görüntüleme ve veri sistemi (BI-RADS) kategorisi [22] tarafından belirlenir. Kötü huylu tümörler yapısal bozulma ile birlikte düzensiz şekillerde ortaya çıkar. Öte yandan, iyi huylu tümörler yuvarlak veya ovaldir ve iyi tanımlanmış kenarlara sahiptir veya makro-lobüle edilmiştir [23].

Her iki tümör MRG'de farklı görünür. Ancak yine de meme kitleleri bazen görüntüleme yöntemleri üzerinde kanserli ve iyi huylu kitleler arasında örtüşebilir ve bunları ayırmak için bir biyopsi gerekebilir [24]. ESA modeli, eğitim aşamasında tümörün bu özelliklerini, insanın yaptığı gibi, insanın gerçek yaşamıyla anlamsal olarak tutarlı olan faaliyetlerden öğrenir [25, 26].

## 1.3. Tezin amacı ve organizasyonu

Çalışmanın amacı, biyopsi gerektirmeden bilgisayar yardımıyla otomatik olarak iyi huylu ve habis meme kitlelerini ayırt etmektir. Bu bağlamda tez kapsamında Meme

MR görüntülerini kullanan kullanıcıdan bağımsız, karar destek süreçlerinde zaman kazandıran yeni bir derin ESA mimarisi önerilmiştir. Yalnızca piksel bilgilerini kullanarak, çevrimiçi veri artırma işlemine sahip çok katmanlı bir ESA modeli tasarlanmıştır. Doğruluk, hata oranı, hassasiyet, duyarlılık, özgüllük gibi performans ölçümleri, ağın umut verici olduğunu göstermektedir.

Tezin 2. Bölümünde kaynak taramasına yer verilmiştir. 3. Bölümde meme kanseri, görüntüleme türleri ve derin öğrenmenin anlatıldığı materyal metot bulunmaktadır. 4. Bölümde araştırma bulguları ve tartışma sunulmuştur. 5. Bölümde sonuç ve önerilere yer verilmiştir.



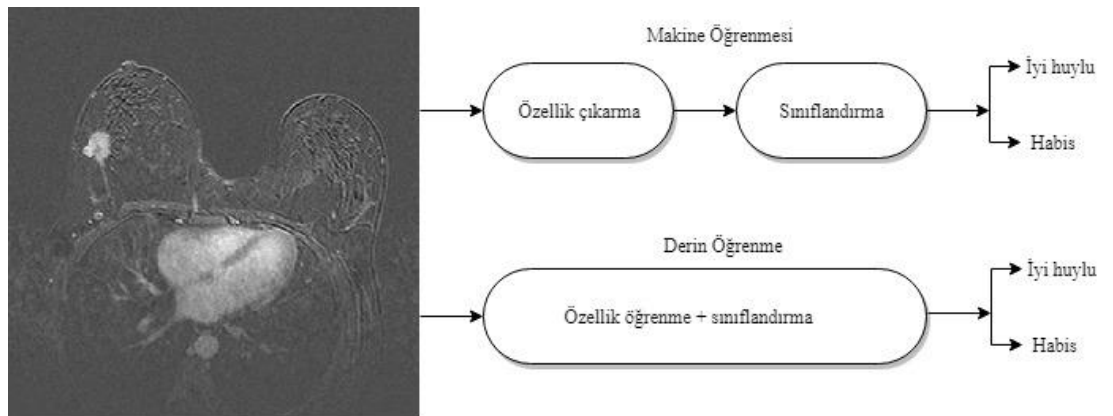
## 2 LİTERATÜR TARAMASI

### 2.1.Bilgisayar Destekli Tanı Sistemleri

Medikal görüntülerin değerlendirilmesi genellikle öznel, deneysel, zaman alan, uzmana bağlı, yorucu bir görevdir ve radyologlar tarafından elle gerçekleştirilir. Bilgisayar teknolojilerinde son yıllarda yaşanan gelişmeler, radyolojik görüntülerde lezyon tespiti için modern bilgisayarlı tanı sistemlerinin gelişimini kolaylaştırmıştır. Bilgisayar destekli tanı (BDT) sistemleri, radyoloji uzmanlarına medikal görüntülerdeki anormallikleri tespit etmede ikinci görüş olarak yardımcı olmaktadır. Teşhis konusunda nihai karar radyologa aittir ve kesin tanı histopatolojik yöntemler ile konulmaktadır.

BDT sistemleri iki ana aşamadan oluşur: (1) analiz aşaması (2) tanı aşaması. Analiz aşaması ön işleme, segmentasyon ve özellik çıkarımı gibi bir dizi işlemten oluşmaktadır. Tanı aşaması, çıkartılan özelliklere göre sınıflandırma ve değerlendirme işlemlerinden oluşmaktadır.

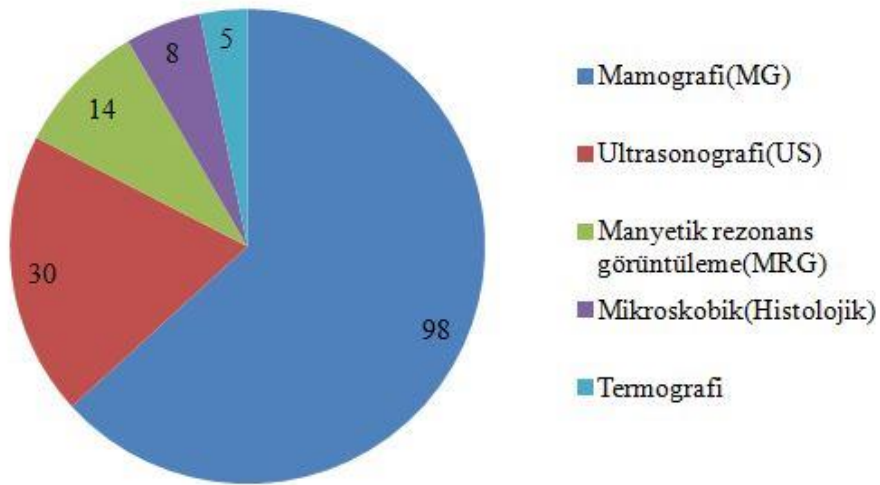
BDT sistemlerinde, genellikle makine öğrenmesi veya derin öğrenme algoritmaları tercih edilmektedir. Şekil 2.1’de makine öğrenmesi ve derin öğrenme algoritmaları arasındaki fark gösterilmektedir.



Şekil 2.1. Makine öğrenmesi ve derin öğrenme


Makine öğrenmesi, sistemin tümörü tanımasında görüntüden elle çıkarılan özelliklere göre sınıflandırma yapan, yapay zekânın bir alt grubudur. Derin öğrenme algoritmaları ise özellikleri otomatik olarak tanımlar. Derin öğrenme, önce bir tümörü iyi huylu veya habis olduğunu bulmak için en alakalı faktörlerin hangisi olduğunu tanımlamaktadır. Daha sonra tümörü daha derinden tanımak için şekiller ve kenarların birleşimini tanımlamaya başlamaktadır. Bunun gibi konseptlerin ardışık hiyerarşik bir şekilde tanımlanmasından sonra, doğru cevabı bulmak için hangi özelliklerin sorumlu olduğuna karar vermektedir. Literatürdeki çalışmaların çoğu, makine öğrenmesi tabanlı yöntemlerdir. Bununla birlikte, ESA tıbbi görüntüleme makine öğrenmesi tabanlı yöntemlerle karşılaştırıldığında görüntü sınıflandırmada daha iyi performans göstermiştir [27].

Yassin ve diğerleri (2018), yapmış oldukları sistematik derleme çalışmalarında medikal görüntüleme türlerine ve sınıflandırma tekniklerine göre meme kanseri bilgisayar destekli tanı sistemlerini tanımlamayı amaçlamışlardır. Bunun için Springer Link (<http://www.springerlink.com>), Science Direct (Elsevier) (<http://www.sciencedirect.com>), IEEE Xplore (<http://www.ieeexplore.ieee.org>) ve Pubmed (<https://www.ncbi.nlm.nih.gov/pubmed/>) gibi birkaç elektronik veritabanında, 2012'den Ocak 2017 yılları arasında basılan yayınları incelemişlerdir. Şekil 2.2'de görüntüleme türlerine göre meme kanseri bilgisayar destekli tanı sistemleri yayın sayıları verilmiştir. Buna göre manyetik rezonans görüntüleri kullanılarak yapılan çalışmalar, mamografi ve ultrasonografiye göre daha azdır [28].



**Şekil 2.2.** Görüntüleme türlerine göre meme kanseri BDT sistemleri [28]

Şekil 2.3’de farklı sınıflandırma tekniklerine göre meme kanseri bilgisayar destekli tanı sistemleri yayın sayıları verilmiştir. Sistematik derlemeye göre, destek vektör makineleri ve yapay sinir ağları en sık kullanılan sınıflandırıcı algoritmalar olurken, derin öğrenme algoritmaları kullanılarak yapılan çalışmalar 7 adettir. Bunlardan 5 tanesinde mamografi, birer tanesinde ultrasonografi ve histoloji görüntüleri kullanılmıştır. Manyetik rezonans görüntüleri bakımından literatürde eksiklik dikkat çekmektedir.



Şekil 2.3. Sınıflandırma tekniklerine göre meme kanseri BDT sistemleri [28]

## 2.2.Makine Öğrenmesi Tabanlı Bilgisayar Destekli Tanı Sistemleri

Waugh ve diğerleri (2016), gri seviye yineleme matris özelliklerini kullanan invazif olmayan lezyon alt tip sınıflandırma sistemi önermiştir. Hem eğitim hem test sırasında benzer histolojik alt tip sınıflandırması yapılmıştır. Önerdiği yöntem, eğitim için %75 doğruluk, 0.816 AUROC değeri, test için %72.5 doğruluk, 0.823 AUROC değeri elde etmiştir [29].

Gubern-Merida ve diğerleri (2015). lezyonları bulmak için otomatik bir sistem geliştirdiler. Yaptıkları çalışmada, 209 dinamik kontrastlı manyetik rezonans görüntüleme (DK-MRG) görüntülerinden (104 sağlıklı tarama vakası ile birlikte 55 kitle ve 50 kitle dışı habis lezyon) oluşan özel veri seti kullanmışlardır. Dört yanlış

pozitif (*False Positive*) tahmininde %89 doğruluk (kitle benzeri habis lezyonlar için % 91 doğruluk ve kitle benzeri olmayan habis lezyonlar için % 86 doğruluk) elde etmişlerdir [30].

Cai ve diğerleri (2014), dört farklı sınıftaki 28 özelliğin farklı görüntüleme protokolleri altında toplanan veri setine etkilerini analiz etmişlerdir. Sonuç olarak, tüm özellikleri kullanmak yerine, en yüksek tanısal etki oranına sahip beş özelliğin Destek Vektör Makinesini (DVM) kullanarak % 82.8 en yüksek sınıflandırma doğruluğuna sahip olduğunu belirlemişlerdir. Çalışmada, bulanık bölgeyi kümelemeyi (*fuzzy c-means*) ve bir gradyan vektör akış yılanı algoritmasını (*gradient vector flow snake algorithm*) ilgilenilen bölgeyi (*ROI*) segment etmek için dahil edilmiştir [31].

Weiss ve diğerleri (2014), yüksek spektral ve uzaysal çözünürlüklü MRG veri setlerinde su rezonansının Lorentziyan olmayan bileşenlerini karakterize eden nicel bir görüntüleme biyo-belirteçini araştırmışlardır. Lezyon segmentasyonu için bulanık bölgeyi kümelemeyi kullanmışlardır. Voksel bazlı sınıflandırmada 0.88 AUC değerine ulaşmışlardır [32].

Retter ve diğerleri (2013), tanısal açıdan zor lezyonları saptamak için bir sistem geliştirmişlerdir. Sistem, optik akış yöntemine, segmentasyona, morfolojik ve kinetik özellik çıkarımına ve lezyonlardan çıkarılan özellikler için bir değerlendirme yöntemi olarak sınıflandırmaya dayalı yeni bir hareket dengeleme algoritması içermektedir [33].

Milenković ve diğerleri (2013), gri seviye yineleme matrisine ek olarak üç parametrik haritanın (başlangıç geliştirme haritası, başlangıç sonrası geliştirme haritası ve sinyal geliştirme oran haritası) zamansal gelişimlerinin uzamsal varyasyonuna bağlı olarak habis ve iyi huylu lezyonlar arasındaki farklılaşmadaki olası artışını analiz etmişlerdir. Sonuç olarak, teşhis testi 0.9193 duyarlılık oranına ulaşmıştır [34].

Hassanien ve diğeri (2012), dalgacık tabanlı özellik çıkarma ile bulanık kümeler, yapay sinir ağı, DVM birlikte kullanıldığı melez bir yöntem önermişlerdir. Çalışmada kullanılan veri kümesi normal ve anormal olmak üzere iki kategoriye ait 120 resim içermektedir. Anormal kabul edilen, 50 iyi huylu ve kötü huylu 70 normal görüntü vardır. Sonuç olarak DVM %98 ile en yüksek doğruluk elde ederken, yapay sinir ağı %91 doğruluk etmiştir [35].

Yurttakal ve diğeri (2018), MR görüntülerini kullanarak meme kanseri tümörünü bölümlere ayırmak ve iyi huylu-habıs ayırımını yapabilmek için yarı otomatik bilgisayar destekli tanı (BDT) sistemi önermişlerdir. BDT, ilgilenilen bölgeleri segment edebilmek için Beklenti Büyütme (*Expectation Maximization*) algoritmasını kullanmışlardır. Özellik çıkarma aşamasında beşi birinci dereceden yoğunluğa dayalı istatistiksel özellikler ve dördü gri seviye yineleme matrisi tabanlı olmak üzere toplam 9 adet doku özellikleri çıkartılmıştır. Sınıflandırma aşamasında C4.5 Karar ağacı yöntemi ile 0.9524 doğruluk elde etmişlerdir [36].

Soares ve diğeri (2014), DK-MRG ile elde edilen görüntülerin multifraktal analizi yoluyla meme kitlelerinin şüpheli habıs sınıflandırılması için çok ölçekli bir otomatik model önermişlerdir. DVM sınıflandırıcısı kullanılarak 0.985'lik AUROC değeri elde etmişlerdir [37].

Gallejo-Ortiz ve Martel (2015), memenin DK-MRG sırasındaki kitle ve kitle dışı gelişmeleri ayırt etmek için bir BDT sistemi önermişlerdir. Bunun için 176 özellik çıkarmışlardır. Sonuç olarak, kitle ve kitle olmayan lezyonlarda kinetik, doku ve morfolojik özelliklerin uygunluk düzeyi sıralamasının farklı olduğunu tespit etmişlerdir. En iyi performans, iki kademeli sınıflandırıcı, kitle için % 91 AUC, kitle dışı % 95 AUC ile elde etmişlerdir [38].

Yang ve diğeri (2015), arka plan parankimal iyileştirme (*background parenchymal enhancement*) özelliklerini karar verme sürecine entegre ederek DK-MRG kullanarak meme kanseri tanı performansını iyileştirmişlerdir. Sadece tümörlerden hesaplanan kinetik özellikleri kullanarak, maksimum AUC değeri  $0.865 \pm 0.035$  elde etmişlerdir.

Bununla birlikte, arka plan parankimal iyileştirme özellikleri ile AUC değeri  $0,919 \pm 0,029$ 'a yükselmiştir [39].

Bhooshan ve diğerleri (2014), meme tümör bölgelerinin tanısal sınıflamasında yüksek spektral ve uzaysal çözünürlüklü (HiSS) MRG'nin BDT analizinin performansını DK-MRG ile karşılaştırmıştır. 41 adet özel veri üzerinde yaptıkları çalışmada HiSS için  $0.92 \pm 0.06$  AUC, DCE-MRI için  $0.90 \pm 0.05$  AUC elde etmişlerdir [40].

Agner ve diğerleri (2014), meme kanseri alt tiplerini ayırt edebilen ve böyle bir BDT sisteminin gelişmesini mümkün kılan MRG ile görüntüleme fenotiplerinin gerçekten mümkün olduğunu göstermiştir [41].

Yurttakal ve diğerleri (2018), tümörlerin yapısını daha iyi tanımlayabilmek için diğer kanser türlerinden daha nadir görülen tiroid kanseri tümörlerini, yürüyen küpler algoritması ile piksel değerlerini kullanarak 3 boyutlu modellemiştir [42].

### **2.3.Derin Öğrenme Tabanlı Bilgisayar Destekli Tanı Sistemleri**

Dhungel ve diğerleri (2015), toplu aday üretimi için Gauss Karışım Modeli sınıflandırıcısı ile birleştirilmiş çok ölçekli bir derin inanç ağı (DBN) önermiştir. Daha sonra adaylara dokusal ve morfolojik özellikler çıkarmak için bir ESA beslenmiştir. Kullanılan doğrusal DVM sınıflandırıcısı ile % 96 duyarlılık elde etmişlerdir [43].

Fonseca ve diğerleri (2015), mammogram görüntüleri kullanarak DVM sınıflandırıcı ile birlikte özellik çıkarımı için ESA'larda otomatik bir meme yoğunluğu sınıflandırma yöntemi tasarlamışlardır. AUC'nin değeri 0,73 elde etmişlerdir [44].

Samala ve diğerleri (2016), dijital meme tomosentezinde doğru ve yanlış mikrokalsifikasyonları ayırt etmede Derin Öğrenme ESA BDT sisteminin bir uygulamasını analiz etmişlerdir. 64 dijital göğüs tomosentezi kullanılarak AUC değeri 0.93 olarak bulmuşlardır [45].



Son zamanlarda, Huynh ve diğeri (2016), bazı özellikleri çıkarmak için transfer öğrenmeyi içeren derin sinir ağlarına dayanan bir meme görüntüleme BDT sistemi geliştirdiler. Daha sonra, bir topluluk sınıflandırıcısı kullanılarak, 0.94 AUC değerine ulaşmışlardır [46].

Carneiro ve diğeri (2015), kayıtlı olmayan mamogramlar, segment edilmiş mikrokalsifikasyonlar ve kitleler kullanarak ImageNet ile önceden eğitilmiş bir ESA model geliştirmişlerdir. InBreast veri setinde AUC değeri % 91, DDSM veri setinde % 97 AUC değeri elde etmişlerdir [47].

Lévy ve diğeri (2016), meme kitle sınıflandırması için üç ağ mimarisini (Basit ESA, AlexNet, GoogLeNet) eğitmiş ve ağları ön eğitim ile başlatan ağları ImageNet veri seti üzerindeki etkisini analiz etmişlerdir. Sonuç olarak AlexNet ile % 89 doğruluk, GoogleNet ile % 92.9 doğruluk elde etmişlerdir [48].

Tümörün daha iyi sınıflanabilmesi için bölütlenmesi çok önemlidir. Xu ve diğeri (2018), DK-MRG görüntülerini bölütleyebilmek için U-Net ESA modelini kullanmışlardır [49].

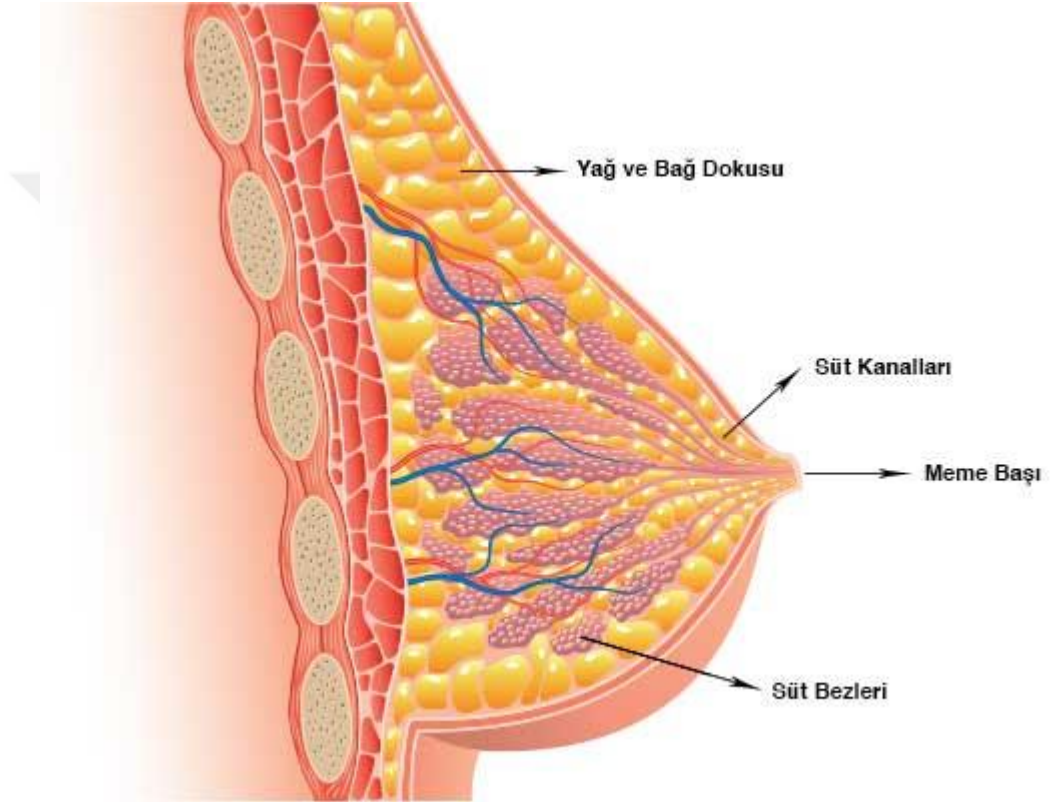
Jiao ve diğeri (2017), DDSM mamografi verisetinde geliştirdikleri ESA modeli önermişlerdir. Daha sonra, karar aşaması için iki doğrusal DVM sınıflandırıcısının eğitildiği, bu modelin farklı hiyerarşik seviyelerinden kitlelerin özelliklerini çıkarmışlardır. Sonunda, karar mekanizmasında, sınıflandırmayı tamamlamak için farklı sınıflandırıcılardan elde edilen sonuçlar birleştirilerek %96.7 doğruluk oranı elde etmişlerdir [50].

