

T.C.  
İSTANBUL AYDIN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**DERİN ÖĞRENME VE DALGACIK DÖNÜŞÜMÜNE DAYALI AKCİĞER  
KANSERİ ERKEN TANISINDA BELİRSİZLİK ÖLÇEĞİNİN  
SAPTANMASI**

**DOKTORA TEZİ**

**Mehmet Akif ÇİFÇİ**

**Bilgisayar Mühendisliği Ana Bilim Dalı  
Bilgisayar Mühendisliği Bilim Dalı**

**Ekim, 2021**



T.C.  
İSTANBUL AYDIN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**DERİN ÖĞRENME VE DALGACIK DÖNÜŞÜMÜNE DAYALI AKCİĞER  
KANSERİ ERKEN TANISINDA BELİRSİZLİK ÖLÇEĞİNİN  
SAPTANMASI**

**DOKTORA TEZİ**

**Mehmet Akif ÇİFÇİ  
(Y1615.610010)**

**Bilgisayar Mühendisliği Ana Bilim Dalı  
Bilgisayar Mühendisliği Bilim Dalı**

**Tez Danışmanı: Prof. Dr. Zafer ASLAN**

**Ekim, 2021**



## ONAY FORMU



## **YEMİN METNİ**

Doktora tezi olarak sunduđum “Derin Öğrenme ve Dalgacık Dönüşümüne Dayalı Akciđer Kanseri Erken Tanısında Belirsizlik Ölçeđinin Saptanması” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’ da gösterilenlerden oluştuđunu, bunlara atıf yapılarak yararlanılmış olduđunu belirtir ve onurumla beyan ederim. (20/10/2021)

**Mehmet Akif ÇİFÇİ**





*sevgili Aleda'ya ithafen,*



## **ÖNSÖZ**

Bu tez çalışmasındaki paha biçilmez rehberliği ve destekleri ile eğitimime olan katkılarından ötürü Prof. Dr. Zafer Aslan'a teşekkür etmek istiyorum. Bu tezin hazırlanması boyunca yaptıkları çok değerli yorum ve geri bildirimler için Prof. Dr. Ali GÜNEŞ ve Doç. Dr. Metin ZONTUL'a teşekkür etmek istiyorum. Akciğer kanseri Hastalığı üzerine bilgi paylaşımında bulunan ve tez çalışmamda desteklerini esirgemeyen çok değerli hocam Prof. Dr. AHMET İLVAN'a teşekkür etmek istiyorum.

Jüri üyesi olan sayın hocalarıma teşekkürlerimi sunuyorum.

**Ekim, 2021**

**Mehmet Akif CİFCİ**



## İÇİNDEKİLER

### Sayfa

ÖNSÖZ.....	v
İÇİNDEKİLER .....	vii
KISALTMALAR .....	ix
ÇİZELGE LİSTESİ.....	xi
ŞEKİL LİSTESİ.....	xiii
ÖZET.....	xvii
ABSTRACT.....	xix
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1 Problemin Tanımı ve Yaklaşımı .....	1
1.2 Tezin Amacı ve Yaklaşımı .....	11
1.3 Çalışmada Karşılaşılan Zorluklar .....	12
1.4 Tez Düzeni .....	14
<b>2. GENEL BİLGİLER.....</b>	<b>17</b>
<b>3. VERİ VE YÖNTEM .....</b>	<b>23</b>
3.1 Deneylerde Kullanılan Veri Kümeleri ve Yönetimi.....	23
3.2 Deneylerde Kullanılan Araçlar.....	27
3.2.1 Makine öğrenimi .....	27
3.2.2 Derin öğrenme.....	30
3.2.3 Sinir ağı .....	31
3.2.4 Eniyileme türleri: .....	50
3.3 Evrişimli Sinir Ağları .....	61
3.3.1 ESA Mimarisi .....	62
3.3.2 Evrişim Katmanı .....	63
3.3.3 Havuzlama Katmanı.....	69
3.3.4 Tam Bağlı Katman .....	70
3.3.5 Hiper Parametreler .....	71
3.3.6 Paket Normalizasyonu .....	73
3.3.7 Paket Normalizasyon İşleminin Avantajları .....	76
3.4 Geleneksel Evrişimli Sinir Ağları .....	76
3.4.1 AlexNet Ağı .....	76
3.4.2 VGG16 Ağı .....	77
3.4.3 Inception v3 Ağı.....	79
3.4.4 ResNet50 Ağı.....	80
3.5 Performans Metrikleri .....	82
<b>4. MODEL ÇALIŞMALARINA YÖNELİK GÖRÜNTÜ İŞLEM SÜRECİ.....</b>	<b>87</b>
4.1 Dalgacık Dönüşümü .....	87
4.1.1 Sürekli Dalgacık Dönüşümü .....	91
4.1.2 İki Boyutlu Sürekli Dalgacık Dönüşümü .....	92
4.1.3 Ayrık Dalgacık Dönüşümü .....	93
4.1.4 Haar Dalgacığı .....	95