Rasti ve diğeri (2017), 112 meme DK-MRG özel veri setinde iyi huylu farklılaşma için karışım topluluğu bazlı bir ESA model önermişlerdir. Duyarlılık, özgüllük ve doğruluk değerlerini sırasıyla % 97.73, % 94.87 ve % 96.39 olarak elde etmişlerdir [51]. Yurttakal ve diğeri (2019), tez kapsamında yayınlanan çalışmalarında, 200 adet DK-MRG özel veri setinde iyi huylu-habis sınıflandırması için ESA model önermişlerdir. Sonuç olarak %98,33 doğruluk elde etmişlerdir [52].

### 3 MATERYAL VE METOD

#### 3.1.Meme Kanseri

Meme, st üretimini saęlayan lobl sistemi ile bunları meme başına aktaran duktus sisteminden oluřan tubuloalveolar bir bezdir [2]. Őekil 3.1’de örnek bir meme yapısı verilmiřtir.



**Őekil 3.1.** Meme yapısı [53]

Meme dokusu, lobller adı verilen st bezleri, duktuslar adı verilen st kanalları, yaę dokusu ve meme başından oluřmaktadır. Meme kanseri ise, st bezleri ve st kanallarını oluřturan hcreler arasında, çeřitli etkenler sonucu kontrolsz şekilde çoęalan ve bařka organlara yayılma potansiyeli tařıyan tmral oluřumdur.

Son yıllarda hızla artan meme kanseri oranı, meme kanseri riskini belirleyen faktrlerin deęiřtięi hipotezini desteklemektedir. Bařlıca risk faktrleri arasında, obezite, beslenme alıřkanlıkları, hormonal etkenler, genetik faktrler, sigara ve

alkol kullanımı gösterilmektedir. Meme kanseri için birçok risk faktörü, modern yaşam tarzımıza ayrılmaz bir şekilde bağlıdır ve açıkça bilinmeyen meme kanseri nedenleri de bulunmaktadır. Riski arttıran birçok neden kolayca değiştirilebilir olmamakla birlikte, riski azaltmak için bazı davranışlar benimsenebilir [54].

Meme kanseri kadınlarda en sık görülen kanseri türü olup, tüm dünyada meme kanseri sıklığı olarak her 8 kadından birinde meme kanseri görüldüğü bildirilmektedir. Ayrıca bunların %75'i 40 yaşın üzerindeki kadınlarda görülmektedir. Bu nedenle meme kanseri en büyük toplum sağlığı problemi olarak kalmaya devam etmektedir. Bunun yanında meme kanseri tedavisindeki gelişmeler oldukça yüz güldürücü olup temel sorun kanserin erken tanısıdır. Erken tanı için tüm dünyada belirlenmiş tarama ve tanı yöntemleri standardize edilmiştir. Ancak her şeye rağmen bu yöntemlerin her birinin kısıtlılıkları mevcuttur [55].

Teknolojinin de gelişmesi ile birlikte yeni tanı arayışlarında da hızlı bir artış olmuştur. Bunlardan biride bilgisayar destekli tanı yöntemleri olup, mevcut tanı için gerekli görüntüleme yöntemlerinin duyarlılık ve özgüllüğünü arttırmayı amaçlamaktadır.

### **3.1.1. Meme kanseri türleri**

Meme tümörü, iyi huylu ve habis olarak iki sınıfa ayrılmaktadır. Habis meme kanserlerinin, histopatolojik olarak birkaç farklı türü bulunmaktadır. Süt kanallarında gelişen kanserlere duktal kanser, süt bezlerinde gelişen kanserlere lobüler kanser adı verilmiştir.

Yayılma potansiyellerine göre ise 2'ye ayrılır. Kanser hücrelerine dönüşmeye başlamışsa in situ formda, yayılma özelliği varsa invaziv formdadır. Bunlardan başka inflamatuvar meme kanseri adı verilen agresif bir meme kanseri türü daha vardır. Genellikle meme enfeksiyonu şeklinde görüntü verir [56].

Patolojik bulgular bakımından başlıca iyi huylu meme lezyonları, kistik veya solid kitle (fibroadenom, filloid tümörler, adenozis) olarak gösterilmektedir [57].

### 3.1.2. Meme kanseri evreleri

Meme kanserinde evreleme, Amerika Kanseri Ortak Komitesi (AJCC) tarafından geliştirilmiştir [58]. Tıbbi onkologların iletişim sürecini kolaylaştırmak için özel olarak sunulan standart bir sınıflandırma işlemidir. TNM standardizasyonu, sırasıyla T (tümör çapı), N (lenf nodu) ve M (metastaz) kodlarından oluşmaktadır.

- T, büyüklüğü ve yapısı, onunla gelen değerle ifade edilen primer tümörü ayırt eder (X, 0, is, 1, 1mic, 1a, 1b, 1c, 2, 3, 4, 4a, 4b, 4c, 4d). TX veya T0, bir tümörün tanımlanabilir veya tespit edilemeyeceğini belirtir. IS, “In Situ” lezyonlarını gösterir ve tümörlerin yayılmasının ilk aşamasına eşittir. 2 cm boyuta kadar T1 tümörleri, 2-5 cm T2 tümörleri, 5 cm üstü T3 tümörleri ve herhangi bir boyutta olup etraf dokuya invaze olmuş meme tümörlerini tarif eder. T4d İnflamatuvar bir karsinomu göstermektedir [58].
- N, lenf bezlerinin meme kanserinden etkilenip etkilenmediğini ve ne ölçüde etkilendiğini göstermektedir. N'ye eşlik eden değerler (X, 0, 1, 2, 2a, 2b, 3, 3a, 3b, 3c) farklıdır. NX, lenf nodlarının değerlendirilmediğini; N0 lenf nodu metastazı olmadığını, N1 koltuk altında hareketli, N2 koltuk altında çok sayıda veya hareketsiz lenf nodu varlığını, N3 uzak lenf bezlerinde metastaz olduğunu göstermektedir [58].
- M, herhangi bir metastaz varlığına karşılık gelir. M0 uzak metastazların olmadığını, M1 uzak organlardaki metastazların bulunduğunu göstermektedir [58].

TNM standardizasyonu, yeni tanı konmuş meme kanseri olan hastalar için standart bir prognostik değerlendirme aracı olarak kullanılmaktadır [54]. Çizelge 3.1’de TNM kodlarıyla ilişkilendirilen meme kanseri evreleri gösterilmektedir.

**Çizelge 3.1.** Meme kanseri evreleri

Evre 0	Tis	N0	M0
Evre 1A	T1	N0	M0
Evre 1B	T0	N1mic	M0
	T1	N1mic	
Evre 2A	T0	N1	M0
	T1	N1	
	T2	N0	
Evre 2B	T2	N1	M0
	T3	N0	
Evre 3A	T0	N2	M0
	T1	N2	
	T2	N2	
	T3	N1	
	T3	N2	
Evre 3B	T4	N0	M0
	T4	N1	
	T4	N2	
Evre 3C	Herhangi bir T	N3	M0
Evre 4	Herhangi bir T	Herhangi bir N	M1

### 3.2.Biyomedikal Görüntüleme

Biyomedikal görüntüleme, canlıların organ, hücre veya moleküler (protein veya gen) seviyede iki boyutlu veya üç boyutlu olarak görüntülenmesidir. Hastaların Mamografi, Manyetik Rezonans Görüntüleme, Ultrason, Bilgisayarlı Tomografi, Radyografi (X-Ray), Pozitron Emisyon Tomografi, Tek Fotonlu Emisyon Bilgisayarlı Tomografi görüntüleri radyologlar tarafından tanı koymak amacıyla alınıp değerlendirilir. Bununla birlikte, her görüntüleme tekniğinin bir risk, fayda dengesinde değerlendirilmesi gerekir [59].

#### 3.2.1. Meme görüntüleme teknikleri

Meme hastalıkları ve meme kanserinde tanı yöntemleri olarak Mamografi , Ultrason, Manyetik Rezonans Görüntüleme ve meme kanseri evrelemesi için Pozitron Emisyon Tomografi tetkikleri kullanılmaktadır.

**Mamografi (MG):** Mamografi, meme görüntülerini oluşturmak için X ışınlarını kullanan, memenin özel bir radyografisidir ve en önemli görüntüleme aracıdır.

Mamografinin amacı, belirtilerden önce meme kanserinin erken teşhisi (tarama mamografisi) ve semptomları olan hastalarda tanı (tanı mamografisi) şeklindedir.

Mamografi, bir film ekranı, fosfor plakalı bilgisayar radyografisi veya dijital bir teknik kullanılarak yapılabilir. Düşük X-ışını dozu, daha yüksek görüntü kalitesi, işleme sonrası, dijital arşivleme, görüntü iletimi ve kimyasal kirlilik içermeyen bir dizi avantajı olan tam alanlı dijital mamografiye öncelik verilmelidir [60, 61].

Dijital mamografi, popülasyona dayalı meme kanseri taramasındaki film ekranlı mamografiden daha iyi tespit performansına sahiptir. Bu kazanç büyük ölçüde tümörlerde izlenen mikrokalsifikasyon gösteriminin artmasından kaynaklanmaktadır, bu da hem duktal karsinoma in situ (DCIS) hem de invaziv karsinomun gelişmiş tespitine imkan vermektedir [62]. Ayrıca dijital mamografideki radyasyon dozları, film ekranlı mamografideki sonuçlara göre görünüm başına % 22 daha düşüktür [63]. Buna karşılık, iyonlaştırıcı radyasyonlar uzun vadede kendileri tümörlerin nedenidir ve görüntü kalitesi diğer tanı yöntemleriyle karşılaştırıldığında daha düşüktür [64].

**Ultrasonografi (US):** İç organlar ve meme dokusu görüntüleri elde etmek için yüksek frekanslı ses dalgaları (1-10Mhz) kullanılmaktadır. X ışınları kullanılmaz. Düşük frekanslar (1-3Mhz) derinlerdeki yapıları incelerken, daha yüksek frekanslar (5-10 Mhz), görüntüyü daha fazla çözme gücüne sahiptir, ancak nesneye daha az derinlemesine nüfuz ederek yüzeysel bölgelerin izlenmesinde kullanılmaktadır. Düşük maliyet, cihazın taşınabilirliği, yöntemin uygulama kolaylığı, incelemenin bilinen bir riskinin bulunmaması en büyük avantajlarından [59].

Genellikle mamografi ve klinik muayene gibi diğer görüntüleme yöntemlerini tamamlamak veya şüpheli olan lezyonların daha ileri teşhisini yapmak için kullanılmaktadır. Buna karşılık, ultrasonografi normal doku dağılımı olan göğüsler için düşük bir çözme gücüne sahiptir ve operatöre bağlı bir işlemdir [65].

**Manyetik rezonans görüntüleme (MRG):** MR tarayıcıları, canlı doku görüntüsünü oluştururken, biyolojik olarak zararlı kabul edilen iyonlaştırıcı radyasyon yerine yüksek manyetik alanlar ve radyo frekansında sinyaller kullanılmaktadır. Görüntü

dokudaki hidrojen atomlarının yoğunluklarına ve hareketlerine bağı olarak görüntü işleme teknikleriyle oluşturulmaktadır [59].

Mamografi ve ultrasonografiden farklı olarak, MRG özellikle yumuşak dokuları görüntülemeye kullanılmaktadır. Ayrıca kitlenin meme dokusu üzerindeki perfüzyon özelliklerini ve morfolojik özellikleri göstermektedir [56]. Amerika Kanser Derneği, meme kanseri açısından yüksek risk (%20 ve daha fazla) içeren kadınları için MRG taraması yapmalarını önermektedir [54].

### 3.2.2. Dinamik kontrastlı manyetik rezonans görüntüleme

İnsan vücudu, yüksek oranda hidrojen atomları bulunmaktadır. Hidrojen atomu çekirdeği tek proton içerir ve güçlü bir manyetik alana sahiptir. Atom çekirdeğinin temel yapıları olan protonlar ve nötronlar kendi eksenini etrafında spin hareketi yapmaktadır. İnsan vücudu güçlü bir manyetik alan içine yerleştirildiğinde, rastgele yönlerde dönüş yapan protonlar mıknatıs vektörü doğrultusunda paralel dizilim göstererek presesyon hareketi yaparlar. Protonlar presesyon hareketi yaparken, radyo frekansı sinyalleri ile uyarılırsa, manyetik alan vektörü ile Eşitlik 3.1’de verilen bir açı yaparak buldukları konumdan saparlar.

$$\phi = \varphi * f * \Delta t \quad (3.1)$$

Eşitlikte,  $\phi$  dönme açısını,  $f$  radyo frekans sinyalinin şiddetini,  $\Delta t$  radyo frekans sinyalinin uygulanma süresini ifade etmektedir. Radyo dalgaları kesildiğinde protonlar başlangıç konumlarına dönerler. Bu aşamada yaptıkları titreşim sonucu yaydıkları sinyaller ölçülerek MR görüntüleri oluşturulur. Protonlar başlangıç konumlarına gelmeden önce daima farklı fazda hareket ederek sinyali sönümlerler. Protonların eski konumlarına gelme sürelerine T1, farklı fazda hareket etme sürelerine T2 süreleri adı verilmektedir. Doku ve lezyonların proton yoğunluğu, T1 süresi ve T2 süresi farklıdır. Görüntü oluştururken 3 parametre de kullanılmaktadır. T1 ağırlıklı görüntülerde sıvı yapılar koyudur. T2 ağırlıklı görüntülerde ise sıvı yapılar parlaktır [66].

MR görüntüleme işlemine başlamadan önce, hastaya gadolinyum (*Gd-DTPA*) içeren kontrast tutucu maddeler verilerek, maddenin perfüzyonu, dokuda tutuluşu ve vücuttan atılışı kaydedilir. Bu sayede iyi huylu ve habis tümör yapılarının diğer yapılardan ayırt edilebilmesi sağlanmaktadır [67].

### 3.3.Derin Öğrenme


Son yıllarda yapay zekâ üzerine yapılan çalışmalar giderek artmaktadır. Günümüzde insanlar, işgücünü otomatikleştirmek, konuşma veya görüntüleri anlamak, tıpta tanı koymak gibi işlemler için akıllı yazılımlar aramaktadır. Bu amaçla yapay zekâ yöntemleri kullanarak insanın problem çözme becerisini taklit etmeye programlanmış bir bilgisayar sistemi olan bilgi tabanlı sistemler geliştirilmiştir [68].

Zamanla sabit kodlanmış bilgiye dayanan sistemlerin karşılaştığı zorluklar, yapay zekâ sistemlerinin, ham verilerden kendi bilgilerini edinmeye ihtiyaç duyduklarını göstermiştir. Bu nedenle makine öğrenmesi algoritmaları geliştirilmiştir. Makine öğrenmesi bilgisayarların gerçek dünya ile ilgili problemleri çözebilmelerini sağlamıştır. Makine öğrenmesi algoritmalarının performansı büyük ölçüde problemin temsil edilmesine bağlıdır. Örneğin bir hastalığa ait karar destek sisteminde, geliştirilen yazılım hastayı doğrudan incelemeyebilir. Bunun yerine hastalığa dair özellikler çıkarılır ve sisteme verilir. Burada problem uzayını temsil eden her değere öznitelik adı verilir. Ancak, birçok problem için hangi özelliklerin çıkarılması gerektiğini bilmek zordur. Bazı özellikleri el ile tasarlamak gerekebilir. Bu da çok fazla zaman ve emek gerektirmektedir [69].

Derin öğrenme ise, giriş uzayı ile çıkış uzayı arasındaki ilişkileri eşleştirmek için çok katmanlı bir mimarinin kullanıldığı makine öğrenim dalıdır [70]. Derin denilir çünkü birden fazla lineer olmayan özellik dönüşümüne sahiptir. En büyük avantajlarından birisi, insan yapımı özelliklere bağlı kalmadan giriş uzayı ile çıkış uzayı arasında haritalanan pek çok karmaşık fonksiyonu otomatik öğrenmesidir. Ayrıca büyük miktarda verilerde yüksek performans göstermektedir [71].




Şekil 3.2’de derin öğrenmenin diğer yapay zekâ türleriyle olan ilişkisini gösteren venn diyagramı verilmiştir.



**Şekil 3.2.** Yapay zekâ türleri arasındaki ilişki


Derin öğrenme içerisinde kullanılan başlıca yöntemler şunlardır:

**Çok katmanlı perseptron (MLP):** İleri beslemeli yayılım ile bir veya daha fazla gizli katmana ve çıkışa sahip sinir ağıdır. Bir sinir ağı iki veya daha fazla gizli katman içeriyorsa derin sinir ağı (DNN) olarak adlandırılır [72]. Şekil 3.3’de örnek bir çok katmanlı perseptron yapısı verilmiştir.




**Şekil 3.3.** Çok katmanlı perseptron

**Boltzmann makinesi (BM):** İyi tanımlanmış enerji fonksiyonuna sahip stokastik bir simetrik ağıdır. Sınırsız bağlanabilirliği vardır [73]. Şekil 3.4’de örnek bir boltzmann makinesinin yapısı verilmiştir.




**Şekil 3.4.** Boltzmann makinesi

**Kısıtlı boltzmann makinesi (RBM):** Derin inanç ağlarının temelini oluşturur. Görünür ve gizli katman olmak üzere iki katman arasındaki simetrik bağlantılardan oluşur. Ancak aynı katmanın iki düğümü birbirine bağlı değildir. Bu bakımdan Boltzmann makinelerinden farklıdır [74]. Şekil 3.5’de örnek bir kısıtlı boltzmann makinesinin yapısı verilmiştir.



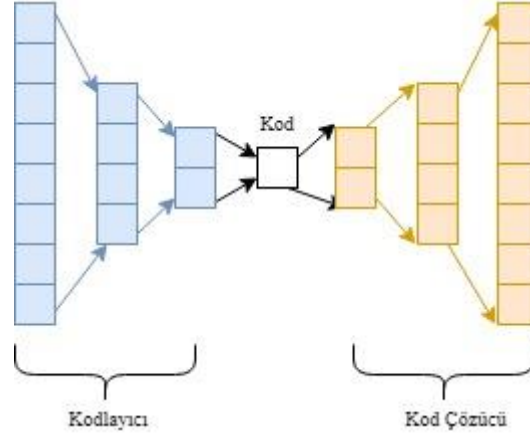
**Şekil 3.5.** Kısıtlı boltzmann makinesi

**Derin inanç ağı (DBN):** Üst katmanların aralarında simetrik bağlantılara sahip olduğu, üretken bir model olup, alt katmanlar işlenen bilgiyi üstlerindeki katmanlardan yönlendirilmiş bağlantılardan alır [75]. Her bir alt ağı gizli katmanı sonraki katmanın görünür katmanıdır. Şekil 3.6’da örnek bir derin inanç ağının yapısı verilmiştir.




**Şekil 3.6.** Derin inanç ağı

**Oto-kodlayıcılar:** Çıkış şeklinin girdiyle aynı olduğu ve ağın temel temsilleri daha iyi öğrenmesini sağlayan denetimsiz öğrenme algoritmaları sınıfıdır [27]. Şekil 3.7’de örnek bir oto-kodlayıcı yapısı verilmiştir.



**Şekil 3.7.** Oto-kodlayıcılar

**Tekrarlayıcı sinir ağı (RNN):** Sıralama sırasını ve mimarilerin içindeki iç döngüleri hesaba katar, yani ağı herhangi bir durumu yalnızca mevcut girdiden değil, geçmiş geçmişinden etkilenir [76]. Şekil 3.8’de örnek bir tekrarlayıcı sinir ağının yapısı verilmiştir.




**Şekil 3.8.** Tekrarlayıcı sinir ağı

Bu derin öğrenme yöntemlerinin her birinin kendine özgü avantaj ve dezavantajları vardır. Problemin karmaşıklığına bağlı olarak kullanılan yöntem değişebilir.

### 3.4.Evrişimsel Sinir Ağı

Evrişimsel katmanlar, iki boyutlu bir aktivasyon haritası oluşturmak için belirlenen bir filtreyi gelen sinyal boyunca kaydırarak giriş görüntüsüne veya sese uygular. Evrişimsel sinir ağları, girişte gizlenmiş özelliklerin geliştirilmesine izin verir [72]. ESA’nın görüntü tanıma ve sınıflandırma gibi alanlarda başarılı sonuçlar verdiği kanıtlanmıştır [77].

Kırmızı, yeşil, mavi (RGB) olmak üzere 3 renkli kanala sahip, 24 piksel genişliğinde ve yüksekliğinde bir görüntüyü girdi olarak girilirse ve ilk katmandaki nöronları sonraki katmana bağlarsak çok katmanlı sinir ağı modeline göre  $24 \times 24 \times 3 = 1728$  ağırlık olması gerekmektedir. Bu da çok fazla veriye ve işlem gücüne gereksinim duymaktadır. Görüntünün boyutu  $300 \times 300$ 'e yükseltirse işlem karmaşıklığı polinomal olarak büyümektedir. ESA, bu problemin üstesinden gelmesi için tasarlanmıştır. Normal sinir ağlarından farklı olarak, ESA'lar girdi verilerini genişlik, yükseklik ve derinliği temsil eden üç boyutlu bir tensör benzeri yapıda düzenler. Bir parametre patlamasını önlemek için, bir katmandaki her hacim sadece bir sonraki katmanın hacmindeki uzamsal olarak ilgili bir bölgeye bağlanmaktadır. Son olarak, çıktı katmanı yüksek boyutlu girdi görüntüsünü çıktı sınıflarının tek bir vektörüne indirgemektedir [71]. Şekil 3.9'da örnek bir ESA verilmiştir.




**Şekil 3.9.** Evrişimsel sinir ağı

Bu bölümde, ESA'da sıklıkla kullanılan veri önışleme, veri artırma, ağı katmanları gibi çeşitli bileşenler ve rolleri açıklanmaktadır. Çünkü bunlar ağı mimarilerinde sıkça kullanılmaktadır.

### 3.4.1. Veri önışleme

Veri önışleme, daha sağlıklı sonuçların elde edilebilmesi veya verinin kullanılan algoritmalarla uyumlu olabilmesi için verinin tanımlanan bir fonksiyona uygun olarak dönüştürülmesi işlemidir. Derin öğrenme uygulamaları önışlemeden geçirildikten sonra daha iyi çalıştıkları gözlenmiştir [71]. Başlıca önışleme yöntemleri şunlardır:

**Normalizasyon / Standardizasyon:** Normalleştirme, veri boyutlarının yaklaşık olarak aynı ölçekte olması için yapılan işlemleri ifade eder. Yaygın olarak kullanılan yöntemlerden birisi, her boyutu sıfır merkezli olduktan sonra standart sapmasına bölmektir. Buna sıfır merkezli normalizasyon denilmektedir. Diğer bir yöntem, veri dizisinde bulunan değerleri  $[-1, +1]$  veya  $[0, +1]$  aralığında yer alacak şekilde dönüştürmektir. Bazı kaynaklarda yeniden ölçeklendirme adı da verilmektedir. Fakat görüntülerde, piksellerin göreceli ölçükleri zaten genelde yaklaşık olarak eşit olduğu için  $[0-255]$  bu ek ön işleme adımını kullanmak gerekemeyebilir [78]. Şekil 3.10'da normalizasyon türleri gösterilmiştir.




**Şekil 3.10.** Normalizasyon türleri (a) orijinal veri, (b) sıfır merkezli normalizasyon, (c) yeniden ölçeklendirme [79]

**Ortalama çıkarma:** Tüm veri kümesinde ortalama bir görüntü hesaplamakta ve bu ortalama görüntüyü her görüntüden çıkartmaktadır. Verilerin özellik boyutlarının orijin boyunca merkezlenmesi etkisine, görüntülerde ise ortalama parlaklığı kaldırma özelliğine sahiptir [71].

**Temel bileşen analizi ve beyazlatma:** Kovaryans matrisinin hesaplanması ve verilerin boyutluluğunu arzu edildiği gibi en yüksek ana bileşenlere indirgemek için kullanılmasıyla verilerin ilişkisiz hale getirildiği süreçtir [71].

Özdeğerdeki verileri alır ve ölçeği normalleştirmek için her boyutu özdeğere böler. Bu dönüşümün geometrik yorumu, eğer girdi verileri çok değişkenli bir Gaussian ise, beyazlanmış verinin sıfır ortalama ve özdeş kovaryans matrisine sahip bir Gauss

olacađıdır [79]. Őekil 3.11’de temel bileŐen analizi ve beyazlatma iŐlemi gsterilmiŐtir.



**Őekil 3.11.** Temel bileŐen analizi ve beyazlatma (a) orijinal veri, (b) temel bileŐen analizi (c) beyazlatma [79]

### 3.4.2. Veri artırma

Derin đrenmenin temel bir zelliđi kendi eđitim verilerinden ilgin zellikler bulabilmesidir ve bu ancak ok sayıda eđitim rneđi olduđunda elde edilmektedir. Onlarca rnek ile karmaŐık bir problemi zmek iin bir evriŐim ađını eđitmek mmkn deđildir. Fakat model dzenliyse ve grev yalın ise, birkaç yz rnek yeterli olabilmektedir. Hatta zellik mhendisliđine gerek kalmadan, veri eksikliđi olmasına rađmen daha makul sonular alınabilmektedir [80].

BaŐlıca veri artırma yntemleri Őunlardır [81]:


- teleme
- Dndrme
- Yansıtma
- lekleme
- Renk kanallarını deđiŐtirme
- Kırpma

Veri artırma iŐlemi, evrimii ve evrimdiŐi olarak iki farklı Őekilde uygulanabilmektedir. evrimdiŐi veri artırmada gerekli tm dnŐmler nceden

gerçekleştirilmektedir. Daha küçük veri kümeleri için tercih edilir. Veri kümesinin boyutu gerçekleştirilen dönüşüm sayısına eşit bir faktörle artmaktadır. Anında büyütme olarak bilinen çevrimiçi veri artırmada ise, oluşturulan öğrenme modeline beslemeden hemen önce mini bir yığın üzerinde gerçekleştirilmektedir. Daha büyük veri setleri için tercih edilir, çünkü boyuttaki aşırı artış hatalar verebilmektedir. Bazı platformlar, GPU'da hızlandırılabilen çevrimiçi büyütme destek vermektedir [82].

### 3.4.3. Ağ katmanları

Tipik bir ESA mimarisi her biri bir girdi tensörünü bir çıktı tensörüne dönüştüren bir dizi katmandan oluşur. Örnek bir ESA mimarisi, evrişim katmanı, havuzlama katmanı, aktivasyon katmanı ve tamamen bağlı katmanlardan oluşmaktadır. Şekil 3.12'de örnek katmanlar gösterilmiştir.



Şekil 3.12. Örnek ağ katmanları

#### 3.4.3.1. Evrişim katmanı (Convolution Layer)

Bir evrişim katmanı, genellikle özellik haritaları olarak adlandırılan bir çıktı üretmek için girdi üzerinde çalışan evrişimsel filtrelerden oluşur. Evrişim katmanları girdi olarak çeşitli özellik haritalarını alır ve çıktı olarak özellik haritaları üretir. Burada  $k$ , evrişim katmanındaki filtre sayısıdır. Filtrelerin sayısı  $k$  ile filtrenin boyutu,  $w*h$  evrişimli katmanların hiper parametreleridir ve  $k@w*h$  şeklinde gösterilmektedir. Matematiksel olarak evrişim, Eşitlik 3.2'de tanımlanmaktadır [69]. Burada  $I$  giriş verisi,  $K$  kernel,  $O$  özellik haritasıdır.

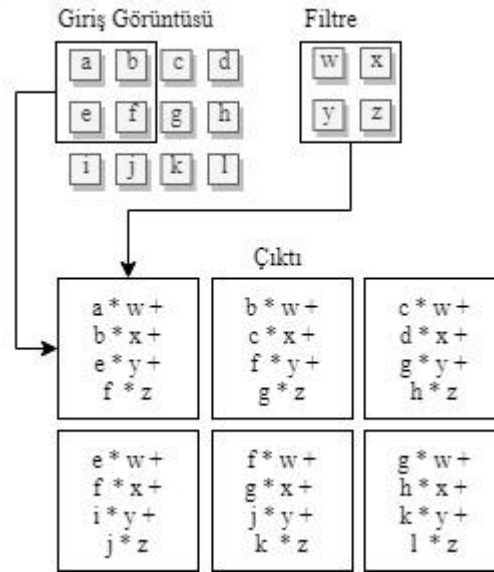


$$S(t) = (I * K)(t) = \sum_{a=-\infty}^{\infty} I(a)K(t-a) \quad (3.2)$$

Filtrenin giriş görüntüsüne uygulanmasında çapraz korelasyon fonksiyonu uygulanmaktadır. Giriş görüntüsü  $I$ 'ya,  $K$  filtresinin uygulanması gösteren çapraz korelasyon fonksiyonu Eşitlik 3.3'de verilmiştir [69].

$$O(i, j) = I * K(i, j) = \sum_{x,y} I(x, y)K(i-x, j-y) \quad (3.3)$$

Bu işlemler uygulanırken çıktı görüntüsünün boyutunda değişim meydana gelir.  $I$  giriş görüntüsünün boyutu  $m*m$ ,  $K$  filtresinin boyutunu  $n*n$  olduğu düşünülürse,  $O$  çıktı görüntüsünün boyutları  $(m-n+1)*(m-n+1)$  boyutlu olur. Şekil 3.13'de giriş görüntüsüne filtrenin uygulanışı gösterilmiştir. Renkli görüntüler, kırmızı-yeşil-mavi olmak üzere 3 kanaldan oluşmaktadır. Bu nedenle aynı işlem 3 kanal için de yapılmaktadır [69].



**Şekil 3.13.** Evrişim katmanında filtrenin uygulanışı

Evrişim katmanının bir diğer önemli hiper parametreleri, piksel ekleme (*padding*) ve kaydırma adımı (*stride*) parametreleridir. Giriş görüntüsü ile çıkış görüntüsü arasındaki boyut farkı, piksel ekleme metoduyla yönetilmektedir. Eklenen pikseller 0 değerinden oluşabilir veya yanındaki piksel değeri kopyalanabilir. Giriş

görüntüsünün boyutu  $m*m$ ,  $K$  filtresinin boyutu  $n*n$ , piksel ekleme değerinin  $p$  olduğu düşünülürse,  $O$  çıktı görüntüsünün boyutlarının giriş görüntüsüyle aynı olması isteniyorsa  $(m+2p-n+1)$  formülü uygulanmaktadır. Piksel ekleme değeri,  $(n-1)/2$  formülüyle bulunmaktadır [83].

Kaydırma adımı, filtrenin giriş görüntüsü üzerinde kaydırılacağı piksel sayısını ifade etmektedir. Bu yüzden çıkış boyutunu direkt etkileyen bir parametredir. Giriş görüntüsünün boyutu  $m*m$ ,  $K$  filtresinin boyunu  $n*n$ , piksel ekleme değerinin  $p$ , kaydırma adımının  $s$  olduğu düşünülürse,  $O$  çıktı görüntüsünün boyutlarını veren formül Eşitlik 3.4'de verilmiştir [83].

$$O = \frac{m-n+2p}{s} + 1 \quad (3.4)$$

Küçük boyutlu filtreler, görüntüye genel bakış olmadan elde edilen yerel özellikler elde eder. Görüntüdeki daha küçük ve karmaşık özellikleri yakalar. Çıkarılan bilgi miktarı geniştir. Daha sonraki katmanlarda yararlı olabilir. Görüntü boyutundaki yavaş azalma, ağı derinleştirir.  $1*1$  filtre kullanmak, her pikseli kullanışlı bir özellik olarak ele almak demektir. Diğer taraftan büyük filtreler, görüntüdeki genel özellikleri elde eder. Temel bileşenleri yakalar. Çıkarılan bilgi miktarı azdır. Görüntü boyutundaki hızlı azalma, ağı sığlaştırır. Görüntü boyutlu filtre kullanmak tamamen bağlı katmanla eşdeğerdir [84].

### 3.4.3.2. Küme normalizasyonu (Batch Normalization)

Derin öğrenme ağını eğitirken ortaya çıkan sorunlardan birisi, iç değişken kayması (*internal covariate shift*) olarak karşımıza çıkmaktadır. Çıktıya yakın katman parametreleri, alt katmanlar tarafından üretilen bazı girdilere uyarlanırken, bu düşük katmanlar parametreleri de uyarlanır. Bu da üst katmanlardaki parametrelerin daha kötü olmasına yol açar. Küme normalizasyon işlemi, tüm düğüm değerlerini sıfır ortalama ve birim varyans ile standart normal dağılıma sahip olacak şekilde kısıtlayarak iç değişken kaymasını azaltmaktadır [85].

Katman ilk önce mini küme ortalamasını çıkartarak ve mini küme varyansına bölerek her kanalın aktivasyonunu normalleştirmektedir. Daha sonra, katman, girişi öğrenilebilir bir ofset ile kaydırmaktadır ve öğrenilebilir bir ölçek faktörü ile ölçeklendirmektedir. Ölçekleme ve kaydırma parametreleri ağı eğitimi sırasında güncellenmektedir [85].

Küme  $B = \{x_1, x_2, \dots, x_n\}$  olduğunu varsayarsak, küme ortalaması Eşitlik 3.5'de verilmiştir.

$$\mu_\beta = \frac{1}{n} \sum_{k=1}^n x_k \quad (3.5)$$

Varyans, standart sapmanın karesi olarak ifade edilmektedir ve her bir küme elemanının ortalamadan farklılık gösterdiği ortalama dereceyi ölçmektedir. Kümenin varyansı Eşitlik 3.6'da verilmiştir.

$$\sigma^2_\beta = \frac{1}{n} \sum_{k=1}^n (x_k - \mu_\beta)^2 \quad (3.6)$$

Normalizasyon işlemi Eşitlik 3.7'de verilmiştir. Burada  $1 \leq i \leq n$  ve  $\varepsilon > 0$  olarak kabul edilmektedir. Epsilon özelliği çok küçük olduğunda sayısal dengeyi iyileştirmektedir.

$$\hat{x} = \frac{x_i - \mu_\beta}{\sqrt{\sigma^2_\beta + \varepsilon}} \quad (3.7)$$

Ölçekleme ve kaydırma işlemi sonucunda oluşan  $Y$  çıktısının formülü Eşitlik 3.8'de verilmiştir. Burada ofset kaydırma parametresi  $\beta$  ile kaydırır ve ölçeklendirme parametresi  $\gamma$  ile ölçeklendirir.

$$Y = \gamma * \hat{x} + \beta \quad (3.8)$$

ESA'ların eğitimini hızlandırmak ve ağ başlatma işlemine duyarlılığı azaltmak için, evrişim tabakaları ile ReLU tabakaları gibi doğrusal olmayanlar katmanlar arasında kullanılmaktadır [86].

### 3.4.3.3. Aktivasyon katmanı (Activation Layer)

Evrişim doğrusal bir işlemdir, dolayısıyla evrişim katmanları yalnızca doğrusal bağımlılığı modelleyebilir. Doğrusal fonksiyonlar,  $f(x)=x$  olarak tanımlanan tek dereceli polinomlardır. Dolayısıyla sınırlı öğrenme gücüne sahiptir. Doğrusal olmayan aktivasyon fonksiyonlarının temel amacı ise, sinir ağlarında doğrusal olmayan özellikleri tanıtmaktır [70].

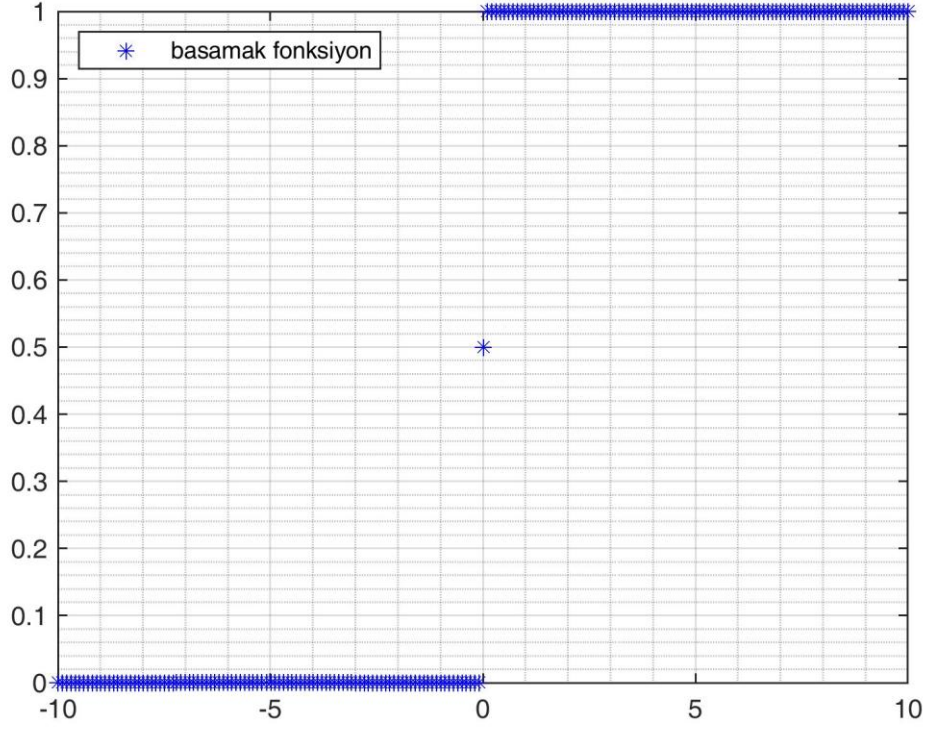
Aktivasyon katmanları çıkış veya bir başka katmanın girişi olabilmektedir. Aktivasyon fonksiyonunun bir diğer önemli özelliği de farklılaştırılabilmesidir. Ağ, çıkış katmanında hesaplanan hataları öğrenmektedir. Ağırlıklar ile ilgili hata derecelerini hesaplamak için ağda geriye doğru ilerlerken geri yayılım optimizasyonunu gerçekleştirmek için farklılaştırılabilir bir aktivasyon fonksiyonu gerekir ve ardından hatayı azaltmak için gradyan inişi veya başka bir optimizasyon tekniği kullanarak ağırlıkları uygun şekilde optimize eder [71].

Bir problem için en uygun fonksiyon, tasarımcının denemeleri sonucunda belirleyebileceği bir durumdur. En uygun fonksiyon, modele ve probleme göre karar vermeyi gerektiren bir optimizasyon problemidir [87]. Başlıca aktivasyon fonksiyonları şunlardır:

**Basamak Fonksiyonu:** Gelen girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre ikili değer (0 veya 1) alan bir fonksiyondur. Bu nedenle ikili sınıflayıcı olarak kullanılmaktadır [87]. Eşitlik 3.9'da verilmiştir.

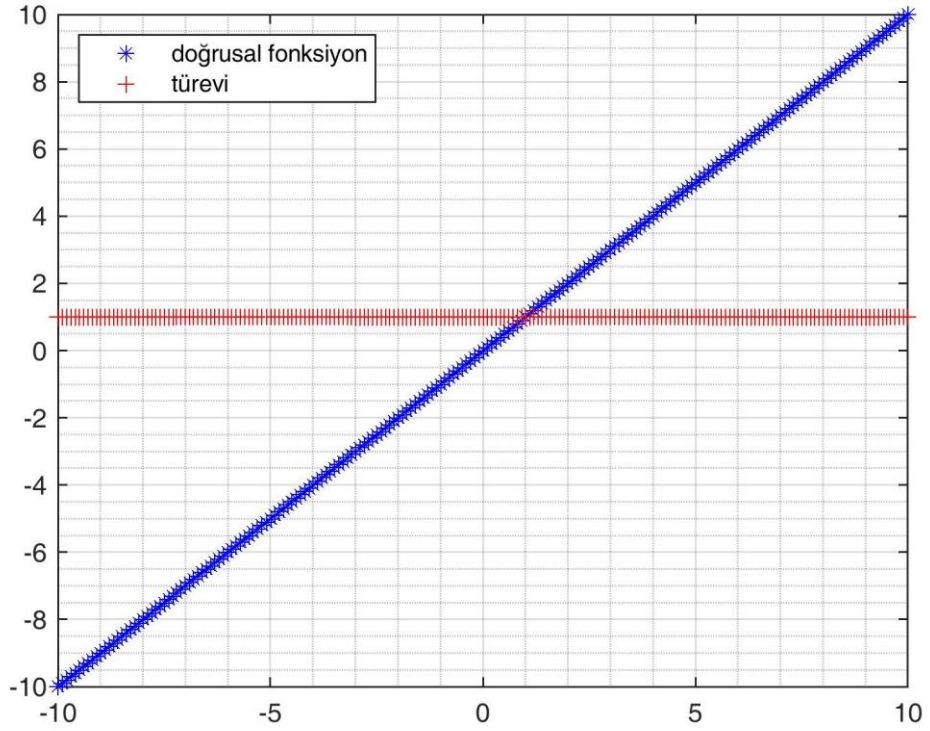
$$f(x) = \begin{cases} 0 & \rightarrow x < 0 \\ 1 & \rightarrow x \geq 0 \end{cases} \quad (3.9)$$

Türevi herhangi bir öğrenme durumunu temsil etmemektedir. Şekil 3.14’de basamak fonksiyonun grafiği verilmiştir.