4.2 Görüntü Ön İşleme .....	98
<b>5. UYGULAMA VE ANALİZ.....</b>	<b>115</b>
5.1 Geleneksel Derin Öğrenme Algoritmalarının Uygulanması .....	116
5.1.1 ResNet50 Ağı .....	117
5.1.2 Inception v3 .....	121
5.1.3 VGG16 Ağı .....	123
5.1.4 AlexNet .....	126
5.2 Yenilikçi Derin Öğrenme Algoritmasının Uygulanması.....	129
5.2.1 4K-ESA Uygulanan Monte Carlo Seyreltme .....	134
5.2.2 4K-ESA Modelinde Belirsizlik (Uncertainty of 4K-CNN Model) .....	138
5.3 Model Sonuçlarının Başarı Değerlendirmesi .....	147
5.4 Belirsizliğe Duyarlı Akciğer Kanseri Sınıflandırması ve Yönlendirme Yoluyla Performans Artışı.....	147
5.5 Belirsizliği ve Yorumlanabilirliği Görselleştirme .....	148
5.6 Deney sonucu ve karşılaştırma .....	148
<b>6. SONUÇLAR VE TARTIŞMA .....</b>	<b>153</b>
<b>KAYNAKLAR.....</b>	<b>159</b>
<b>EKLER.....</b>	<b>165</b>
<b>ÖZGEÇMİŞ.....</b>	<b>187</b>

## KISALTMALAR

<b>ADD</b>	: Ayrık Dalgacık Dönüşümü
<b>AGF</b>	: Alçak Geçiren Filtre
<b>BCM</b>	: Bulanık C-Ortalama
<b>BCM</b>	: Bulanık C-Ortalama
<b>BDT</b>	: Bilgisayar Destekli Tanı
<b>PED</b>	: Paket Eğim Düşümü (BGD)
<b>BT</b>	: Bilgisayarlı Tomografi
<b>BTA</b>	: Basit Tekrarlayan Ağ
<b>Db2</b>	: Daubechies2 Dalgacığı
<b>DD</b>	: Dalgacık Dönüşümü
<b>DDA</b>	: Doğrusal Diskriminant Analiz
<b>DE</b>	: Diferansiyel Evrim
<b>DICOM</b>	: Tıpta Dijital Görüntüleme ve İletişim
<b>DİA</b>	: Derin İnanç Ağı
<b>DN</b>	: Doğru Negatif
<b>DOK</b>	: Derin/Yığılanmış Oto-kodlayıcı
<b>DP</b>	: Doğru Pozitif
<b>DRM</b>	: Deneysel Risk Minimizasyonu (Empirical Risk Minimization)
<b>DSA</b>	: Derin Sinir Ağı
<b>DVM</b>	: Destek Vektör Makineleri
<b>ESA</b>	: Evrimsel Sinir Ağı
<b>FD</b>	: Fourier Dönüşümü
<b>GPU</b>	: Grafik İşlem Birimi
<b>GPU</b>	: Grafik İşlemci Birimi
<b>HSA</b>	: Hopfield Sinir Ağı
<b>HSA</b>	: Hopfield Sinir Ağı
<b>HU</b>	: Hounsfield Ünitesi
<b>IA</b>	: İlgili Alanı (Region of Interest)
<b>KAM</b>	: Kanser Arşiv Merkezinden
<b>KZFD</b>	: Kısa Zamanlı Fourier Dönüşümü
<b>KZFD</b>	: Kısa Zamanlı Fourier Dönüşümü
<b>LSTM</b>	: Kısa Uzun Vadeli Hafıza Ağı
<b>MLP</b>	: Çok katmanlı algılayıcı (Multilayer Perceptron)
<b>MÖ</b>	: Makine Öğrenimi
<b>MR</b>	: Manyetik Rezonans Görüntüleme
<b>mRMR</b>	: Asgari Artıklık Azami İlişkisellik
<b>MSE</b>	: Ortalama karesel hata (Mean squared error)
<b>NB</b>	: Naive Bayes
<b>OK</b>	: Oto-kodlayıcı
<b>PET</b>	: Pozitron Emisyon Tomografisi
<b>PN</b>	: Pulmoner Nodül
<b>PSE</b>	: Parçacık Sürü Eniyilemesi

<b>RBF</b>	: Radyal Tabanlı Fonksiyon
<b>RBM</b>	: Kısıtlandırılmış Boltzmann Makinesi
<b>RMSE</b>	: Ortalama Kare hata Kökü (Root mean squared error)
<b>OED</b>	: Olasılıksal Eğitim Düşümü (SGD)
<b>TBA</b>	: Temel Bileşen Analizi
<b>TÖ</b>	: Takviyeli Öğrenim
<b>TSA</b>	: Tekrarlayan Sinir Ağı
<b>YGF</b>	: Yüksek Geçiren Filtre
<b>YN</b>	: Yanlış Negatif
<b>YP</b>	: Yanlış Pozitif
<b>YPK</b>	: Yapay Arı Kolonisi
<b>YRM</b>	: Yapısal Risk Minimizasyonu (Structural risk minimization)
<b>YSA</b>	: Yapay Sinir Ağı
<b>YZ</b>	: Yapay Zekâ
$\bar{Y}$	: Yeni test girdileri için tahmin edilen etiket
$n_x$	: Her bir eğitim örneği için özniteliklerin sayısı
$\bar{y}$	: Bir eğitim örneğinin tahmini çıkış etiketi
$\mu$	: Ortalama
$c$	: Küme merkezleri
$d$	: Uzaklık (birim)
$f$	: Örnekleme aralığı
$h$	: Hausdorff uzaklığı (birim)
$T$	: Esik değeri
$A$	: $Z$ 'nin doğrusal olmayan dönüşümü, aktivasyon fonksiyonu çıkışı
$C$	: Çoklu sınıflayıcı için sınıf sayısı
$J$	: Tüm eğitim örnekleri
$L$	: Derin sinir ağındaki toplam katman sayısı (giriş katmanı hariç)
$Y$	: Çıkış matrisi: her bir sütun $X$ eğitim setinin etiketi olarak tanımlanır.
$Z$	: $X$ 'in doğrusal dönüşümü
$a$	: $Z$ 'nin doğrusal olmayan dönüşümü, aktivasyon fonksiyonu çıkışı
$b$	: Bias matrisi
$m$	: Eğitim örneklerinin sayısı
$w$	: $X$ için ağırlık matrisi
$x$	: Eğitim örneğinin öznitelikleri
$y$	: Eğitim örneğinin çıkış etiketi
$z$	: $X$ 'in doğrusal dönüşümü
$X$	: Giriş matrisi: her sütun bir eğitim örneği
$\Psi$	: Ana dalgacık fonksiyonunun Fourier dönüşümü
$\sigma$	: Sigmoid fonksiyonu
$\psi$	: Ana dalgacık fonksiyonu
$\omega(t)$	: Anlık frekans



## ÇİZELGE LİSTESİ

### Sayfa

Çizelge 3.1: Veri kümesinin özellikleri .....	24
Çizelge 3.2: Çok katmanlı algılayıcı eğitim algoritması .....	37
Çizelge 3.3: Aktivasyon fonksiyonları .....	49
Çizelge 3.4: Eğitim düşümü algoritmaları .....	53
Çizelge 3.5: Nesterov hızlandırılmış eğitim algoritması (62).....	55
Çizelge 3.6: Düzenleştirme algoritmaları.....	60
Çizelge 3.7: Evrişim katmanı parametreleri ve fonksiyonları.....	67
Çizelge 3.8: Derin öğrenme akciğer kanseri tespitinde kullanılan metrikler .....	82
Çizelge 3.9: Performans ölçümü parametreleri .....	83
Çizelge 4.1: Başlıca dalgacık türleri.....	89
Çizelge 4.2: Dalgacık Dönümünün başlıca uygulama alanları.....	90
Çizelge 4.3: Watershed yapılırken uyulması gereken kurallar .....	111
Çizelge 5.1: Temel Bileşen Analizi temel amaçları .....	116
Çizelge 5.2: ResNet50 model Sonuçları.....	119
Çizelge 5.3: Inception v3 model sonuçları .....	122
Çizelge 5.4: VGG16 model Sonuçları.....	125
Çizelge 5.5: AlexNet model Sonuçları .....	128
Çizelge 5.6: 4K-ESA modelinin sonuçları .....	135
Çizelge 5.7: Belirsizlik ve tahmini doğruluk arasındaki ilişki .....	141
Çizelge 5.8: Belirsizlik (Bayesian) olmadan elde edilen sonuçlar .....	149
Çizelge 5.9: Belirsizlik (Bayesian) ile elde edilen sonuçlar .....	150
Çizelge 5.10: Kullanılan modellerin özellikleri.....	150
Çizelge A.1: Deneylerde kullanılan fonksiyon öğrenme algoritmaları .....	167
Çizelge A.2: Yoğunluğa dayalı kümeleme algoritması.....	167
Çizelge A.3: 2B ADD' de kullanılan dalgacıklar .....	171
Çizelge A.4: Geleneksel modellerin karşılaştırılması .....	171
Çizelge A.5: Hata matrisi gösterimi .....	171
Çizelge B.1: Hounsfield üniteleri ve anlamları.....	179
Çizelge B.2: ESA mimarisi kod parçacıkları.....	179
Çizelge B.3: ESA mimarisi kod parçacıkları.....	180
Çizelge B.4: ESA mimarisi kod parçacıkları.....	181
Çizelge B.5: ESA mimarisi kod parçacıkları.....	181
Çizelge C.1: Çalışılan geleneksel model özeti .....	183
Çizelge C.2: Çalışılan geleneksel model özeti .....	183
Çizelge C.3: Çalışılan geleneksel model özeti .....	183
Çizelge C.4: Çalışılan geleneksel model özeti .....	184
Çizelge C.5: Inception v3 alt ağlarındaki parametre sayısı .....	184
Çizelge C.6: ResNet50 ile yapılan 85 devirli bir deney .....	185
Çizelge C.7: ResNet50 ile yapılan 85 devirli bir deney .....	185
Çizelge C.8: ResNet50 ile yapılan 85 devirli bir deney .....	186