Şekil 3.14. Basamak fonksiyon

**Doğrusal Fonksiyon:** Gelen girdi değerleri olduğu gibi hücrenin çıktısı olarak kabul edilmektedir. Örnek bir doğrusal fonksiyon  $f(x)=c*x$ , türevi alındığında x’e bağlı olmayan sabit bir değer göstermektedir. Tahminde bir hata varsa, geri yayılım tarafından yapılan değişiklikler sabittir. Dolayısıyla öğrenme durumu gerçekleşmemektedir. Ara katmanların işlevsiz kalmasına neden olmaktadır [88]. Şekil 3.15’de doğrusal fonksiyonun grafiği verilmiştir.




Şekil 3.15. Doğrusal fonksiyon

**Sigmoid Fonksiyon:** Sürekli ve türevi alınabilir bir aktivasyon fonksiyonudur. Girdi değerleri,  $[-\infty, +\infty]$  arasındaki değerleri için  $(0, 1)$  arasında bir değer üretir [89]. Sigmoid fonksiyon Eşitlik 3.10'da verilmiştir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.10)$$

Dezavantajı,  $x$  değeri çok yüksek veya çok düşük olduğu durumlarda türev değerleri 0'a yakınsamaktadır. Bu probleme gradyanların kaybolması (*vanishing gradient*) denilmektedir. Bu problem, öğrenme olayının minimuma inmesine, hatayı minimize edecek optimizasyon algoritmasının lokal minimumlara takılmasına neden olabilmektedir [90]. Şekil 3.16'da sigmoid fonksiyonun grafiği verilmiştir.

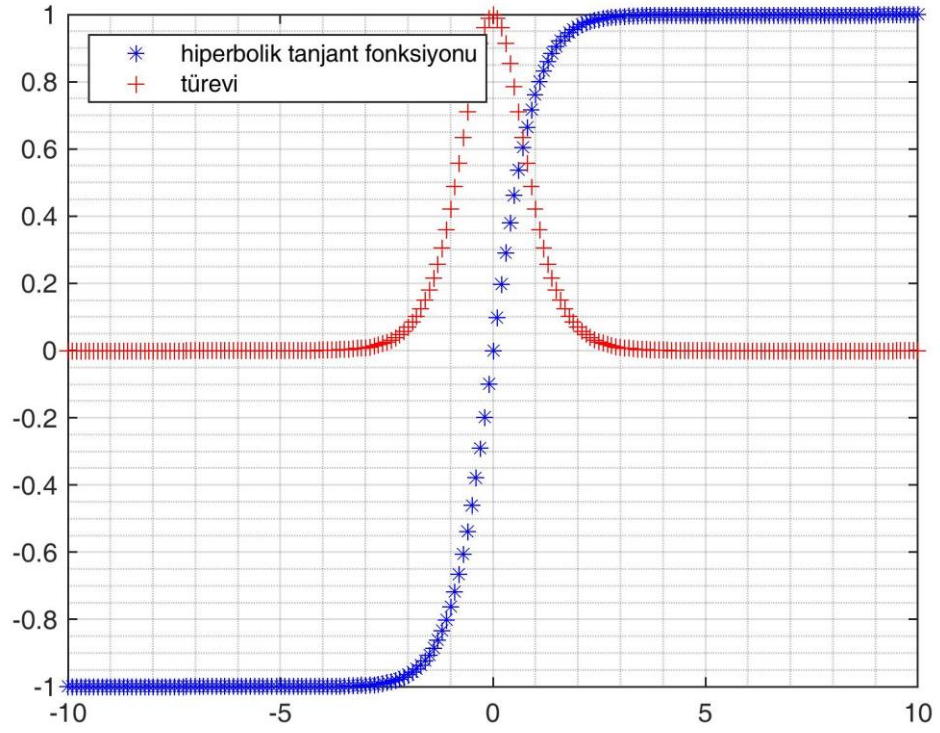


Şekil 3.16. Sigmoid fonksiyon

**Hiperbolik Tanjant Fonksiyonu:** Sigmoid fonksiyonuna benzer yapıdadır. Hiperbolik tanjant fonksiyonunun çıkış değerleri  $-1$  ile  $+1$  arasında değişmektedir [87]. Hiperbolik tanjant fonksiyon, Eşitlik 3.11’de verilmiştir.

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (3.11)$$

Sigmoid fonksiyonuna göre avantajı, türevinin daha çok değer almasıdır. Fakat, gradyanların kaybolması problemi devam etmektedir [90]. Şekil 3.17’de hiperbolik tanjant fonksiyonun grafiği verilmiştir.

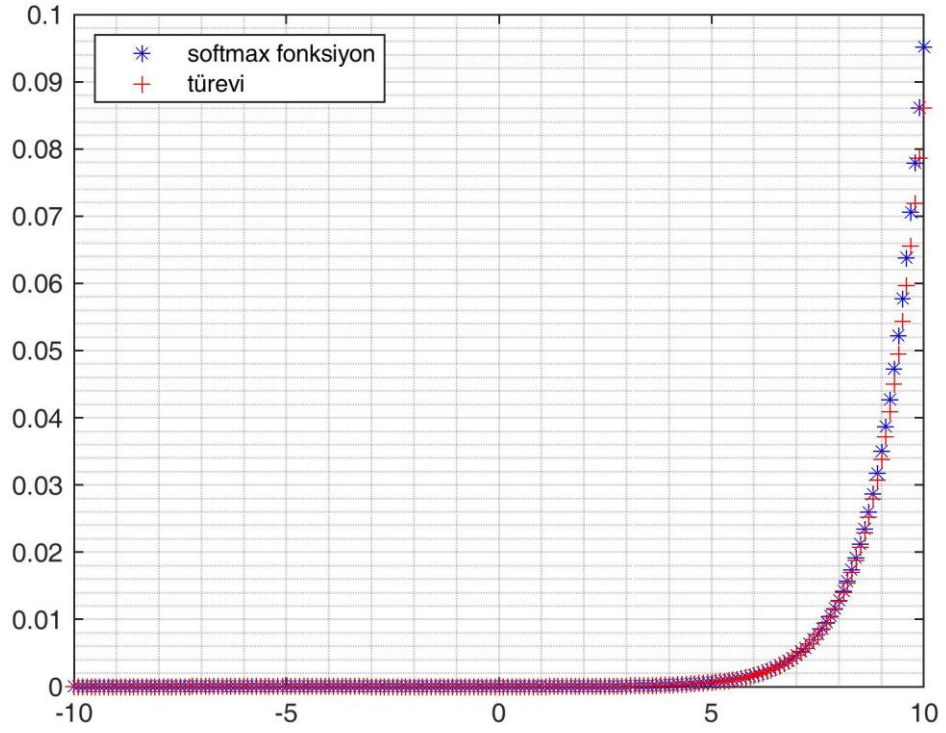


Şekil 3.17. Hiperbolik tanjant fonksiyon

**Softmax Fonksiyon:** Softmax fonksiyonun genelde çoklu sınıflandırma problemlerinde, özellikle derin öğrenme ağlarında çıkış katmanında kullanılmaktadır. Sigmoid fonksiyon ise ikili sınıflandırma problemlerinde tercih edilmektedir [91]. Eşitlik 3.12’de softmax fonksiyon verilmiştir. Şekil 3.18’de softmax fonksiyonun grafiği verilmiştir. Burada  $x = (x_1, x_2, \dots, x_n)$  çıkış vektörüdür.

$$f(x) = \frac{e^{x_a}}{\sum_{a=1}^n e^{x_a}} \quad (3.12)$$



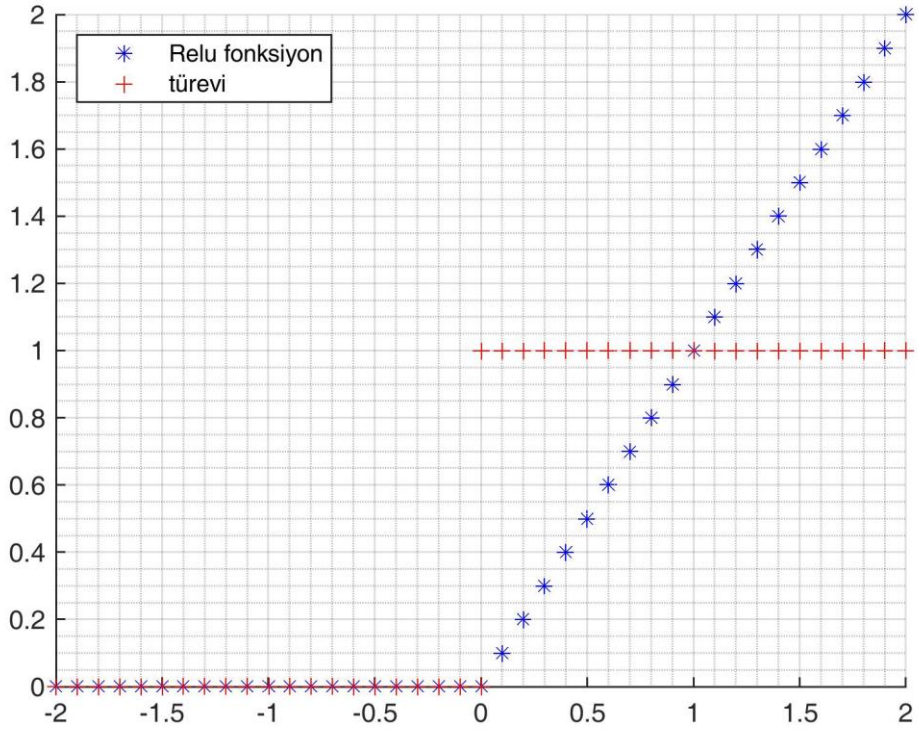


Şekil 3.18. Softmax fonksiyon

**Doğrultulmuş Lineer Birim (Relu) Fonksiyonu:** Çıkış değerleri  $[0, +\infty]$  arasında değişmektedir [92]. Eşitlik 3.13’de verilmiştir.

$$f(x) = \begin{cases} 0 \rightarrow x < 0 \\ x \rightarrow x \geq 0 \end{cases} \quad (3.13)$$

Sigmoid fonksiyon ve hiperbolik tanjant fonksiyon tüm nöronların aktif olmasına neden olmaktadır. Fakat doğrultulmuş lineer birim fonksiyonu  $[0, +\infty]$  arasında değer alması nedeniyle bazı nöronların aktif olmasını sağlamaktadır. Bu da ağıın daha hızlı çalışmasını sağlamaktadır. Diğer bir avantajı, gradyanların kaybolması problemini hafifleten pozitif argümanların sınırsız olmasıdır. Dezavantajı sıfır değer bölgesinin türevinin sıfır olması, yani sıfır bölgesinde öğrenmenin gerçekleşmemesidir [90]. Şekil 3.19’da doğrultulmuş lineer birim fonksiyonun grafiği verilmiştir.

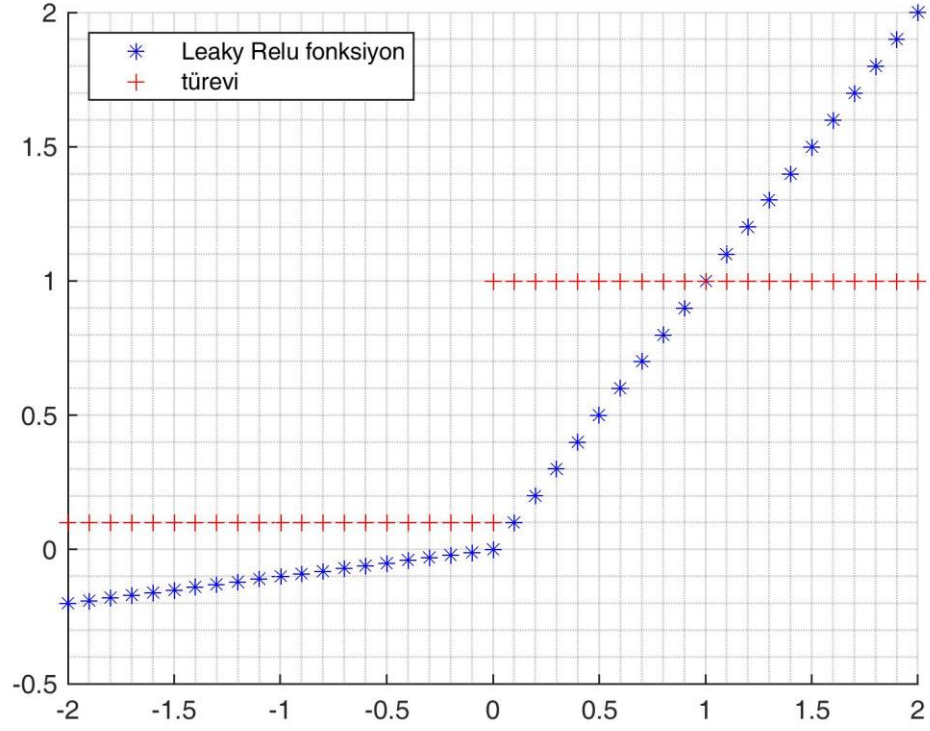


Şekil 3.19. Relu fonksiyon

**Parametrik Doğrultulmuş Lineer Birim (PReLU) Fonksiyonu:** Doğrultulmuş lineer birim fonksiyonunun sıfır değer bölgesinde türevinin sıfır olması sorununu çözmek için geliştirilmiştir. Parametrik doğrultulmuş lineer birim fonksiyon Eşitlik 3.14’de verilmiştir.

$$f(x) = \begin{cases} 0,01 \rightarrow x < 0 \\ x \rightarrow x \geq 0 \end{cases} \quad (3.14)$$

Sızdıran doğrultulmuş lineer birim (*Leaky Relu*) adı da verilmektedir [93]. Parametrik değer 0,01 belirlenmiştir. Eğer parametre değeri 0.01’den farklıysa, Randomize doğrultulmuş lineer birim fonksiyon olarak adlandırılmaktadır [94]. Şekil 3.20’de parametrik doğrultulmuş lineer birim fonksiyonun grafiği verilmiştir.

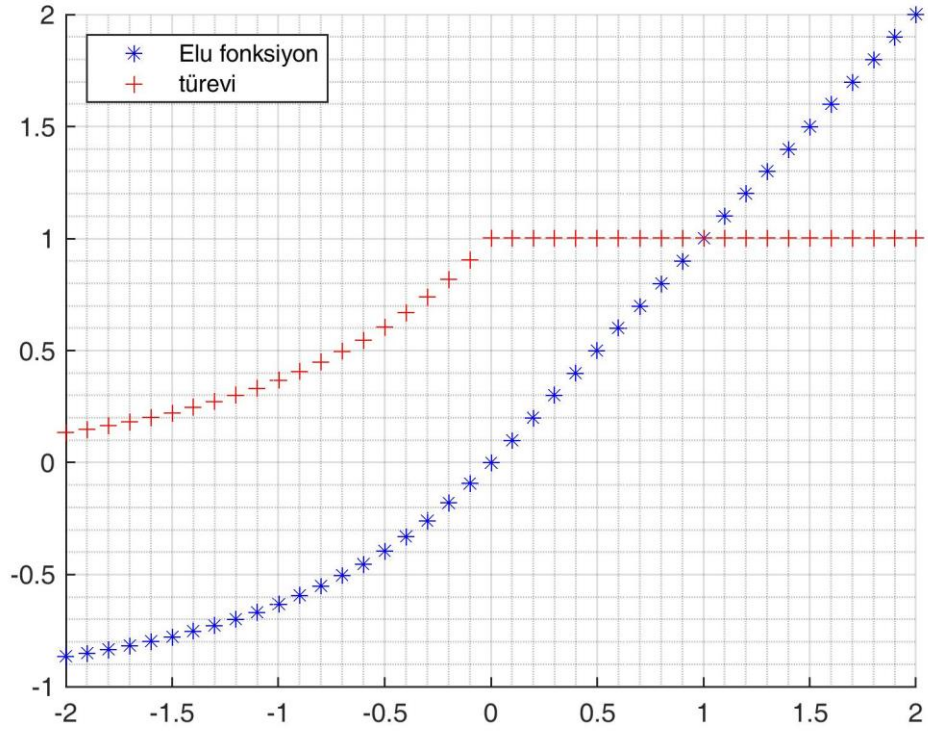


Şekil 3.20. PRelu fonksiyon

**Üstel Lineer Birim (Elu) Fonksiyonu:** Pozitif girdilerde doğrusal, negatif girdilerde üstel doğrusal olmayan özellik göstermektedir. Üstel lineer birim fonksiyon Eşitlik 3.15’de verilmiştir.

$$f(x) = \begin{cases} x \rightarrow x \geq 0 \\ \alpha * (\exp(x) - 1) \rightarrow x < 0 \end{cases} \quad (3.15)$$

Doğrusal olmama parametresi,  $\alpha$  değeridir. ELU katmanının çıktısının minimum değeri  $\alpha$  'ya eşittir ve 0'a yaklaşan negatif girişlerdeki eğim  $\alpha$  'dır [95]. Şekil 3.21’de üstel lineer birim fonksiyonun grafiği verilmiştir.




Şekil 3.21. Elu fonksiyon

#### 3.4.3.4.Havuzlama katmanı (Pooling Layer)

Havuzlama katmanı (*Pooling*) giriş görüntüsünü genişlik ve yükseklik bakımından azaltarak yeniden örnekleme yapmaktadır. Havuz katmanları, özellik haritalarını özellik sayısı arttıkça makul bir boyutta tutmak için gereken verileri takip etmenize ve sonraki evrişim katmanlarının girdilerin daha geniş bir uzamsal alanını görmesi için gereken verileri uzamsal olarak örnekleme yapmasını sağlamaktadır. Ağ tarafından öğrenilecek parametre sayısını azaltır. Bu ağın ezberlemesinin önüne geçme ve performansı ve doğruluğu artırma etkisine sahiptir [96].

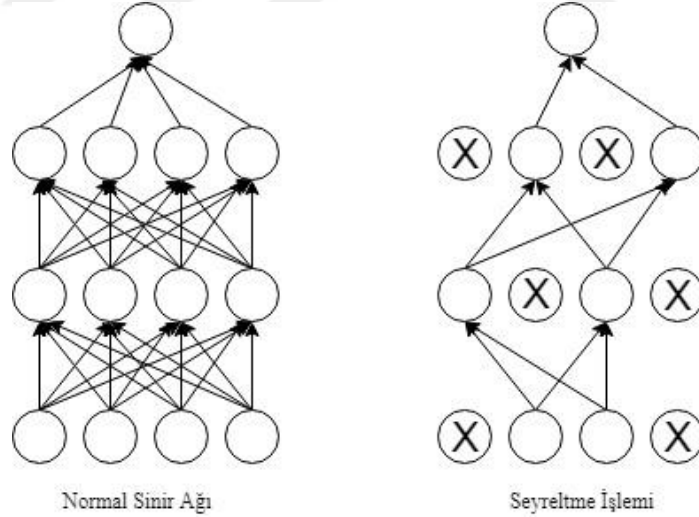
Birden fazla havuzlama tekniği vardır. En yaygın havuzlama teknikleri maksimum havuzlama ve ortalama havuzlamadır. Maksimum havuzlama işleminde geçerli matrisin en büyük değeri seçerken, ortalama havuzlama da geçerli matrisin değerlerinin ortalamasını almaktadır [81]. Şekil 3.22'de kaydırma adımı 2, piksel ekleme 0 olan bir 2 x 2 bir filtrenin giriş görüntüsüne uygulanışı gösterilmektedir.



Şekil 3.22. Havuzlama işlemi

### 3.4.3.5. Seyreltme katmanı (Dropout Layer)

Seyreltme, bazı ağ katmanlarının çıkışına uygulanabilen bir düzenleme tekniğidir. Verilen  $p$  olasılık değerine göre herhangi bir nöronun çıktısını sıfıra ayarlayarak ağı ezberlemesinin önüne geçmektedir. Bir sinir ağına seyreltme uygulamak, eğitim sırasında ağda bulunan nöronları geçici olarak dışlar. Diğer düğümlerden bağımsız olarak,  $0 < p < 1$  olasılıklı bir düğüm ağdan dışlanır. Bir nöron dışlama, sadece değerini ve ona bağlı tüm ağırlıkları sıfıra ayarlayarak yapılır. Bu işlem ağdaki tüm nöronlar için geçerlidir. Evrişimli, havuzlanmış veya tamamen bağlı katmanlardan sonra uygulanabilmektedir. [97]. Şekil 3.23'de örnek bir seyreltme işlemi görülmektedir.