## ŞEKİL LİSTESİ

### Sayfa

Şekil 1.1: Alkol, sigara, yaş, genetik faktörlerden kaynaklı akciğer kanseri grafiği ...	3
Şekil 1.2: a) Akciğer kanseri nodülü görüntüsü, b) Sağlıklı akciğer BT görüntüsü....	4
Şekil 1.3: Bilgisayarlı Tomografi görüntüleme cihazı .....	7
Şekil 1.4: Hounsfield skalası .....	8
Şekil 1.5: DICOM formatlı görüntü özellikleri .....	9
Şekil 1.6: Kanser arşiv merkezinden alınan veri kümesi.....	13
Şekil 3.1: a) Kötü huylu, b) İyi huylu, c) Nodül yok, d) Sağlıklı görüntüsü.....	24
Şekil 3.2: KAM'da yer alan aynı BT taramasından elde edilen farklı sonuçlar.....	24
Şekil 3.3: Çapı 2 cm'den küçük BT taramaları.....	26
Şekil 3.4: Nodül olarak kabul görmeyen BT taramaları.....	26
Şekil 3.5: Benign, malignite ve sağlıklı BT verisinin korelasyonu .....	27
Şekil 3.6: Bir sinir hücresi yapısı.....	32
Şekil 3.7: Basit algılayıcının yapısı .....	33
Şekil 3.8: Çok katmanlı ağ yapısı .....	36
Şekil 3.9: Artan epok ile test ve eğitim doğruluğu arasındaki ilişki.....	38
Şekil 3.10: a) Standart sinir ağı, b) Seyreltme uygulanmış sinir ağı .....	40
Şekil 3.11: İleri yönde yayılım modeli .....	41
Şekil 3.12: Bir ağın BT görüntüsüne bağlı olarak bir sonuç üretmesi.....	46
Şekil 3.13: Öğrenme katsayısı ile yineleme arasındaki korelasyon .....	48
Şekil 3.14: a) Batch ve b) Mini-batch'in uygulandığı durumda hata değeri değişimi	52
Şekil 3.15: Momentum ile olasılıksal eğim düşümü .....	54
Şekil 3.16: a) Momentum tabanlı hızlandırılmış eğim, b) Nesterov tabanlı hızlandırılmış eğim karşılaştırılması .....	56
Şekil 3.17: Epok sayısı eğitim hatası ve doğru tahmin grafiği .....	59
Şekil 3.18: Evrişimli sinir ağı mimarisi grafiği .....	62
Şekil 3.19: Evrişim uygulanışı.....	64
Şekil 3.20: Evrişimli sinir ağına girdi ve çekirdek temsili gösterim .....	65
Şekil 3.21: Dolgu değerleri ve sıfır ile doldurulmuş filtre.....	68
Şekil 3.22: Maksimum ve ortalama havuzlama katmanı.....	69
Şekil 3.23: Tam Bağlı Katman .....	71
Şekil 3.24: Dolgusu olan ve olmayan ESA .....	73
Şekil 3.25: Paket normalizasyonu gösterimi .....	74
Şekil 3.26: Normalize edilmiş veri .....	74
Şekil 3.27: ESA mimarisinde detaylı paket normalizasyon işlemi.....	75
Şekil 3.28: AlexNet ağı mimari yapısı .....	76
Şekil 3.29: VGG16 ağı mimari yapısı .....	78
Şekil 3.30: Inception v3 mimari yapısı.....	80
Şekil 3.31: Kalıntı (Residual) öğrenme blokları yapısı .....	81
Şekil 4.1: (a) Ayrık Fourier dönüşümü, (b) Kısa süreli Fourier dönüşümü ve (c) Ayrık Dalgacık Dönüşümü için zaman-frekansı.....	87