Şekil 3.23. Seyreltme işlemi

### 3.4.3.6. Tamamen bağlı katman (Fully Connected Layer)

Tamamen bağlı bir katman girdi olarak bir vektör  $x$  alır ve başka bir  $y$  vektörü verir, matematiksel olarak Eşitlik 3.16'da verilen bir matris-vektör çarpımı ile tanımlanır:

$$y=A*x \quad (3.16)$$

Giriş görüntüsünün boyutları  $m*n$  olduğunu düşünürsek,  $x \in R^n$  ve  $A \in R^{m*n}$  olduğu eğitilebilir bir ağırlık matrisidir. Çıktının her bir bileşeni, girdideki tüm bileşenlerin ağırlıklı bir toplamıdır. Ağırlıklı toplam, hangi özelliklerin belirli bir nesneye veya sınıfa en uygun olduğunu belirlemeye karşılık gelir [86].

ESA, bir girdi görüntüsünü nihai sınıf puanlarına dönüştürür. Her katman farklı şekilde çalışır ve farklı parametre gereksinimlerine sahiptir. Bu katmanlardaki parametreler, geri yayılım şeklinde gradyan iniş tabanlı bir algoritma ile öğrenilir [71].

### **3.5.Sinir Ağını Eğitme**

Oluşturulan sinir ağının eğitiminde göz önünde bulundurulması gereken birçok faktör vardır. Bu faktörler, oluşturulan ağ eğitim sürecine başladığında başlangıç ağırlıklarının belirlenmesi, regülasyon, optimizasyon algoritmaları ve kayıp fonksiyon belirleme gibi işlemlerdir.

#### **3.5.1. Ağ ağırlığı başlatma**

Her ESA katmanı, eğitim seti üzerinde eğitilmiş belirli parametrelere veya ağırlıklara sahiptir. Bu optimal ağırlığı öğrenmek için bazı optimizasyon algoritmaları kullanılmaktadır. Bu algoritmalara girişler, ilk ağırlık kümesini, bir kayıp fonksiyonunu ve etiketli eğitim verilerini içerir. Algoritma, eğitim verilerinde verilen etiketlere göre kayıp değerini hesaplamak için başlangıç ağırlıklarını kullanır ve kaybı azaltmak için ağırlığını ayarlar.

Bu ayarlanan ağırlık, bir sonraki yinelemeyi beslemektedir ve yakınsama elde edilene kadar devam etmektedir. Bu süreçten görülebileceği gibi, ağ başlatma için başlangıç ağırlığının seçimi, ağ eğitiminin yakınsama kalitesi ve hızı üzerinde önemli bir rol oynamaktadır [71]. Bunun için çeşitli stratejiler uygulanmıştır.

**Sıfır kurulum:** Tüm ağırlığı 0 olarak ayarladığında, kayıp fonksiyonuna göre türev ağdaki her ağırlık için aynıdır. Bu nedenle tüm ağırlıklar sonraki yinelemede aynı değerlere sahiptir. Bu, gizli birimleri simetrik yapmakta ve çalıştırdığımız tüm yinelemeler için devam etmektedir. Modeli doğrusal bir modele eşdeğer yapmaktadır. Dolayısıyla her nöron aynı kayıp değerini hesaplayacak ve her yinelemede, aynı gradyan güncellemesini yapacaktır. Bu, her nöronun benzer özellikleri öğreneceği ve ağırlıkların verilerden ilginç kalıpları öğrenecek kadar çeşitli olmayacağı anlamına gelmektedir [98].

**Rasgele kurulum:** Bütün ağırlıklara başlangıçta rastgele bir değer verilir. Eğer ağırlıklar çok yüksek değerlerde başlatılırsa, gradyanların patlaması (*exploding gradients*) sorununa neden olabilmektedir. Dolayısıyla  $w*x+b$  değeri çok daha yüksek olmaktadır. Öğrenmenin çok zaman almasına, yanlış hesaplamalara, *NaN* veya *Inf* değerini alan kayıplara ve modelin asla öğrenememesine neden olmaktadır [98]. Bu şekilde aykırı değerlerin varlığında eğitimi dengelemek için gradyan kırpma (*gradient clipping*) hiperparametresi kullanılmaktadır. Gradyan kırpma, ağırlıkların daha hızlı eğitilmesini sağlar ve genellikle öğrenilen görevin doğruluğunu etkilemez [99].

Eğer ağırlıklar çok düşük değerlerde başlatılırsa, gradyanların kaybolması (*vanishing gradients*) sorununa neden olabilmektedir. Dolayısıyla ağırlık güncellemesi küçük olmasına, daha yavaş yakınsamaya, kayıp fonksiyonunun optimizasyonunu yavaşlatmasına, sinir ağının eğitiminin durmasına neden olabilmektedir [98]. İyi bir uygulama için, ağırlıkları rasgele bağımsız olarak sıfır ortalama ve standart sapma 0.01 ile normal bir dağılımdan örnekleme yaparak başlatılmalıdır [71].

**Xavier ve He kurulum:** Ağırlıkların başlangıç değerlerinin belirlenmesinde önemli bir sorun, çıktılarının girdi sayısı ile birlikte artan bir varyansa sahip olmasıdır. Her bir nöronun çıkışındaki varyansı, ağırlık vektörünü girdi sayısının kareköküyle ölçeklendirerek 1'e normalleştirilmektedir. Yani rasgele belirlenen  $n$  giriş sayısı kadar ağırlık değerleri,  $1/\sqrt{n}$  ile çarpılmaktadır. Bu, ağdaki tüm nöronların başlangıçta yaklaşık olarak aynı çıkış dağılımına sahip olmasını ve yakınsaklık oranını iyileştirmesini sağlamaktadır [79].

Bu düşünceden yola çıkarak, Glorot ve Bengio [100] Xavier kurulum ile  $n_{giriş}$ ,  $n_{çıkış}$  önceki katmandaki ve sonraki katmandaki birim sayısı olduğu Eşitlik 3.17’de verilen şekilde başlatılmasını önermektedir.

$$Var(w) = \frac{2}{n_{giriş} + n_{çıkış}} \quad (3.17)$$

He ve ark. [101] sıfır ortalama ve varyans  $2 / n_{giriş}$  ile normal bir dağılımdan başlatılmasını önermektedir.

### 3.5.2. Düzenleştirme

Düzenleştirme, ezberlemeyi azaltan bir süreçtir. Aşırı öğrenme durumlarında model ağırlıklarının düzenlenmesini sağlamaktadır. Düzenleştirme işlemi, kenarların ağırlıklarını tanımlanmış kayıp fonksiyonuna ekler ve bütünsel olarak daha yüksek bir kaybı temsil eder. Ağ daha sonra kaybı azaltmak için kendisini ayarlar ve böylece ağırlık güncellemelerini doğru yönde yapmasını sağlar [102]. Düzenleştirme işleminin formülü Eşitlik 3.18’de verilmiştir.

$$Maliyet\ Fonksiyon = Kayıp\ Fonksiyon + \frac{\lambda}{2} * Ağırlıkla \quad (3.18)$$

Denklemden verilen  $\lambda$ , düzenleştirme parametresidir. Önünde  $1 / 2$  faktörü yaygındır, çünkü o zaman  $w$  parametresine göre bu terimin gradyanı  $2 * \lambda * w$  yerine sadece  $\lambda * w$  olmaktadır. Ağ düzenlemenin çeşitli yolları vardır. Yaygın olarak kullanılan tekniklerden bazıları şunlardır:

**L1 düzenleştirme:** Mutlak ağırlıklar, kayıp fonksiyonuna eklenmektedir. Modeli daha genel hale getirmek için, ağırlıkların değerleri 0'a düşürülmektedir. Gürültülü girişleri tamamen ortadan kaldırmak ve ideal olarak bu girişlere 0 ağırlık vermek istenildiğinde kullanılmaktadır [102]. Kayıp fonksiyona eklenen L1 düzenleştirmenin Eşitlik 3.19’da verilmiştir.



$$\frac{\lambda}{2} * \sum |W| \quad (3.19)$$

**L2 düzenleme:** Ağırlıkların karesi, kayıp fonksiyonuna eklenir. Ağırlıklar ne kadar yüksek olursa ceza da o kadar yüksek olur. Modeli daha genel hale getirmek için, ağırlıkların değerleri 0'a yakın (ancak aslında 0 değil) bir değere düşürmektedir. Bu nedenle buna ağırlık azalması (*weight decay*) yöntemi de denir . Ağırlıkların L1 düzenlemeye göre daha küçük olmasını sağlamaktadır. Bir ağda daha yüksek ağırlıklara sahip olmak, ağı daha yüksek ağırlıklara sahip nöronlara bağımlı hale getirecektir. Küçük ağırlığa sahip olan ağı bütün girdilerini uygun şekilde kullanacağı ve daha çeşitlendirileceği anlamına gelmektedir. Bu yüzden L1 düzenlemeye göre daha yaygın şekilde kullanılmaktadır. Kayıp fonksiyona eklenen L2 düzenleme Eşitlik 3.20'de verilmiştir [71].

$$\frac{\lambda}{2} * \sum |W|^2 \quad (3.20)$$

L1 düzenlemesini L2 düzenlemesiyle birleştirmek mümkündür. Bu şekilde kullanıma Elastik Net denilmektedir [79]. Eşitlik 3.21'de verilmiştir.

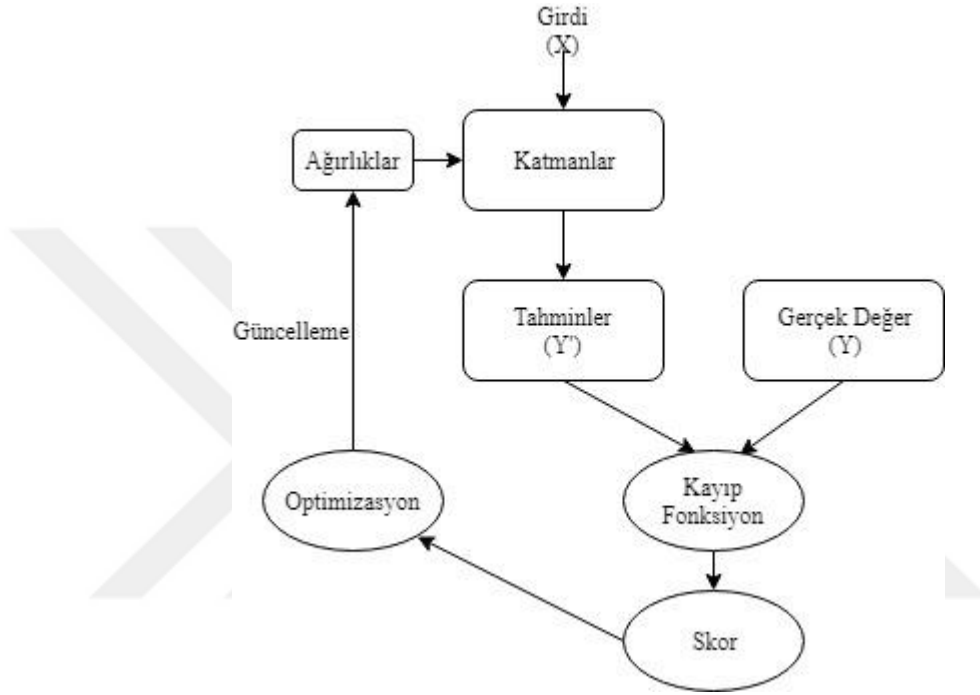
$$\frac{\lambda}{2} * [(1-\alpha) * \sum |W| + \alpha * \sum |W|^2] \quad \lambda \in \mathfrak{R} \text{ ve } \alpha \in [0,1] \quad (3.21)$$

**Maksimum norm kısıtlama düzenlemesi:** Her nöron için ağırlık vektörünün büyüklüğüne  $\|w\|_2 \leq k$  gibi mutlak bir üst sınır uygulamak ve kısıtlamayı zorlamak için öngörülen gradyan inişini kullanmaktır. Bu, ağ ağırlıklarının ve güncellemelerinin her zaman sınırlandırılmasını ve ağı öğrenme hızı gibi faktörlere bağlı olmamasını sağlamaktadır [79].

### 3.5.3. Kayıp Fonksiyon

Nöron sayısı, aktivasyon fonksiyonları, girdi – çıktı birimleri ile katman dizisini tanımlayarak oluşturulan model, başlangıçta rastgele ağırlıklarla başlatılmaktadır. Bir

nöronun bir sonraki nöron üzerindeki etkisini veya nihai çıktıyı belirleyen ağırlıklar, ağ tarafından öğrenme sürecinde güncellenmektedir. Çıktı, bir sonraki katman için bir girdi haline gelmektedir. Nihai katmanın çıktısı, eğitim kümesi için öngörü olacaktır. Kayıp fonksiyonun resmin içine girdiği yer burasıdır. Model için bir sonraki adım, kaybı azaltmaktır. Şekil 3.24’de ağırlıkların güncellenmesi süreci gösterilmektedir.



**Şekil 3.24.** Ağırlıkların güncellenmesi

Kayıp fonksiyon, ağırlıkların güncellenmesi için eğitim sürecinde mevcut ağırlık grubunun ne kadar iyi ya da zayıf olduğunu anlamasına yardımcı olmaktadır. Başlıca kullanılan kayıp fonksiyonlar şunlardır:

**Çapraz entropi:** Çoklu sınıflandırma problemlerinde doğru dağılımla aradaki farkı ölçmek için tercih edilmektedir. Eşitlik 3.22’de formülü verilmektedir.

$$skor = - \sum_{i=1}^N \sum_{j=1}^M t_{ij} * \ln y_{ij} \quad (3.22)$$

Eşitlikte,  $N$  örnek sayısını,  $M$  sınıf sayısını,  $t_{ij}$   $i$ 'nci örneğin  $j$ 'nci sınıfa ait olduğunu,  $y_{ij}$   $j$  sınıfı için  $i$  örneğinin çıktısı olduğunu ifade etmektedir [103].

**Menteşe kayıp fonksiyon:** Sınıflandırma problemlerinde genellikle destek vektör makinesi (DVM) algoritmasında tercih edilmektedir [104]. Eşitlik 3.23'de formülü verilmektedir.

$$skor = \sum_{j=1}^n w_j \max(0, 1 - m_j) \quad (3.23)$$

Eşitlikte  $m_j$  sınıflandırma skorunu ifade etmektedir. Sınıflandırma skorunun pozitif değerleri doğru sınıflandırmayı gösterir ve ortalama kayba fazla katkıda bulunmaz. Negatif değerleri ise hatalı sınıflandırmayı gösterir ve ortalama kayba önemli ölçüde katkıda bulunur.

#### 3.5.4. Optimizasyon

Optimizasyon fonksiyonları, türevleri, kısmi türevleri ve nöronların ağırlığında küçük bir değişiklik yaparak ağın kayıp fonksiyonunda ne kadar değişiklik göreceğini anlamak için hesaplardaki zincir kuralını kullanan matematiksel algoritmalarıdır. Kayıp fonksiyonunda meydana gelen artış, azalan veya azalacak olan, bağlantının ağırlığında gereken değişimin yönünün belirlenmesine yardımcı olmaktadır. Başlıca optimizasyon algoritmaları şunlardır:

**Stokastik dereceli azalma (SGD):** Standart dereceli algoritması, her bir iterasyonda kaybın negatif gradyanı yönünde küçük adımlar atarak, kayıp fonksiyonunu en aza indirmek için ağ parametresi olan ağırlıkları güncellemektedir. Eşitlik 3.24'de parametre vektörü verilmiştir.

$$\theta_{\ell+1} = \theta_{\ell} - \alpha * \nabla E(\theta_{\ell}) \quad (3.24)$$

Denkleme göre,  $\ell$  iterasyon sayısını,  $\alpha > 0$  öğrenme oranını ve  $E(\theta)$  kayıp fonksiyonu ifade etmektedir. Standart dereceli azalma algoritmasında, kayıp

fonksiyonunun gradyanı olan  $\nabla E(\theta_\ell)$ , tüm eğitim seti kullanılarak değerlendirilmektedir ve standart dereceli azalma algoritması tüm veri setini bir kerede kullanır.

Stokastik dereceli azalma algoritması ise, her iterasyonda gradyanı değerlendirir ve mini küme olarak adlandırılan eğitim verisinin bir alt kümesini kullanarak, ağ parametresi olan ağırlıkları güncellemektedir.

Bir mini küme kullanılarak hesaplanan parametre güncellemeleri, tam veri setinin kullanılmasından kaynaklanacak parametre güncellemesinin gürültülü bir tahminidir. Mini kümeleri kullanarak eğitim algoritmasının tüm eğitim setine geçmesi epok olarak adlandırılmaktadır.

Stokastik dereceli azalma algoritması, optimuma doğru en dik iniş yolu boyunca salınım yapabilmektedir. Özellikle stokastik dereceli azalma algoritmasında yüksek varyanslı salınımlar yakınsamayı zorlaştırmaktadır [103].

Momentum parametresi eklemek bu salınımı azaltmaktadır. Eşitlik 3.25'de momentum eklenmiş parametre vektörünün bağıntısı verilmiştir.

$$\theta_{\ell+1} = \theta_\ell - \alpha * \nabla E(\theta_\ell) + \gamma * (\theta_\ell - \theta_{\ell-1}) \quad (3.25)$$

Denkleme göre,  $\gamma$  parametresi önceki gradyan adımının mevcut iterasyona katkısını belirlemektedir [105].

**Karekök ortalama yayılımı (RMSProp):** Stokastik dereceli azalma algoritması, tüm parametreler için tek bir öğrenme oranı kullanmaktadır. Karekök ortalama yayılımı algoritması, parametreye göre farklılık gösteren ve optimize edilen, kayıp fonksiyonuna otomatik olarak adapte olabilen öğrenme oranlarını kullanarak ağ eğitimini iyileştirmeyi amaçlamaktadır. Eşitlik 3.26'da parametre gradyanlarının karelerinin hareketli bir ortalamasını gösteren bağıntı verilmiştir.

$$v_\ell = \beta_1 * v_{\ell-1} + (1 - \beta_1) * [\nabla E(\theta_\ell)]^2 \quad (3.26)$$

Denkleme göre,  $\beta_1$  bozulma oranı (*decay rate*) ifade etmektedir. Eşitlik 3.27'de hareketli ortalamanın kullanıldığı parametre vektörü verilmiştir.

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha * \nabla E(\theta_\ell)}{\sqrt{v_\ell} + \varepsilon} \quad (3.27)$$

Burada  $\varepsilon$ , sıfıra bölünmeyi önlemek için eklenen küçük bir sabittir. RMSProp algoritması, büyük gradyanlarda parametre öğrenme oranlarını etkin bir şekilde azaltır ve küçük gradyanlarda parametre öğrenme oranlarını artırır [69].

**Uyarlanabilir moment tahmini (Adam):** RMSProp algoritmasından farklı olarak hem parametre gradyanlarının hem de kare değerlerinin hareketli ortalamasını tutmaktadır. Eşitlik 3.28'de parametre gradyanlarını, Eşitlik 3.29'da parametre gradyanlarının karesini kullanan hareketli ortalama bağıntıları verilmiştir.

$$m_\ell = \beta_1 * m_{\ell-1} + (1 - \beta_1) * \nabla E(\theta_\ell) \quad (3.28)$$

$$v_\ell = \beta_2 * v_{\ell-1} + (1 - \beta_2) * [\nabla E(\theta_\ell)]^2 \quad (3.29)$$

Eşitlikte,  $\beta_1$  ve  $\beta_2$  bozulma oranları, sırasıyla gradyan bozulma faktörü ve kare gradyan bozulma faktörünü ifade etmektedir. Eşitlik 3.30'da hareketli ortalamaların kullanıldığı parametre vektörü verilmiştir.

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha * m_\ell}{\sqrt{v_\ell} + \varepsilon} \quad (3.30)$$

Gradyanlar çoğunlukla gürültü içeriyorsa, gradyanın hareketli ortalaması küçülür ve bu nedenle parametre güncellemeleri de küçülür [106].

### 3.5.5. Hiper parametreler

Hiper parametreler, öğrenme sürecini tanımlayan probleme ve veri setine göre farklılık gösteren parametrelerdir. Model parametrelerinin aksine hiper parametreler öğrenilmez. Gelişmiş performans elde etmek için, model geliştirici modele uygun olarak hiper parametreleri ayarlaması gerekmektedir [102].

Derin öğrenme uygulamalarında kullanılan başlıca hiper parametreler, veri setinin büyüklüğü ve çeşitliliği, bir katmandaki nöronların sayısı, gizli katmanların sayısı, aktivasyon fonksiyonu, optimize edici algoritma, mimarinin öğrenme oranı, epok sayısı, mini küme büyüklüğü, kayıp fonksiyon, seyreltme değeri, ağ ağırlıklarını başlatma yöntemleri, ESA'da kullanılan filtre boyutları, havuzlama metodu olabilmektedir.

Çok küçük bir öğrenme oranı, çok yavaş bir eğitim sürecine ve lokal minimuma takılmasına neden olurken, çok büyük bir öğrenme hızı aşmaya ve kayıp fonksiyonunun sapsmasına neden olabilmektedir. En uygun çözüm, öğrenme oranını başlangıçta yüksek tutmak, daha sonra en düşük hata oranına ulaşana kadar azaltmaktır [102].

### 3.6.Görselleştirme

Bir ESA'nın önemli yönlerinden biri, bir kez eğitildiğinde, özellik çıkarıcı fonksiyonu gören bir dizi özellik haritası veya filtre öğrenmesidir.

**Katman aktivasyonu:** Bu, ağın ileri besleme sırasında nöronların aktivasyonunu görselleştiren en yaygın ağ görselleştirme şeklidir. Her öğrenilen filtrenin, her giriş görüntüsüne verdiği tepkiyi gösterir. Aynı zamanda filtrelerin çoğunun herhangi bir kullanışlı özellik öğrenip öğrenmediği konusunda fikir vermektedir [71].

**Filtre görselleştirme:** ESA filtrelerinin, görselleştirildiğinde her filtrenin ne tür bir görüntü özelliğini yansıtabileceğini göstermektedir [71].



Yetersiz öğrenmeyi gidermek için; daha fazla veri almak, daha büyük bir eğitim modeli geliştirmek, veri artırma işlemleri yapmak gerekmektedir. Aşırı öğrenmeyi gidermek için; seyreltme katmanı eklemek, küme normalizasyonu uygulamak ve düzenlileştirme parametreleri belirlemek ve veri artırma işlemleri yapmak gerekmektedir [81].

### 3.7.2. Doğrulama süreci

Doğrulama sürecinde, veri seti eğitim ve kontrol grubu olmak üzere iki parçaya bölünmektedir. Eğitim veri seti kullanılarak sınıflandırıcı model elde edilir. Daha sonra geliştirilen sınıflandırıcı model, kontrol verisi üzerinde test edilerek tahminler elde edilir [107]. Veri setinin eğitim ve kontrol şeklinde bölünmesini sağlamak amacıyla bazı yöntemler geliştirilmiştir. Bu yöntemlerden bazıları şunlardır:

**Dışarıda tutma:** Bu yöntem büyük veri setlerinde tercih edilmektedir. Veri kümesinin %70'i gibi belirli bir oranı rasgele seçilerek eğitim seti oluşturulur. Geri kalanlar kontrol grubu olarak belirlenmektedir.

**k-katlı çapraz doğrulama:** Bu yöntem veri setinin küçük olduğu durumlarda tercih edilmektedir. Veri seti k eşit parçaya bölünür. Bu parçalardan k-1 tanesi eğitim, bir tanesi kontrol için kullanılır. Bu işlem k defa tekrar eder ve her seferinde elde edilen doğruluk değerlerinin ortalaması alınarak geliştirilen modelin doğruluk değeri elde edilir [107].

**Üçlü ayırma:** Veri seti eğitim, doğrulama ve kontrol olmak üzere 3 gruba ayrılmaktadır. Doğrulama grubu, geliştirilen modelin hiper parametrelerini ayarlarken eğitim veri setine uygun bir modelin tarafsız bir değerlendirmesini sağlamak için kullanılmaktadır.



### 3.7.3. Performans metrikleri

Performansı belirleyebilmek için öncelikle eğitim veri kümesinde geliştirilen modelin eğitilmesi, ardından kontrol veri kümesinde tahminlerin elde edilmesi gerekmektedir.

Sınıflandırma işlemlerinde gerçek veri ile tahmin edilen değerleri karşılaştırmak için karışıklık matrisi kullanılmaktadır. Matrisin sütunları gerçek hedef değerlere ait sınıf etiketlerini, satırları tahmin edilen çıkış sınıf etiketlerini göstermektedir [108]. Şekil 3.26'da ikili sınıflandırıcı için örnek karışıklık matrisi gösterilmektedir.

		Gerçek Değer	
		P	N
Tahmin Edilen Değer	P	TP	FP
	N	FN	TN

Şekil 3.26. Karışıklık matrisi

**Gerçek pozitif (TP):** Gerçek değeri pozitif ve tahmin edilen değer de pozitif olduğu değerlerdir.

**Gerçek negatif (TN):** Gerçek değeri negatif ve tahmin edilen değer de negatif olduğu değerlerdir.

**Yanlış pozitif (FP):** Gerçek değeri negatif fakat tahmin edilen değer pozitif olduğu değerlerdir.

**Yanlış negatif (FN):** Gerçek değeri pozitif fakat tahmin edilen değeri negatif olduğu değerlerdir.

Karışıklık matrisinden hesaplanan bazı performans ölçütleri vardır. Bu ölçütlerden bazıları şunlardır:

**Doğruluk ölçütü:** Gerçek değerlerin, tahmin edilen değerlerle hangi oranda aynı olduğunu ortaya koymaktadır. Eşitlik 3.31’de verilen bağıntı yardımıyla hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.31)$$

Doğruluk ölçütü kullanılarak hata oranına *1-doğruluk* bağıntısıyla ulaşılmaktadır. Doğruluk ölçütü değerinin büyüklüğü önemlidir ve sınıflandırma modelinin tahmin edebilme gücünü göstermektedir.

**Duyarlılık:** Sınıflandırıcının gerçek pozitif değeri tahmin edebilme başarısını elde etmek amacıyla kullanılmaktadır. Doğru pozitif oran (*TPR*) veya hatırlatma (*Recall*) adı da verilmektedir. Eşitlik 3.32’de verilen bağıntı yardımıyla hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.32)$$

**Özgünlük:** Sınıflandırıcının gerçek negatif değeri tahmin edebilme başarısını elde etmek amacıyla kullanılmaktadır. Doğru negatif oran (*TNR*) olarak da adlandırılmaktadır. Eşitlik 3.33’de verilen bağıntı yardımıyla hesaplanmaktadır.

$$\text{Özgünlük} = \frac{TN}{TN + FP} \quad (3.33)$$

**Kesinlik:** Sınıflandırıcının tahmin edilen pozitif değer o sınıfa ait tüm gözlemler içindeki payını ölçmek amacıyla kullanılmaktadır. Pozitif tahmini değer adı da verilmektedir. Eşitlik 3.34’de verilen bağıntı yardımıyla hesaplanmaktadır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.34)$$

**F1 puanı:** Duyarlılık ve kesinlik ölçütlerinin harmonik ortalaması F1 puanı olarak isimlendirilmektedir. Her iki ölçütü birlikte değerlendirmek amacıyla kullanılmaktadır. Eşitlik 3.35’de verilen bağıntı yardımıyla hesaplanmaktadır.

$$F1 \text{ puanı} = [ ( \text{Duyarlılık} * \text{Kesinlik} ) / ( \text{Duyarlılık} + \text{Kesinlik} ) ] \quad (3.35)$$

**Negatif tahmini değer (NPV):** Sınıflandırma sonucu negatif olanların içinde ne kadarının gerçekte hasta olmadığını göstermektedir. Aynı zamanda sınıflandırma sonucu gerçekte hasta olmama olasılığını da ifade etmektedir. Eşitlik 3.36’da verilen bağıntı yardımıyla hesaplanmaktadır.

$$\text{Negatif tahmini değer} = \frac{TN}{TN + FN} \quad (3.36)$$

**Yanlış pozitif oranı (FPR):** Sınıflandırma sonucu pozitif çıkanların yanlış olma olasılığını göstermektedir. Eşitlik 3.37’de verilen bağıntı yardımıyla hesaplanmaktadır.

$$\text{Yanlış pozitif oranı} = \frac{FP}{TN + FP} \quad (3.37)$$

**Yanlış keşif oranı (FDR):** Gerçek değeri negatif fakat tahmin edilen değeri pozitif olan değerlerin oranını göstermektedir. Eşitlik 3.38’de verilen bağıntı yardımıyla hesaplanmaktadır.

$$\text{Yanlış keşif oranı} = \frac{FP}{TP + FP} \quad (3.38)$$

**Yanlış negatif oranı (FNR):** Sınıflandırma sonucu negatif çıkanların yanlış olma olasılığını göstermektedir. Eşitlik 3.39’da verilen bağıntı yardımıyla hesaplanmaktadır.

$$\text{Yanlış negatif oranı} = \frac{FN}{FN + TP} \quad (3.39)$$

**Matthews Korelasyon Katsayısı (MCC):** Matthews korelasyon katsayısı, ikili sınıflandırmaların kalitesinin ölçüsü olarak makine öğrenmesinde kullanılmaktadır [109].

Doğru ve yanlış pozitiflerin ve negatiflerin karışıklık matrisini tek bir sayı ile tarif etmede kullanılır [110]. Eşitlik 3.40'da verilen bağıntı yardımıyla hesaplanmaktadır.

$$MCC = \frac{(TP * TN) - (FP * FN)}{\sqrt{((TP + FP) * (TP + FN) * (TN + FP) * (TN + FN))}} \quad (3.40)$$



## 4 ARAŞTIRMA BULGULARI VE TARTIŞMA

### 4.1. Manyetik rezonans görüntülerinin elde edilmesi

Göğüs MR görüntüleri, 1.5 Tesla'da (Achieva, Philips, Hollanda) sekiz kanallı özel göğüs bobinleri kullanılarak hastalar yatay bir pozisyonda iken gerçekleştirildi. Eksenel düzlemde yağ baskısız T1 ağırlıklı taramalar (TR: 550 ms TE: 10 ms THK: 3 mm, FOV: 300 mm NSA: 2 T: 1.55 dk), T2 ağırlıklı gradyan eko (GRE) taramaları yağ baskılı elde edildi (TR: 4000 ms TE: 125 ms FOV 300 mm NSA: 2 T: 1.40 dak).

Otomatik intravenöz bolus uygulaması ile dinamik kontrastlı görüntüleme yapıldı. Her bir kontrastlı seri için, geliştirilmiş olmayan serinin, geliştirilmiş seriden çıkarılması yoluyla, sonuç görüntüleri elde edildi. Bu görüntüler MR görüntüleme yapıldıktan sonra MR cihazının iş istasyonundan kalınlığı 2.0 mm'den az olan DICOM formatındadır. İşlemler sonucunda, 65536 farklı gri seviyeli (0-65535) renk içeren 288x288 çözünürlüğe sahip uint16 veri türünde görüntüler elde edildi.

### 4.2. Veri seti


Ham veri setindeki MR görüntüleri, Haseki Eğitim ve Araştırma Hastanesi, Radyoloji Bölümünden alınmıştır. Kurum ve girişimsel olmayan araştırmalar etik kurulu bu retrospektif çalışmayı onaylamıştır. Veri kümesi, aralarında 200 tümör bölgesinin meme MR görüntülerinden, 98'i iyi huylu ( $17.63 \pm 5.79$  mm) ve 102 habis ( $29.80 \pm 9.88$  mm) olarak oluşturulmuştur. Enfeksiyon ve granülomatöz mastitis hastaları ve MR görüntüsünün çarpık olduğu hastalar çalışmaya dahil edilmemiştir.

BI-RADS (Breast MRI imaging and data system) lezyon karakteristikleri iki radyolog tarafından bağımsız olarak değerlendirilmiş ve lezyonlu bölgeler iyi huylu ve habis olarak sınıflandırılmıştır. Daha sonra, tüm lezyonların tanısı, bir çekirdek iğne biyopsisiyle (16G otomatik çekirdek iğne, Geotek, TÜRKİYE) doğrulanmıştır. Çizelge 4.1, veri setinin özelliklerini göstermektedir.

**Çizelge 4.1.** Veri seti özellikleri


<b>Lezyon Sayısı</b>	200
<b>İyi huylu</b>	98(ortalama boyut $17.63 \pm 5.79$ mm)
<b>Habis</b>	102(ortalama boyut $29.80 \pm 9.88$ mm )
<b>Çözünürlük</b>	288×288
<b>Resim Formatı</b>	DICOM
<b>Sekans</b>	Dinamik Kontrastlı MR
<b>Kesit kalınlığı</b>	<2.0mm

Şekil 4.1’de oluşturulan veri setindeki orijinal iyi huylu örnek görüntüler gösterilmektedir.



**Şekil 4.1.** Veri setindeki orijinal iyi huylu tümör örnekleri

Şekil 4.2’de oluşturulan veri setindeki orijinal habis örnek görüntüler gösterilmektedir.




**Şekil 4.2.** Veri setindeki orijinal habis tümör örnekleri

### **4.3.İlgili tümör bölgesinin belirlenmesi ve önışlem**


Veri setindeki görüntüler, ham veri setinden aynı en boy oranıyla MR kesitlerinden tümör bölgeleri kırılarak elde edilmiştir. Daha sonra, her görüntü 50x50'ye yeniden boyutlandırılmıştır. Bundan sonra, piksel değerleri normalleştirilmiştir. Son olarak, önceden eğitilmiş derin sinir ağı DnCNN, görüntüleri dengelemek ve gürültüleri azaltmak için veri setindeki her normalize edilmiş görüntüye uygulanmıştır.

Şekil 4.3'deki MR kesitinin sol üst kısmındaki şüpheli bölge, Şekil 4.4.(a)'yı elde etmek için aynı en boy oranına sahip dikdörtgen şeklinde kırılmıştır. Ardından,


kırpılmış görüntü 50x50'ye yeniden boyutlandırıldı, normalize edildi ve DnCNN derin sinir ağı kullanılarak gürültüler giderildi. Sonuç olarak Şekil 4.4.(b)'deki örnek görüntü elde edildi.



Şekil 4.3. Orijinal görüntü




(a)



(b)

Şekil 4.4. (a) Kırpılmış orijinal tümörlü bölge (b) Yeniden boyutlandırılarak ön işlemden geçmiş tümörlü bölge

DnCNN sinir ağı 59 katmandan oluşmaktadır ve sadece gri tonlamalı görüntülerde kullanılabilir. Şekil 4.5.(a), ön işlemden geçmiş iyi huylu ve Şekil 4.5.(b) ise kötü huylu tümörlerin bazılarını gösterir.




(a)

(b)

Şekil 4.5. Veri kümesinde ön işlemden geçmiş tümör örnekleri (a) iyi huylu örnekler (b) habis örnekler



Şekil 4.6’da sınıflandırma süreci gösterilmiştir. İlgili tümör bölgesi belirlenmiş ve önışlemeden geçirilmiş lezyonlar sırasıyla ESA katmanlarından geçirilerek otomatik görsel özellikler çıkarılmış ve sınıflandırma işlemi yapılmıştır.




Şekil 4.6. Sınıflandırma süreci

#### 4.4. Veri artırma

Önerilen ağın veri kümesindeki görüntülerin tüm ayrıntılarını ezberlemesini ve ilgisiz örüntüleri öğrenmesinin önüne geçmek için çevrimiçi veri artırma uygulanmıştır. Bir görüntü verisi artırıcısı, yeniden boyutlandırma, döndürme ve yansıtma gibi görüntü büyütme işlemleri için bir dizi ön işleme seçeneği yapılandırır. Bu nedenle, görüntülerde rastgele olarak dikey ve yatay da 3 piksel kaydırma, 20 derecelik bir açıyla döndürülmüştür.

#### 4.5. Önerilen ESA modeli

Çalışmada geliştirilen ESA modelin yazılımsal alt yapısı Matlab ortamında geliştirilmiştir. Nvidia GTX 1050 ekran kartına sahip masaüstü bilgisayarda uygulanmıştır. Şekil 4.7’de modelin mimari yapısı gösterilmektedir.



**Şekil 4.7.** Önerilen ESA modeli

Önerilen ESA ağ mimarisi 6 adet evrişim, küme normalizasyonu, doğrultulmuş lineer birim fonksiyonu ve maksimum havuzlama katmanından, 1 adet seyreltme, tamamen bağlı katmandan ve softmax aktivasyon fonksiyonu katmanlarından oluşmaktadır. Ağ eğitim sürecinde “Adam” olarak adlandırılan Adaptive Moment tahmini metodunu kullanmıştır.

Önerilen modelde boyutları 50x50x1 olan görüntüye, filtre sayısı 32 filtre boyutu 7x7x1 olan ilk evrişim katmanı uygulanmıştır. İkinci evrişim katmanı girdi olarak ilk evrişim katmanının çıktısını alır ve 5x5x32 boyutunda 64 filtre ile filtreler. Üçüncü evrişim katmanı, ikinci evrişim katmanının çıkışına bağlı 3x3x64 boyutunda 128 çekirdeğe sahiptir. Tüm evrişim katmanları maksimum havuzlama ve küme normalizasyonu katmanlarıyla birbirine bağlanmıştır.

Havuz boyutu 2x2 olarak uygulanmıştır. Seyreltme katmanı, tamamen bağlı katmandan önce kullanılmıştır. Sistemin ezberlemesini önleyerek bir düzenleme görevi görür. Rastgele giriş elemanlarının %50’sini sıfıra ayarlar. Çizelge 4.2, önerilen ağ mimarisini daha detaylı göstermektedir.

**Çizelge 4.2.** Önerilen ağ mimarisindeki katmanlar

No	Tür	Tanımı
1	Giriş Görüntüsü	50x50x1 boyutundaki görüntüler sıfır merkezli normalizasyon
2	Evrişim	Filtre sayısı=32, filtre boyutu=7x7x1, kaydırma adımı=[1 1], piksel ekleme=[1 1 1 1]
3	Normalizasyon	32 kanal ile küme normalizasyonu
4	Aktivasyon	ReLU Aktivasyon fonksiyonu

5	Maksimum Havuzlama	Filtre boyutu=2x2, kaydırma adımı=[2 2], piksel ekleme=[0 0 0 0]
6	Evrişim	Filtre sayısı=64, filtre boyutu=5x5x32, kaydırma adımı=[1 1], piksel ekleme=[1 1 1 1]
7	Normalizasyon	64 kanal ile küme normalizasyonu
8	Aktivasyon	ReLU Aktivasyon fonksiyonu
9	Maksimum Havuzlama	Filtre boyutu=2x2, kaydırma adımı=[2 2], piksel ekleme=[0 0 0 0]
10	Evrişim	Filtre sayısı=128, filtre boyutu=3x3x64, kaydırma adımı=[1 1], piksel ekleme=[1 1 1 1]
11	Normalizasyon	128 kanal ile küme normalizasyonu
12	Aktivasyon	ReLU Aktivasyon fonksiyonu
13	Maksimum Havuzlama	Filtre boyutu=2x2, kaydırma adımı=[2 2], piksel ekleme=[0 0 0 0]
14	Evrişim	Filtre sayısı=256, filtre boyutu=3x3x128, kaydırma adımı=[1 1], piksel ekleme=[1 1 1 1]
15	Normalizasyon	256 kanal ile küme normalizasyonu
16	Aktivasyon	ReLU Aktivasyon fonksiyonu
17	Maksimum Havuzlama	Filtre boyutu=2x2, kaydırma adımı=[2 2], piksel ekleme=[0 0 0 0]
18	Evrişim	Filtre sayısı=512, filtre boyutu=3x3x256, kaydırma adımı=[1 1], piksel ekleme=[1 1 1 1]
19	Normalizasyon	512 kanal ile küme normalizasyonu
20	Aktivasyon	ReLU Aktivasyon fonksiyonu
21	Maksimum Havuzlama	Filtre boyutu=2x2, kaydırma adımı=[2 2], piksel ekleme=[0 0 0 0]
22	Evrişim	Filtre sayısı=1024, filtre boyutu=3x3x512, kaydırma adımı=[1 1], piksel ekleme=[1 1 1 1]
23	Normalizasyon	1024 kanal ile küme normalizasyonu
24	Aktivasyon	ReLU Aktivasyon fonksiyonu
25	Seyreltme	50% seyreltme katmanı
26	Tamamen Bağlı	2 tamamen bağlı katman

Katman		
27	Aktivasyon	Softmax Aktivasyon Fonksiyonu
28	Sınıflandırma	Çapraz entropi kayıp fonksiyonu ve Adam Optimize Edici

Çizelge 4.3’de, modelin karmaşıklığını ifade eden her bir katmanın aktivasyon boyutu ve öğrenilebilir parametre sayıları gösterilmektedir.