Şekil 4.2: Dalgacık Dönüşümünde kullanılan pencere ve çözünürlük hücreleri .....	89
Şekil 4.3: ADD'de ayrıştırma ve birleştirme süreçleri gösterimi .....	92
Şekil 4.4: Dalgacık Dönüşümünde işaretin altbandlara ayrışımı .....	94
Şekil 4.5: Haar Dalgacığı ile üretilmiş iki farklı görüntü .....	97
Şekil 4.6: Haar Dalgacığı yapısı .....	98
Şekil 4.7: Histogram filtresi kullanımı .....	100
Şekil 4.8: Her bir BT taramasına ayrı ayrı uygulanmış veri önışleme adımı .....	101
Şekil 4.9: Optimal Eşikleme görüntüsü .....	102
Şekil 4.10: Normal (sağlıklı) eşikleme sonrası .....	103
Şekil 4.11: Kanserli görüntü eşikleme sonrası .....	104
Şekil 4.12: Normal (sağlıklı) kenarlar görüntüsü .....	104
Şekil 4.13: Kanserli BT Görüntü kenarları gösterimi .....	105
Şekil 4.14: BT görüntüsünde kenar belirleme .....	105
Şekil 4.15: Sağlıklı greyskale görüntü gösterimi .....	106
Şekil 4.16: Kanserli greyskale görüntü gösterimi .....	107
Şekil 4.17: a) BT hastalıklı görüntüsünün negatifi b) Sağlıklı görüntüsünün negatifi	107
Şekil 4.18: BT görüntülerine Gauss bulanıklığı uygulaması .....	108
Şekil 4.19: BT görüntüsünden akciğer çıkarımı (maske uygulanışı) .....	110
Şekil 4.20: Watershed uygulanışı .....	110
Şekil 4.21: a) Otsu eşiği uygulanışı (b) Tamamlanmış BT görüntüsü .....	112
Şekil 4.22: Görüntünün bölünmesi gösterimi .....	113
Şekil 4.23: Görüntünün çevrilmesi .....	114
Şekil 5.1: ResNet50 ile elde edilmiş en iyi sonuçlar .....	118
Şekil 5.2: Uygulanan ResNet50 mimarisi .....	118
Şekil 5.3: ResNet50 hata matrisi gösterimi .....	120
Şekil 5.4: ResNet50 ağı ROC eğrisi sonuçları .....	120
Şekil 5.5: ResNet50 doğruluk ve kayıp oranları .....	121
Şekil 5.6: Inception v3 hata matrisi gösterimi .....	122
Şekil 5.7: Inception v3 ROC performansı gösterimi .....	123
Şekil 5.8: VGG16 Şeması gösterimi .....	124
Şekil 5.9: VGG16 hata matrisi gösterimi .....	125
Şekil 5.10: VGG16 ROC sonuçları gösterimi .....	126
Şekil 5.11: AlexNet Modeli yönteminin akış şeması .....	126
Şekil 5.12: Dışarda tutma yöntemi (holdout method) .....	127
Şekil 5.13: AlexNet hata matrisi gösterimi .....	128
Şekil 5.14: AlexNet modelinin ROC performans gösterimi .....	129
Şekil 5.15: 4K-ESA MC mimari yapısı .....	130
Şekil 5.16: Rastgele Üst Örnekleme .....	131
Şekil 5.17: Rastgele Alt Örnekleme gösterilmektedir .....	132
Şekil 5.18: İA bölgesi belirlenmiş BT görüntüsü gösterimi .....	133
Şekil 5.19: 4K-ESA metodu performans sonuçları .....	135
Şekil 5.20: 4K-ESA hata matrisi gösterimi .....	136
Şekil 5.21: 4K-ESA eğitim doğruluğu ve kayıp oranları .....	137
Şekil 5.22: 4-K ESA ROC eğrisi sonuçları .....	137
Şekil 5.23: 4K-ESA modeline ilişkin olarak ortaya çıkan sonuçlar .....	138
Şekil 5.24: Belirsizlik uygulanan 4K-ESA modeline ait çıktılar .....	144
Şekil 5.25: 4K-ESA model sonuçları ve ROC eğrisi .....	145
Şekil 5.26: Doğru ve hatalı tahminlere göre gruplandırılan tüm test numuneleri için tahmin belirsizliğinin dağılımı .....	145

<b>Şekil 5.27:</b> 4K-ESA ile belirsizlik ölçeği uygulanmış olan BNN 4K-ESA'nın karşılaştırılması .....	146
<b>Şekil 5.28:</b> Belirsizlik ölçeği eklenmeden modellere ait çalışma ve başarı süreleri	151
<b>Şekil 5.29:</b> Belirsizlik ölçeği ile çalışılan modellere ait çalışma ve başarı süreleri.	152
<b>Şekil A.1:</b> Akciğer İA çıkarımı: a. orijinal CT görüntüsü, b. bit düzlemi, c. erozyon, d. ortanca filtresi,.....	168
<b>Şekil A.2:</b> Temel çalışma akışı gösterimi .....	168
<b>Şekil A.3:</b> Büyütme, b) ana hatlarıyla gösterim, c. kenar belirleme d. İA bölgesi..	169
<b>Şekil A.4:</b> 2B ADD için frekans düzlemi .....	169
<b>Şekil A.5:</b> MC seyreltme, RoS ve RuS yöntemleri denenerek BT veri setindeki dengesizliğin giderilmesi .....	170
<b>Şekil A.6:</b> Etiketli kanser verisi özellikleri.....	170
<b>Şekil B.1:</b> Maske uygulanmış akciğer BT görüntüsü .....	173
<b>Şekil B.2:</b> Maske uygulanmış akciğer BT görüntüsü .....	174
<b>Şekil B.3:</b> Maske uygulanmış akciğer BT görüntüsü .....	175
<b>Şekil B.4:</b> Maske uygulanmış akciğer BT görüntüsü .....	176
<b>Şekil B.5:</b> Maske uygulanmış akciğer BT görüntüsü .....	177
<b>Şekil B.6:</b> 4K-ESA model sonuçları .....	178