**Çizelge 4.3.** Önerilen ağ mimarisinin parametre sayıları

Katman no	Tür	Aktivasyon boyutu	Öğrenilebilir parametreler	Toplam öğrenilebilir parametre sayısı
1	Giriş Görüntüsü	50x50x1	-	0
2	Evrişim	46x46x32	Ağırlıklar 7x7x1x32 Bias 1x1x32	1600
3	Normalizasyon	46x46x32	Ofset 1x1x32 Ölçekleme 1x1x32	64
4	Aktivasyon	46x46x32	-	0
5	Maksimum Havuzlama	23x23x32	-	0
6	Evrişim	21x21x64	Ağırlıklar 5x5x32x64 Bias 1x1x64	51264
7	Normalizasyon	21x21x64	Ofset 1x1x64 Ölçekleme 1x1x64	128
8	Aktivasyon	21x21x64	-	0
9	Maksimum Havuzlama	10x10x64	-	0
10	Evrişim	10x10x128	Ağırlıklar 3x3x64x128 Bias 1x1x128	73856
11	Normalizasyon	10x10x128	Ofset 1x1x128 Ölçekleme 1x1x128	256
12	Aktivasyon	10x10x128	-	0
13	Maksimum Havuzlama	5x5x128	-	0
14	Evrişim	5x5x256	Ağırlıklar 3x3x128x256 Bias 1x1x256	295168

15	Normalizasyon	5x5x256	Ofset 1x1x256 Ölçekleme 1x1x256	512
16	Aktivasyon	5x5x256	-	0
17	Maksimum Havuzlama	2x2x256	-	0
18	Evrişim	2x2x512	Ağırlıklar 3x3x256x512 Bias 1x1x512	1180160
19	Normalizasyon	2x2x512	Ofset 1x1x512 Ölçekleme 1x1x512	1024
20	Aktivasyon	2x2x512	-	0
21	Maksimum Havuzlama	1x1x512	-	0
22	Evrişim	1x1x1024	Ağırlıklar 3x3x512x1024 Bias 1x1x1024	4719616
23	Normalizasyon	1x1x1024	Ofset 1x1x1024 Ölçekleme 1x1x1024	2048
24	Aktivasyon	1x1x1024	-	0
25	Seyreltme	1x1x1024	-	0
26	Tamamen Bağlı Katman	1x1x2	Ağırlıklar 2x1024 Bias 2x1	2050
27	Aktivasyon	1x1x2	-	0
28	Sınıflandırma	-	-	0
<b>Toplam</b>	-	-	-	<b>6327746</b>

Ayrıca probleme ve veri kümesine göre farklılık gösterebilecek öğrenme hızı, gradyan faktörü, epsilon gibi bazı hiper parametreler bulunmaktadır. Çizelge 4.4’de, ağda kullanılan hiper parametreler, değerleri ile birlikte özetlemektedir.

**Çizelge 4.4.** Hiper parametreler

<b>Optimize Edici</b>	Adam
<b>Gradyan bozulma faktörü</b>	0.900
<b>Kare Gradyan bozulma faktörü</b>	0.999
<b>Epsilon</b>	$10^{-8}$
<b>Başlangıç öğrenme oranı</b>	$10^{-3}$
<b>Seyreltme parametresi</b>	0.5
<b>L2 Düzenleme</b>	$10^{-4}$
<b>Gradyan Eşik Metodu</b>	L2 Norm
<b>Gradyan Eşik Değer</b>	Inf

<b>Doğrulama Frekansı</b>	5
<b>Doğrulama Dayancı</b>	5
<b>Maksimum Epok</b>	500
<b>Mini Küme Boyutu</b>	128
<b>Karıştırma</b>	Her Epok


#### 4.6.Önerilen modelin eğitilmesi

Ön işleme aşamasından sonra, veri kümesi, %70'i eğitim grubu ve %30'u kontrol grubu olarak kullanılmak üzere rastgele bir şekilde iki parçaya bölünmüştür. Çizelge 4.5, eğitim ve kontrol gruplarında kullanılan lezyon sayılarını göstermektedir.


**Çizelge 4.5.** Eğitim ve kontrol grupları

<b>Gruplar</b>	<b>Habis</b>	<b>İyi huylu</b>	<b>Toplam</b>
<b>Eğitim Grubu</b>	70	70	140
<b>Kontrol Grubu</b>	32	28	60
<b>Toplam</b>	102	98	200

Ağırlıklar, rastgele bağımsız olarak sıfır ortalama ve standart sapma 0.01 ile normal bir dağılımdan örnekleme yaparak başlatılmıştır. Şekil 4.8 ve Şekil 4.9, önerilen model için eğitim süreçlerindeki doğruluk ve kayıp grafiklerini göstermektedir.




**Şekil 4.8.** Önerilen ESA modelinin doğruluk grafiği




**Şekil 4.9.** Önerilen ESA modelinin kayıp grafiği

Eğitim sürecinde doğruluğunun (mavi çizgi) ve validasyon doğruluğunun (kesik siyah çizgi) birbirine yaklaştığı gözlemlenmektedir. Ayrıca, kayıp grafiğine göre, hem eğitim kaybı hem de doğrulama kaybı düşüktür ve eğitim süreci boyunca azalır.

Şekil 4.10'da, 50x50x1 giriş görüntüsünde birinci evrişim katmanı "conv 1" tarafından öğrenilen 7x7x1 boyutunda 32 adet görsel özellik gösterilmektedir. Şekil 4.11'de ise Şekil 4.10'daki görsel özelliklerin Şekil 4.4.(b)'deki görüntüye uygulanmış halini göstermektedir.



**Şekil 4.10.** Birinci evrişim katmanında öğrenilen özellikler



**Şekil 4.11.** Özelliklerin Şekil 4.4.(b)'ye uygulanması

#### **4.7.Önerilen modelin performansının değerlendirilmesi**

Burada, yalnızca piksel bilgileri kullanılarak, çevrimiçi veri büyütme göstergeli çok katmanlı bir ESA modeli tasarlanmıştır. Model, nispeten büyük lezyonlarla, yani iyi huylu  $17.63 \pm 5.79$  mm ve habis  $29.80 \pm 9.88$  mm ile eğitilerek test edilmiştir.

Geliştirilen ESA modelinin etkinliği, duyarlılık, özgüllük, kesinlik, kesinlik, F1 Puanı, Yanlış Olumsuz Oran, Yanlış Keşif Oranı, Yanlış Olumlu Oran, Olumsuz



Tahmini Değer ve Sınıflandırma Doğruluk, Matthews Korelasyon Katsayısı gibi bazı performans ölçütleri kullanılarak değerlendirildi.

Bu performans ölçütleri, Şekil 4.12’de verilen karışıklık matrisi kullanılarak değerlendirilmiştir.

**Confusion Matrix**

Output Class	Benign	28 46.7%	1 1.7%	96.6% 3.4%
	Malign	0 0.0%	31 51.7%	100% 0.0%
		100% 0.0%	96.9% 3.1%	98.3% 1.7%
		Benign	Malign	
		Target Class		

**Şekil 4.12.** Önerilen modelin karışıklık matrisi

Önerilen ESA ağı, grafik ekran kartının işlemcisini kullanarak ilk defa karşılaştığı 60 tümörlü bölgeden 59’unu doğru tahmin etmiştir. Bir habis tümörü doğru şekilde tespit edememiştir. Ağın doğruluğu % 98.33’tür. Ağın hata oranı 0.0167, duyarlılığı 1.0 iken, özgünlüğü %96.88, kesinlik %96.55 olarak elde edilmiştir. Çizelge 4.6’da, ağ için daha fazla performans istatistiği sunmaktadır.

**Çizelge 4.6.** Performans ölçütleri

Ölçüt	Değer
Duyarlılık	1.0000
Özgünlük	0.9688
Kesinlik	0.9655
Olumsuz tahmini değer	1.0000
Yanlış pozitif oranı	0.0313

Yanlış keşif oranı	0.0345
Yanlış negatif oranı	0.0000
Doğruluk	0.9833
F1 Puanı	0.9825
Matthews Korelasyon Katsayısı	0.9671

Çizelge 4.7’de son yıllarda makine öğrenmesi algoritmaları ve derin öğrenme teknikleri kullanılarak yapılan bazı çalışmalar verilmiştir. Ayrıca, çalışmaların çoğunda özel veriler kullanılmıştır.

**Çizelge 4.7.** Literatür karşılaştırması

No	Kullanılan Metod	Sonuç	Veri seti
1	K-En yakın komşu[29]	Doğruluk=74.7%, AUC=81.6%	Özel 221 hasta
2	Lineer diskriminant analiz, K-en yakın komşu, Gentleboost, DVM, Rasgele orman[30]	Duyarlılık =95% Doğruluk =91%	Özel 209 görüntü
3	DVM, K-En yakın komşu, Rasgele orman[31]	Doğruluk =82.8%, Duyarlılık =94%, Özgünlük =77.8%, AUC=80.9%	Özel 327 hasta (234 eğitim, 93 test verisi)
4	Bulanık K-kümelere[32]	AUC=88%	Özel 23 görüntü (15 habis, 8 iyi huylu)
5	Naive Bayes - İkinci derecen diskriminant analiz (NQDA), DVM[33]	AUC=87%	Özel 63 hasta
6	En küçük mesafe sınıflandırıcı, Lojistik regresyon, DVM[34]	Duyarlılık =95%, Özgünlük =78.19%, AUC=96.51%–97.55%	Özel 115 görüntü (78 habis, 37 iyi huylu)
7	DVM[35]	Doğruluk =98%	Özel 120 görüntü (70 normal, 50 anormal)
8	DVM[37]	Doğruluk =94% AUC=98.5%	Özel 70 klinik vaka
9	Rasgele orman[38]	Duyarlılık =100%, Özgünlük =77%, AUC=91%	Özel 240 hasta
10	DVM[39]	Duyarlılık =80%, Özgünlük =90%, AUC=91.9%±0.029	Özel 115 görüntü
11	Bayes tabanlı yapay sinir ağı[40]	HiSS için; AUC=92%±0.06	Özel 41 görüntü (34 habis, 7 iyi)

		DCE-MRI için; AUC=90%±0.05	huylu)
12	DVM[41]	AUC=77%	Özel 585 vaka
13	4 DBN + Gauss Karışım Modeli sınıflandırıcı ve 2 ESA + 2 rastgele orman sınıflandırıcısı[43]	Duyarlılık:96%	InBreast mamogram veri seti
14	3 evrişim + DVM sınıflandırıcı[44]	AUC:73%	Özel mamogram görüntüleri
15	2 evrişim + 1 tamamen bağlı katman[45]	AUC:93%	64 dijital meme tomosentez
16	5 evrişim + 2 tamamen bağlı katman[46]	AUC:94%	219 meme lezyonu
17	4 evrişim + 2 tamamen bağlı katman[47]	InBreast için; AUC= 91% DDSM için; AUC=97%	InBreast ve DDSM mamogram veri setleri
18	Alexnet, GoogleNet[48]	Alexnet için; Doğruluk =89% GoogleNet için; Doğruluk =92.9%	DDSM mamogram veri seti
19	Karışım topluluğu tabanlı ESA (ME-CNN)[51]	Duyarlılık =97.73% Özgünlük =94.87% Doğruluk =96.39%	Özel 112 Kontrastlı MR görüntüsü
20	Önerilen ESA Modeli	Duyarlılık=100%, Özgünlük=96.88%, Doğruluk =98.33%	Özel 200 Kontrastlı MR görüntüsü

\*AUC: Eğrinin altındaki alan

Önerilen ESA modeli performans istatistikleri açısından, Çizelge 4.7'de belirtilen modellerden daha iyi performans göstermektedir. Eğitim test denemeleri sırasında, model yüzde yüz doğruluğa dahi ulaşmıştır ancak yöntem %98.33 doğruluk oranıyla daha kararlı çalışmaktadır. Ek olarak, Alexnet [111] önceden eğitilmiş son teknoloji yaklaşım modelleri başlangıç noktası olarak kullanılmış ve önerilen ESA modeli ile aynı sonuçları vermiştir.

## 5 SONUÇ VE ÖNERİLER

Hem görüntüleme hem de bilgisayardaki gelişmeler sinerjistik olarak görüntü işleme tekniklerinin potansiyel kullanımında hızlı bir yükselişe yol açmıştır. Görüntü işleme teknikleri açısından, Tıbbi görüntüler sadece bir resimden ibaret değildir. Daha fazlasıdır, çünkü bu görüntüler veridir. Görüntüler yüksek boyutlu verilere dönüştürülerek, tıbbın karar desteğinde kullanılabilir. Görüntüler yüksek boyutlu verilere dönüştürülerek, tıbbın karar desteğinde kullanılabilir.

Derin öğrenmeyle birlikte yapay zekâ alanındaki çalışmalar özellik mühendisliğinden, model mühendisliğine dönüşmüştür. Daha önceki çalışmalarda araştırmacılar bir problemin çözümü için temsil kabiliyeti yüksek özellikler oluşturmaya yoğunlaşmıştır. Günümüzde donanımların işlem kapasitelerinin artması, araştırmacıların daha karmaşık modeller tasarlamasına imkân vermiştir.

Meme MRG görüntüleme için optimum bir sistem, tümörün biyolojik özellikleri farklılıkları yansıtsa bile iyi huylu ve habis tümörleri ayırt edebilmelidir. Bununla birlikte, bu lezyonların benzerliği nedeniyle, biyopsi yapmadan bunları doğru teşhis etmek her zaman mümkün değildir. Bu nedenle tez kapsamında, bilgisayar analiziyle invazif olmayan sistemle çeşitli boyutlardaki kitlelerin otomatik olarak karakterize edilmesi ve sınıflandırılması için bir modelin tasarlanması amaçlanmıştır.

Çalışmada, daha önce hiçbir çalışmada kullanılmamış, gerçek hastalardan alınan MR görüntülerinden oluşturulan veri seti kullanılmıştır. Önerilen model, MR görüntülerinden otomatik görsel özellikler oluşturmakta ve grafik işlemcisi kullanılarak 36 saniyede, karşılaşılmayan 60 tümör görüntüsünün 59'unu doğru sınıflandırmaktadır. Literatürde bildirildiği üzere MRG'nin okuma süresi uzman bir meme radyoloğu için 3-5 dakika iken, genel radyolog için bu süre 10-15 dakikaya ulaşmaktadır [112]. Bu bakımdan elde ettiğimiz sonuç çalışmamızın en önemli avantajlarından biridir ve bu nedenle klinik uygulamalarda kullanımı uygundur.

Kısaca, önerilen model, tümörün biyolojik bakımdan farklı özellikler yansıttığı durumlarda dahi, iyi huylu ve kötü huylu tümörleri ayırt edebilmesi açısından meme MRG görüntüleme için optimum bir sistemdir. Ayrıca, biyopsiye ihtiyaç duymadan

bilgisayar analizi ile çeşitli boyutlardaki kitleleri otomatik olarak karakterize ederek sınıflandırmaktadır.

Sonuç olarak % 98.33 oranında yüksek doğruluk derecesine sahip bir model geliştirilmiştir. Bu tez boyunca, MRG görüntülerini kullanarak lezyonları habis veya iyi huylu tümörler olarak karakterize etmek için, kullanıcıdan bağımsız, karar destek süreçlerinde zaman kazandıran yeni bir ESA modeli sunulmuştur. Doğruluk, hata oranı, hassasiyet, özgüllük ve hassasiyet gibi performans ölçütleri, ağın umut verici olduğunu göstermektedir. Yöntem klinik uygulamada kullanılabilir ve gereksiz biyopsileri önlenmesine yardımcı olmaktadır.



## KAYNAKÇA

- [1] V. Ozmen, Breast cancer in the world and Turkey. *J Breast Health*. 4 (2): 6-12, 2008.
- [2] S. Aydıntuğ, Meme kanserinde erken tanı. *Sted*. 13 (6): 226-228, 2004.
- [3] M. Gültekin, G. Boztaş, Türkiye kanser istatistikleri. Sağlık Bakanlığı, Türkiye Halk Sağlığı Kurumu. 43, 2014.
- [4] W. A. Berg, Benefits of screening mammography. *Jama*. 303 (2): 168-169, 2010.
- [5] B. Cady, J. S. Michaelson, The life-sparing potential of mammographic screening. *Cancer*. 91 (9): 1699-1703, 2001.
- [6] S. A. Feig, C. J. D'Orsi, R. E. Hendrick, V. P. Jackson, D. B. Kopans, B. Monsees, E. A. Sickles, C. B. Stelling, M. Zinninger, P. Wilcox-Buchalla, American College of Radiology guidelines for breast cancer screening. *AJR. American journal of roentgenology*. 171 (1): 29-33, 1998.
- [7] R. A. Smith, V. Cokkinides, H. J. Eyre, American Cancer Society guidelines for the early detection of cancer, 2003. *CA: a cancer journal for clinicians*. 53 (1): 27-43, 2003.
- [8] E. A. Sickles, Screening for breast cancer with mammography. *Clinical imaging*. 15 (4): 253-260, 1991.
- [9] D. Adler, M. Helvie, Mammographic biopsy recommendations. *Current Opinion in Radiology*. 4 (5): 123-129, 1992.
- [10] E. A. Sickles, Periodic mammographic follow-up of probably benign lesions: results in 3,184 consecutive cases. *Radiology*. 179 (2): 463-468, 1991.
- [11] J. L. Prince, J. M. Links, *Medical imaging signals and systems*. Pearson Prentice Hall Upper Saddle River, NJ, 2006.
- [12] D. S. Wollins, M. R. Somerfield, Q and A: Magnetic resonance imaging in the detection and evaluation of breast cancer. *Journal of oncology practice*. 4 (1): 18, 2008.
- [13] C. Kuhl, The current status of breast MR imaging part I. Choice of technique, image interpretation, diagnostic accuracy, and transfer to clinical practice. *Radiology*. 244 (2): 356-378, 2007.

- [14] L. Turnbull, S. Brown, I. Harvey, C. Olivier, P. Drew, V. Napp, A. Hanby, J. Brown, Comparative effectiveness of MRI in breast cancer (COMICE) trial: a randomised controlled trial. *The Lancet*. 375 (9714): 563-571, 2010.
- [15] M. Gity, A. Arabkheradmand, E. Taheri, M. Shakiba, Y. Khademi, B. Bijan, M. S. Sadaghiani, A. H. Jalali, Magnetic resonance imaging features of adenosis in the breast. *Journal of breast cancer*. 18 (2): 187-194, 2015.
- [16] A. Hamidinekoo, E. Denton, A. Rampun, K. Honnor, R. Zwiggelaar, Deep learning in mammography and breast histology, an overview and future trends. *Medical image analysis*. 47, 45-67, 2018.
- [17] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, Gradient-based learning applied to document recognition. *Proceedings of the IEEE*. 86 (11): 2278-2324, 1998.
- [18] M. Havaei, A. Davy, D. Warde-Farley, A. Biard, A. Courville, Y. Bengio, C. Pal, P. M. Jodoin, H. Larochelle, Brain tumor segmentation with deep neural networks. *Medical image analysis*. 35, 18-31, 2017.
- [19] H. R. Roth, A. Farag, L. Lu, E. B. Turkbey, R. M. Summers, Deep convolutional networks for pancreas segmentation in CT imaging. in *Medical Imaging 2015: Image Processing*, 2015, 9413: International Society for Optics and Photonics, s. 94131G.
- [20] J. Shin, N. Tajbakhsh, R. Todd Hurst, C. B. Kendall, J. Liang, Automating carotid intima-media thickness video interpretation with convolutional neural networks. in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, s. 2526-2535.
- [21] H.-C. Shin, H. R. Roth, M. Gao, L. Lu, Z. Xu, I. Nogues, J. Yao, D. Mollura, R. M. Summers, Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE transactions on medical imaging*. 35 (5): 1285-1298, 2016.
- [22] E. A. Sickles, C. J. D'Orsi, L. W. Bassett, C. M. Appleton, W. A. Berg, E. S. Burnside, *ACR BI-RADS® Atlas, Breast imaging reporting and data system*. Reston, VA: American College of Radiology. s. 39-48, 2013.
- [23] C. Spick, H. Bickel, S. H. Polanec, P. A. Baltzer, Breast lesions classified as probably benign (BI-RADS 3) on magnetic resonance imaging: a systematic review and meta-analysis. *European radiology*. 28 (5): 1919-1928, 2018.

- [24] A. T. Stavros, D. Thickman, C. L. Rapp, M. A. Dennis, S. H. Parker, G. A. Sisney, Solid breast nodules: use of sonography to distinguish between benign and malignant lesions. *Radiology*. 196 (1): 123-134, 1995.
- [25] Y. Liu, L. Nie, L. Han, L. Zhang, D. S. Rosenblum, Action2Activity: recognizing complex activities from sensor data. in *Twenty-fourth international joint conference on artificial intelligence*, 2015.
- [26] Y. Liu, L. Nie, L. Liu, D. S. Rosenblum, From action to activity: sensor-based activity recognition. *Neurocomputing*. 181, 108-115, 2016.
- [27] M. A. Wani, F. A. Bhat, S. Afzal, A. I. Khan, *Advances in Deep Learning*. Springer, 2019.
- [28] N. I. Yassin, S. Omran, E. M. El Houby, H. Allam, Machine learning techniques for breast cancer computer aided diagnosis using different image modalities: A systematic review. *Computer methods and programs in biomedicine*. 156, 25-45, 2018.
- [29] S. A. Waugh, C.A. Purdie, L. B. Jordan, S. Vinnicombe, R. A. Lerski, P. Martin, A. M. Thompson, Magnetic resonance imaging texture analysis classification of primary breast cancer. *European radiology*. 26 (2): 322-330, 2016.
- [30] A. Gubern-Mérida, R. Martí, J. Melendez, J. L. Hauth, R. M. Mann, N. Karssemeijer, B. Platel, Automated localization of breast cancer in DCE-MRI. *Medical image analysis*. 20 (1): 265-274, 2015.
- [31] H. Cai, L. Liu, Y. Peng, Y. Wu, L. Li, Diagnostic assessment by dynamic contrast-enhanced and diffusion-weighted magnetic resonance in differentiation of breast lesions under different imaging protocols. *BMC cancer*. 14 (1): 366, 2014.
- [32] W. A. Weiss, M. Medved, G. S. Karczmar, M. L. Giger, Residual analysis of the water resonance signal in breast lesions imaged with high spectral and spatial resolution (HiSS) MRI: a pilot study. *Medical physics*. 41 (1), 2014.
- [33] F. Retter, C. Plant, B. Burgeth, G. Botella, T. Schlossbauer, A. Meyer-Bäse, Computer-aided diagnosis for diagnostically challenging breast lesions in DCE-MRI based on image registration and integration of morphologic and dynamic characteristics. *EURASIP Journal on Advances in Signal Processing*. 2013 (1): 157, 2013.