# DERİN ÖĞRENME VE DALGACIK DÖNÜŞÜMÜNE DAYALI AKCİĞER KANSERİ ERKEN TANISINDA BELİRSİZLİK ÖLÇEĞİNİN SAPTANMASI

## ÖZET

Bilimsel çalışmalarda 200'den fazla kanser türünün insanları etkilediği ifade edilmektedir. Söz konusu bilinen kanser türleri arasında en ölümcül olanı akciğer kanseridir. Akciğer kanserini, semptom ve bulguların takip edilmesiyle teşhis ve tedavi etmek oldukça önemlidir. Ancak hastalığın hangi aşamada olduğuna, örneğin hastalığın başka organlara da yayılma durumuna bağlı olarak, semptomlarda farklılıklar görülebilir. Fakat hastalığa ilişkin herhangi bir semptom görülmediğinde, elde edilmiş bir bulgu olmadığı için hekimler tarafından yapılan fiziksel muayene esnasında hastalık gözden kaçırılabilir. Dolayısıyla bu gibi durumların yaşanmaması için hastalığın tanısında Manyetik Rezonans Görüntüleme (MR), Bilgisayarlı Tomografi (BT) vb. tekniklerin kullanılmasıyla akciğer bölgesinin detaylı görüntülenmesi çok önemlidir.

Bu yöntemler sayesinde her yıl yüz binlerce canın kurtarılabilmesi amacıyla kanser hastalığı erken safhada saptanabilmektedir. Fakat söz konusu bu yüz binlerce hastaya ait taramaların analiz edilmesi radyologlar açısından zaman ve yoğun emek gerektiren ciddi bir iş yüküdür. Çok sayıda radyologun bu ciddi iş yükünün neden olduğu gözlemci yorgunluğu sebebiyle performansları da olumsuz şekilde etkilenmektedir. Dolayısıyla BT taramalarının daha verimli şekilde okunarak saptanması ve değerlendirilmesi amacıyla bir sisteme gereksinim duyulmaktadır.

Bu tez kapsamında bu gereksinimden hareketle; %80'i eğitim, %10'u test ve geriye kalan %10'u ise doğrulama için kullanılmak üzere Kanser Arşiv Merkezi (KAM) merkezinden alınan 639598 BT görüntüsü üzerinde Derin Öğrenme (DÖ) ve Öğrenme Aktarımı (ÖA) yöntemlerine dayalı işlemler yapılarak 4K-ESA ve BNN 4K-ESA modelleri geliştirilmiştir. Geliştirilen 4K-ESA modelinin geleneksel modellerden (AlexNet, MobileNet vb.) önemli farkı; 4 katmanlı olması sebebiyle bilgisayara fazla yük getirmemesi ve seyreltme tekniği yerine DropWeights tekniğini kullanmasıdır. Çünkü geleneksel modeller çok katmanlı ve çok parametrelili yapılaraya sahip olmaları sebebiyle yanlış hata oranlıları oldukça yüksek olan modellerdir. Bu tez çalışması kapsamında geliştirilen 4K-ESA modeli geleneksel yöntemlerin (ImageNet gibi) aksine, BT görüntülerini işlemeye uygun ince ayarlar yapılarak hazırlanması ve fazla yük ve parametrelerden arındırılmış olması sebebiyle sadece bir konuya yönelerek veriyi 00:03:21sn gibi bir sürede işleyebilmektedir. 4K-ESA üzerine Uncertainty of Quantification (UQ) eklenmesiyle oluşturulan Bayes Ağları (BNN) 4K-ESA modeli sayesinde ise 4K-ESA modelinden elde edilen sonuçlar güven ölçeğine tabi tutulmaktadır.