- [34] J. Milenković, K. Hertl, A. Košir, J. Žibert, J. F. Tasič, Characterization of spatiotemporal changes for the classification of dynamic contrast-enhanced magnetic-resonance breast lesions. *Artificial intelligence in medicine*. 58 (2): 101-114, 2013.
- [35] A. E. Hassanien, T.-H. Kim, Breast cancer MRI diagnosis approach using support vector machine and pulse coupled neural networks. *Journal of Applied Logic*. 10 (4): 277-284, 2012.
- [36] A. H. Yurttakal, H. Erbay, T. İkizceli, S. Karaçavuş, G. Çınarer, A comparative study on segmentation and classification in breast mri imaging. *IIOAB JOURNAL*. 9 (5): 23-33, 2018.
- [37] F. Soares, F. Janela, M. Pereira, J. Seabra, M. M. Freire, Classification of breast masses on contrast-enhanced magnetic resonance images through log detrended fluctuation cumulant-based multifractal analysis. *IEEE Systems Journal*. 8 (3): 929-938, 2014.
- [38] C. Gallego-Ortiz, A. L. Martel, Improving the accuracy of computer-aided diagnosis for breast MR imaging by differentiating between mass and nonmass lesions. *Radiology*. 278 (3): 679-688, 2015.
- [39] Q. Yang, L. Li, J. Zhang, G. Shao, B. Zheng, A new quantitative image analysis method for improving breast cancer diagnosis using DCE-MRI examinations. *Medical physics*. 42 (1): 103-109, 2015.
- [40] N. Bhooshan, M. Giger, M. Medved, H. Li, A. Wood, Y. Yuan, L. Lan, A. Marquez, G. Karczmar, G. Newstead, Potential of computer-aided diagnosis of high spectral and spatial resolution (HiSS) MRI in the classification of breast lesions. *Journal of Magnetic Resonance Imaging*. 39 (1): 59-67, 2014.
- [41] S. C. Agner, M. A. Rosen, S. Englander, J. E. Tomaszewski, M. D. Feldman, P. Zhang, C. Mies, M. D. Schnall, A. Madabhushi, Computerized image analysis for identifying triple-negative breast cancers and differentiating them from other molecular subtypes of breast cancer on dynamic contrast-enhanced MR images: a feasibility study. *Radiology*. 272 (1): 91-99, 2014.
- [42] A. H. Yurttakal, H. Erbay, T. İkizceli, S. Karaçavuş, G. Çınarer, 3D Mass Visualization of Thyroid CT Images thru Marching Cubes Method. *Electronic Letters on Science&Engineering*. 14 (3): 20-26, 2018.

- [43] N. Dhungel, G. Carneiro, A. P. Bradley, Automated mass detection in mammograms using cascaded deep learning and random forests. in 2015 international conference on digital image computing: techniques and applications (DICTA), 2015: IEEE, s. 1-8.
- [44] P. Fonseca, J. Mendoza, J. Wainer, J. Ferrer, J. Pinto, J. Guerrero, B. Castaneda, Automatic breast density classification using a convolutional neural network architecture search procedure. in Medical Imaging 2015: Computer-Aided Diagnosis, 2015, 9414: International Society for Optics and Photonics, s. 941428.
- [45] R. K. Samala, H. P. Chan, L. M. Hadjiiski, K. Cha, M. A. Helvie, Deep-learning convolution neural network for computer-aided detection of microcalcifications in digital breast tomosynthesis. in Medical Imaging 2016: Computer-Aided Diagnosis, 2016, 9785: International Society for Optics and Photonics, s. 97850Y.
- [46] B. Q. Huynh, H. Li, M. L. Giger, Digital mammographic tumor classification using transfer learning from deep convolutional neural networks. *Journal of Medical Imaging*. 3 (3): 034501, 2016.
- [47] G. Carneiro, J. Nascimento, A. P. Bradley, Unregistered multiview mammogram analysis with pre-trained deep learning models. in International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: Springer, s. 652-660.
- [48] D. Lévy, A. Jain, Breast mass classification from mammograms using deep convolutional neural networks. arXiv preprint arXiv:1612.00542, 2016.
- [49] X. Xu, L. Fu, Y. Chen, R. Larsson, D. Zhang, S. Suo, J. Hua, J. Zhao, Breast Region Segmentation using Convolutional Neural Network in Dynamic Contrast Enhanced MRI. in 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2018: IEEE, s. 750-753.
- [50] Z. Jiao, X. Gao, Y. Wang, J. Li, A deep feature based framework for breast masses classification. *Neurocomputing*. 197, 221-231, 2016.
- [51] R. Rasti, M. Teshnehlab, S. L. Phung, Breast cancer diagnosis in DCE-MRI using mixture ensemble of convolutional neural networks. *Pattern Recognition*. 72, 381-390, 2017.

- [52] A. H. Yurttakal, H. Erbay, T. İkizceli, S. Karaçavuş, Detection of breast cancer via deep convolution neural networks using MRI images. *Multimedia Tools and Applications*. s. 1-19, 2019.
- [53] E. Öztürk, Meme Sağlığı. <http://www.drerkanozturk.com/meme-hastaliklari/meme-sagligi/meme-yapisi/> (Erişim tarihi: 23.05.2019)
- [54] E. R. Sauter, M. B. Daly, Breast cancer risk reduction and early detection. Springer, 2010.
- [55] V. Özmen, Activities of turkish federation of breast disease societies. *Eur J Breast Health*. 6 (2): 43-44, 2010.
- [56] A. Aydiner, A. İğci, A. Soran, Breast Cancer: A Guide to Clinical Practice. Springer, 2018.
- [57] M. Guray, A. A. Sahin, Benign breast diseases: classification, diagnosis, and management. *The oncologist*. 11 (5): 435-449, 2006.
- [58] C. C. Compton, D. R. Byrd, J. Garcia-Aguilar, S. H. Kurtzman, A. Olawaiye, M. K. Washington, AJCC cancer staging atlas: a companion to the seventh editions of the AJCC cancer staging manual and handbook. Springer Science & Business Media, 2012.
- [59] M. H. Asyalı, S. Kara, B. Yılmaz, Biyomedikal Mühendisliğinin Temelleri. Nobel Akademik Yayıncılık, 2014.
- [60] M. V. Prummel, D. Muradali, R. Shumak, V. Majpruz, P. Brown, H. Jiang, S. J. Done, M. J. Yaffe, A. M. Chiarelli, Digital compared with screen-film mammography: measures of diagnostic accuracy among women screened in the Ontario breast screening program. *Radiology*. 278 (2): 365-373, 2015.
- [61] F. Sardanelli, H. S. Aase, M. Álvarez, E. Azavedo, H. J. Baarslag, C. Balleyguier, P. A. Baltzer, V. Beslagic, U. Bick, D. Bogdanovic-Stojanovic, Position paper on screening for breast cancer by the European Society of Breast Imaging (EUSOBI) and 30 national breast radiology bodies from Austria, Belgium, Bosnia and Herzegovina, Bulgaria, Croatia, Czech Republic, Denmark, Estonia, Finland, France, Germany, Greece, Hungary, Iceland, Ireland, Italy, Israel, Lithuania, Moldova, The Netherlands, Norway, Poland, Portugal, Romania, Serbia, Slovakia, Spain, Sweden, Switzerland and Turkey. *European radiology*. 27 (7): 2737-2743, 2017.

- [62] A. M. Bluekens, R. Holland, N. Karssemeijer, M. J. Broeders, G. J. den Heeten, Comparison of digital screening mammography and screen-film mammography in the early detection of clinically relevant cancers: a multicenter study. *Radiology*. 265 (3): 707-714, 2012.
- [63] R. E. Hendrick, E. D. Pisano, A. Averbukh, C. Moran, E. A. Berns, M. J. Yaffe, B. Herman, S. Acharyya, C. Gatsonis, Comparison of acquisition parameters and breast dose in digital mammography and screen-film mammography in the American College of Radiology Imaging Network digital mammographic imaging screening trial. *American journal of roentgenology*. 194 (2): 362-369, 2010.
- [64] A. B. de Gonzalez, S. Darby, Risk of cancer from diagnostic X-rays: estimates for the UK and 14 other countries. *The lancet*. 363 (9406): 345-351, 2004.
- [65] A. Malich, T. Boehm, M. Facius, M. G. Freesmeyer, M. Fleck, R. Anderson, W. A. Kaiser, Differentiation of mammographically suspicious lesions: evaluation of breast ultrasound, MRI mammography and electrical impedance scanning as adjunctive technologies in breast cancer detection. *Clinical radiology*. 56 (4): 278-283, 2001.
- [66] R. E. Hendrick, *Breast MRI: fundamentals and technical aspects*. Springer Science & Business Media, 2007.
- [67] A. Jackson, D. L. Buckley, G. J. Parker, *Dynamic contrast-enhanced magnetic resonance imaging in oncology*. Springer, 2005.
- [68] C. L. Dym, R. E. Levitt, *Knowledge-based systems in engineering*. McGraw-Hill Book Company, 1991.
- [69] I. Goodfellow, Y. Bengio, A. Courville, *Deep learning*. MIT press, 2016.
- [70] J. F. Wiley, *R Deep Learning Essentials*. Packt Publishing Ltd, 2016.
- [71] W. Di, A. Bhardwaj, J. Wei, *Deep Learning Essentials: Your hands-on guide to the fundamentals of deep learning and neural network modeling*. Packt Publishing, 2018.
- [72] V. Zocca, G. Spacagna, D. Slater, P. Roelants, *Python Deep Learning*. Packt Publishing Ltd, 2017.
- [73] R. Salakhutdinov, G. Hinton, Deep boltzmann machines. in *Artificial intelligence and statistics*, 2009, s 448-455.

- [74] G. E. Hinton, A practical guide to training restricted Boltzmann machines. in Neural networks: Tricks of the trade: Springer, 2012, s 599-619.
- [75] G. E. Hinton, S. Osindero, Y. W. Teh, A fast learning algorithm for deep belief nets. Neural computation. 18 (7): 1527-1554, 2006.
- [76] C. Olah, Understanding lstm networks. <http://colah.github.io/posts/2015-08-Understanding-LSTMs> (Erişim tarihi: 23.05.2019)
- [77] Y. LeCun, Y. Bengio, G. Hinton, Deep learning. Nature. 521 (7553): 436, 2015.
- [78] H. Akpınar, Data: veri madenciliği veri analizi. Papatya Yayıncılık Eğitim, 2014.
- [79] F. F. Li, A. Karpathy, J. Johnson, CS231n: Convolutional neural networks for visual recognition. University Lecture. <http://cs231n.stanford.edu> (Erişim tarihi: 23.05.2019)
- [80] F. Chollet, Deep learning with Python. Manning Publications, 2018.
- [81] R. Shanmugamani, Deep Learning for Computer Vision: Expert techniques to train advanced neural networks using TensorFlow and Keras. Packt Publishing Ltd, 2018.
- [82] B. Raj, Data Augmentation | How to use Deep Learning when you have Limited Data - Part 2. <https://medium.com/nanonets/how-to-use-deep-learning-when-you-have-limited-data-part-2-data-augmentation-c26971dc8ced> (Erişim tarihi: 22.04.2019).
- [83] V. Dumoulin, F. Visin, A guide to convolution arithmetic for deep learning. arXiv preprint arXiv:1603.07285, 2016.
- [84] S. Sahoo, Deciding optimal kernel size for CNN. <https://towardsdatascience.com/deciding-optimal-filter-size-for-cnns-d6f7b56f9363> (Erişim tarihi: 20.04.2019).
- [85] S. Ioffe, C. Szegedy, Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv preprint arXiv:1502.03167, 2015.
- [86] M. H. Beale, M. T. Hagan, H. B. Demuth, Neural network toolbox user's guide. The MathWorks Inc, 2017.
- [87] E. Öztemel, Yapay sinir ağları. Papatya Yayıncılık, İstanbul, 2003.

- [88] V. Avinash Sharma, Understanding activation functions in neural networks. <https://medium.com/the-theory-of-everything/understanding-activation-functions-in-neural-networks-9491262884e0> (Erişim tarihi: 21.05.2019).
- [89] S. Sharma, Activation functions: Neural networks. <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6> (Erişim tarihi: 22.05.2019).
- [90] A. S. Walia, Activation functions and it's types-Which is better?. <https://towardsdatascience.com/activation-functions-and-its-types-which-is-better-a9a5310cc8f> (Erişim tarihi: 20.05.2019).
- [91] S. Polamuri, Difference between softmax function and sigmoid function. <http://dataaspirant.com/2017/03/07/difference-between-softmax-function-and-sigmoid-function/> (Erişim tarihi: 19.05.2019).
- [92] V. Nair, G. E. Hinton, Rectified linear units improve restricted boltzmann machines. in Proceedings of the 27th international conference on machine learning (ICML-10), 2010, s 807-814.
- [93] A. L. Maas, A. Y. Hannun, A. Y. Ng, Rectifier nonlinearities improve neural network acoustic models. in Proc. icml, 2013, 30 (1):3.
- [94] L. Dan-Ching, A Practical Guide to ReLU. <https://medium.com/tiny-mind/a-practical-guide-to-relu-b83ca804f1f7> (Erişim tarihi: 19.05.2019).
- [95] D. A. Clevert, T. Unterthiner, S. Hochreiter, Fast and accurate deep network learning by exponential linear units (elus). arXiv preprint arXiv:1511.07289, 2015.
- [96] J. Nagi, F. Ducatelle, G. A. Di Caro, D. Cireşan, U. Meier, A. Giusti, F. Nagi, J. Schmidhuber, L. M. Gambardella, Max-pooling convolutional neural networks for vision-based hand gesture recognition. in 2011 IEEE International Conference on Signal and Image Processing Applications (ICSIPA), 2011: IEEE, s. 342-347.
- [97] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, Dropout: a simple way to prevent neural networks from overfitting. The Journal of Machine Learning Research. 15 (1): 1929-1958, 2014.
- [98] S. Yadav, Weight Initialization Techniques in Neural Networks. <https://towardsdatascience.com/weight-initialization-techniques-in-neural-networks-26c649eb3b78> (Erişim tarihi: 18.05.2019).

- [99] R. Pascanu, T. Mikolov, Y. Bengio, On the difficulty of training recurrent neural networks. in International conference on machine learning, 2013, s. 1310-1318.
- [100] X. Glorot, Y. Bengio, Understanding the difficulty of training deep feedforward neural networks. in Proceedings of the thirteenth international conference on artificial intelligence and statistics, 2010, s. 249-256.
- [101] K. He, X. Zhang, S. Ren, J. Sun, Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. in Proceedings of the IEEE international conference on computer vision, 2015, s. 1026-1034.
- [102] J. Moolayil, Deep Neural Networks for Supervised Learning: Classification. in Learn Keras for Deep Neural Networks: Springer, 2019, s. 101-135.
- [103] C. M. Bishop, Pattern recognition and machine learning. Springer, 2006.
- [104] B. Moons, D. Bankman, M. Verhelst, Embedded Deep Neural Networks. in Embedded Deep Learning: Springer, 2019, s. 1-31.
- [105] K. P. Murphy, Machine learning: a probabilistic perspective. MIT press, 2012.
- [106] D. P. Kingma, J. Ba, Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.
- [107] Y. Özkan, Veri madenciliği yöntemleri. Papatya Yayıncılık Eğitim, 2008.
- [108] C. Sammut, G. I. Webb, Encyclopedia of machine learning and data mining. Springer Publishing Company, Incorporated, 2017.
- [109] B. W. Matthews, Comparison of the predicted and observed secondary structure of T4 phage lysozyme. Biochimica et Biophysica Acta (BBA)-Protein Structure, 405 (2): 442-451, 1975.
- [110] D. M. Powers, Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. Bioinfo Publications, 2011.
- [111] A. Krizhevsky, I. Sutskever, G. E. Hinton, Imagenet classification with deep convolutional neural networks. in Advances in neural information processing systems, 2012, s. 1097-1105.
- [112] C. K. Kuhl, S. Schradig, K. Strobel, H. H. Schild, R.-D. Hilgers, H. B. Bieling, Abbreviated breast magnetic resonance imaging (MRI): first postcontrast subtracted images and maximum-intensity projection - a novel

approach to breast cancer screening with MRI. *Journal of Clinical Oncology*.  
32 (22): 2304-2310, 2014.





## EKLER

### EK 1: Kırıkkale Üniversitesi Tıp Fakültesi Dekanlığından Alınan Etik Kurul Raporu


**KIRIKKALE ÜNİVERSİTESİ**  
**GİRİŞİMSEL OLMAYAN ARAŞTIRMALAR ETİK KURUL KARARI**

**Toplantı Tarihi:** 12.09.2018  
**Toplantı Sayısı:** 18/6  
**Karar No:** 2018.08.02

Üniversitemiz Girişimsel Olmayan Araştırmalar Etik Kurulu 12.09.2018 Çarşamba günü saat 10:00'da Prof.Dr. Berkant ÖZPOLAT başkanlığında toplanarak gündemdeki Kırıkkale Üniversitesi Tıp Fakültesi, Bozok Üniversitesi TBMYO Öğr. Gör. Ahmet Haşim YURTTAKAL'ın "Göğüs MR Görüntülerinde Görüntü İşleme Ve Derin Öğrenme Uygulamaları" isimli başvurusunu görüştü.

**KARAR:**

Kırıkkale Üniversitesi Tıp Fakültesi, Bozok Üniversitesi TBMYO Öğr. Gör. Ahmet Haşim YURTTAKAL'ın "Göğüs MR Görüntülerinde Görüntü İşleme Ve Derin Öğrenme Uygulamaları" isimli başvurusu Kırıkkale Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu Yönergesinde belirtilmiş olan Etik İlkelerine uygun bulunmuştur.

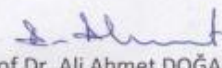
  
Prof.Dr. Berkant ÖZPOLAT  
Başkan

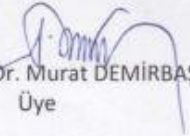
Prof.Dr. Hakan BOYUNAĞA  
(Katılmadı) Başkan Vekili


Prof.Dr. Arzu DAŞKAPAN  
(Katılmadı) Üye

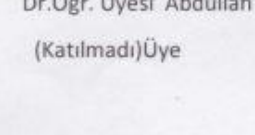
Prof.Dr. Teoman Zafer APAN  
Üye

Dr. Öğr. Üyesi Mehmet Zahit ADIŞEN  
Üye

  
Prof.Dr. Ali Ahmet DOĞAN  
Üye

  
Prof.Dr. Murat DEMİRBAŞ  
Üye

  
Dr. Öğr. Üyesi Oktay AYDIN  
Üye

  
Dr. Öğr. Üyesi Abdullah YILMAZ  
(Katılmadı) Üye

## ÖZGEÇMİŞ

Adı Soyadı :Ahmet Haşim YURTTAKAL  
Doğum Tarihi :26.02.1986  
Yabancı Dil :İngilizce

### Eğitim Durumu (Kurum ve Yıl):

Lisans : Süleyman Demirel Üniversitesi-2008  
Yüksek Lisans : Selçuk Üniversitesi-2014

### Çalıştığı Kurum/Kurumlar ve Yıl/Yıllar:

Artvin Çoruh Üniversitesi 2010-2012  
Bozok Üniversitesi 2012-Devam ediyor

### Yayınları (SCI-ESCI):

1. A. H. Yurttakal , H. Erbay, T. İkizceli, S. Karaçavuş. Detection of breast cancer via deep convolution neural networks using MRI images, Multimedia Tools And Applications, 2019. (Taranan index: Thomson SCIE)
2. A. H. Yurttakal , H. Erbay, T. İkizceli, S. Karaçavuş, G. Çınarer. A Comparative Study On Segmentation And Classification In Breast Mri Imaging, The IIOAB Journal, 2018. (Taranan index: Thomson ESCI).

### Yayınları (Diğer) :

1. A. H. Yurttakal , H. Erbay, T. İkizceli, S. Karaçavuş, G. Çınarer. 3D Mass Visualization of Thyroid CT Images thru Marching Cubes Method, Electronic Letters on Science&Engineering, 2018

### Araştırma Alanları :

Görüntü İşleme, Derin Öğrenme, Makine Öğrenmesi