Geliştirilen modeller sırasıyla; ön işleme, sınıflandırma, belirsizlik ölçeğinin uygulanması ve karar verme olmak üzere temel olarak dört adımdan oluşmaktadır. Ön işleme adımından elde edilen sonuçlara göre; verilerin mini-paket şeklinde

verilmesinin bütün modellerin performanslarını olumlu yönde etkilediği kanıtlanmıştır. Sınıflandırma adımından elde edilen sonuçlar sayesinde; modellere girdi olarak verilen BT görüntülerinin kanserli olup olmadığı, kanserli ise bunun iyi mi yoksa kötü huylu mu oldukları belirlenmiştir. Belirsizlik ölçeğinin uygulanması adımından elde edilen sonuçlarla; çalıştırılan modeller arasında en iyi sonuç veren modelin, parametre sayıları geleneksel modellere göre daha düşük olan 4K-ESA modeli olduğu görülmüştür. Karar verme aşamasından elde edilen sonuçlara göre ise; UQ eklenmeden yapılan deneyler neticesinde 4K-ESA modelinin Matthews correlation coefficient (MCC) değeri 0.988, F2 skoru 0.816, doğruluk oranı 0.971, özgüllük 0.825, hassasiyet 0.974 olarak hesaplanmıştır. F1 skoru 0.962; UQ eklenerek yapılan deneyler neticesinde de BNN 4K-ESA MC modelinin MCC değeri 0.98, F2 skoru 0.88, doğruluk oranı 0.98, özgüllük 0.94, hassasiyet 0.97 ve F1 skoru 0,96 olarak bulunmuştur. Ayrıca çalışmadan elde edilen bulgulara dayalı olarak; belirsizlik Tahmini Entropisi ve Uyuşmazlık Yoluyla Bayesian Aktif Öğrenme (UYBNN) oranları da %90 olarak saptanmıştır. Böylece akciğer hastalıklarıyla ilgili BT görüntülerinde hastalığın, kanser olup olmadığı kanser ise hangi tür kanser olduğunun tespit edilebilmesi açısından geliştirilen modellerin geleneksel modellere göre %98'e kadar daha doğru sonuçlar verdiği görülmüştür.

**Anahtar Kelimeler:** *Derin Öğrenme, Veri İşleme, Göğüs Kanseri, Evrimsel Sinir Ağları, Ayrık Dalgacık Dönüşümü*



# **UNCERTAINTY OF THE QUANTIFICATION IN DIAGNOSING LUNG CANCER FROM CT IMAGES USING DEEP LEARNING AND DISCRETE WAVELET TRANSFORM**

## **ABSTRACT**

It is stated that more than 200 known types of cancer affect humans. Among the known types of cancer, lung cancer is the most deadly one. It is very important to diagnose and treat lung cancer by following the symptoms and signs. However, depending on the stage of the disease, for example, if the disease has spread to other organs, there may be differences in symptoms. However, when there are no symptoms related to the disease, the disease can be overlooked during the physical examination by physicians since there is no finding obtained. Therefore, in order to avoid such situations, Magnetic Resonance Imaging (MRI), CT, etc. Detailed imaging of the lung area with the use of techniques is very important.

Thanks to these methods, cancer disease can be detected at an early stage in order to save hundreds of thousands of lives every year. However, analyzing the scans of these hundreds of thousands of patients is a serious workload that requires time and effort for radiologists. The performances of many radiologists are also negatively affected due to the observer fatigue caused by this serious workload that requires time and effort. Therefore, a system is needed to read, detect and evaluate CT scans more efficiently.

Based on this requirement within the scope of the study; 4K-ESA and BNN 4K-ESA models have been developed by performing operations based on DÖ and ÖA methods on 639598 CT images taken from the KAM center to be used for 80% training, 10% testing, and the remaining 10% for verification. The primary difference of the 4K-ESA model developed from traditional models (AlexNet, MobileNet, etc.); Since it is 4 layers, it does not cause too much load on the computer and uses the DropWeights technique instead of the dilution technique. Because traditional models have multi-layer and multi-parameter structures, they are models with very high false error rates. In addition, the developed 4K-ESA model, unlike traditional methods (such as ImageNet), can process the data in a time like 00:03:21 by focusing on only one subject, as it is prepared by fine-tuning suitable for processing CT images and is free from excess load and parameters. Thanks to the BNN 4K-ESA model created by adding UQ on 4K-ESA, the results obtained from the 4K-ESA model are subjected to a confidence scale.

The models developed are; It basically consists of four steps: preprocessing, classification, application of the uncertainty scale, and decision making. According to the results obtained from the pre-processing step; It has been proved that giving the data as mini-packets positively affects the performance of all models. Thanks to the results obtained from the classification step; It was determined whether the CT images, which were given as input to the models, were cancerous, and if they were cancerous, whether they were benign or malignant. With the results obtained from

the application of the uncertainty scale; It has been observed that the best model among the operated models is the 4K-ESA model with lower parameter numbers compared to conventional models. According to the results obtained from the decision-making phase; As a result of the experiments without adding UQ, the MCC value of the 4K-ESA model was 0.988, the F2 score was 0.816, the accuracy ratio was 0.971, the specificity was 0.825, the sensitivity was 0.974 and the F1 score was 0.962; As a result of the experiments performed by adding UQ, the MCC value of the BNN 4K-ESA MC model was 0.98, the F2 score was 0.88, the accuracy ratio was 0.98, the specificity was 0.94, the sensitivity was 0.97 and the F1 score was 0.96. In addition, as a result of the findings obtained from the study; Uncertainty Estimated Entropy and UYBNN ratios were also found to be 90%. Thus, it has been observed that the models developed in terms of detecting whether the disease is cancer or what type of cancer it is in CT images related to lung diseases give more accurate results than traditional models.

**Keywords:** *Deep Learning, Data pre-processing, Lung Cancer, Convolutional Neural Networks, Discrete Wavelet Transform, Uncertainty quantification*

## 1. GİRİŞ

Çalışmanın bu bölümünde doktora tez konusu olarak ele alınan problemin tanımına, tedavi yöntemlerine, verilerin elde edilmesi ve işlenmesine, çalışmanın amaçlarına ve karşılaşılan zorluklara ilişkin detaylara yer verilmiştir.

### 1.1 Problemin Tanımı ve Yaklaşımı

Kelime anlamı açısından ele alındığında kanser; bir organ veya dokuda bulunan hücrelerin düzensiz şekilde bölünerek çoğalması sonucunda meydana gelen kötü huylu tümörlerdir (Steinbichler et al., 2018). Bununla birlikte kanser, vücuttaki hücrelerin kontrol dışı çoğalması sebebiyle ortaya çıkan 100'ün üzerinde hastalık grubunu da tanımlamaktadır. Tıbbi anlamı açısından ele alındığında ise kötü huylu bir neoplazm olan kanser, düzensiz hücre büyümelerini kapsayan bir çeşit hastalık grubu şeklinde ifade edilmektedir. Kanser söz konusu olduğunda hücre, kontrol edilemez bir biçimde bölünüp büyüyerek bulunduğu çevreye yayılan kötü tümörleri meydana getirmektedir (Xie et al., 2018). Kanser, vücudun her bölümüne kan akıntıları veya lenfatik sistemler aracılığıyla yayılabilmektedir. Fakat her tümör kanserli değildir ve iyi huylu tümörler çevrelerinde bulunan dokulara ve vücuda yayılmamaktadır. Kanser vakalarının %5-10'u çevresel; %90-95'i ise genetik sebepler kaynaklıdır (Wani & Lone, 2018). Kansere sebep olabilecek çevresel etmenlerin dağılımı; %15-20 oranında radyasyon, %25-30 oranında tütün ürünleri ve %30-35 oranında obezite ve diyet şeklinde belirtilmiştir (Gaber et al., 2017).


Bilinen 200'den fazla kanser türünün insanları etkilediği ifade edilmektedir. Söz konusu bilinen kanser türleri arasında en ölümcül olanı akciğer kanseridir. Sağlıklı bir akciğer dokusunun yapısında bulunan bazı hücrelerin, ihtiyaç dışı ve kontrol edilemez bir biçimde çoğalmasıyla akciğerin içinde normal olmayan kitleler oluşmakta ve böylece akciğer kanseri başlamaktadır. Tarama testi veya

tıbbi görüntüleme gibi farklı yöntemler ile kanser semptomlarının varlığı tespit edilebilmektedir (Heigener & Reck, 2018).

Dünya genelinde kanser sebebiyle gerçekleşen kayıpların en başında, akciğer kanserine bağlı olarak meydana gelen ölümler yer almaktadır. Her yıl yüz binlerce can kurtarılabilmesi amacıyla Bilgisayarlı Tomografi (BT) kullanılmakta, kanser problemi erken safhada tespit edilebilmektedir. Fakat söz konusu bu yüz binlerce taramanın analiz edilmesi radyologlar açısından zaman ve emek gerektiren ciddi bir iş yüküdür. Çok sayıda radyoloğun zaman ve yoğun emek gerektiren bu ciddi iş yükünün neden olduğu gözlemci yorgunluğu sebebiyle performansları da olumsuz şekilde etkilenmektedir. Dolayısıyla BT taramalarının daha verimli şekilde okunarak saptanması ve değerlendirilmesi amacıyla bir sisteme gereksinim duyulmaktadır.

Daha önce de belirtildiği gibi akciğer kanserinin meydana gelmesinde en sık rastlanan sebeplerden biri tütündür (sigara vb.). Fakat akciğer kanserinin yalnızca tütün ürünlerinin kullanımından kaynaklandığı yönündeki algı da gerçeği yansıtmamaktadır. Ölümle sonuçlanan hava kirliliği ve tütün ürünleri kullanımı nedeni ile oluşan akciğer kanserlerinin dünya genelinde gözlenme oranı; kadınlarda yaklaşık olarak %80, erkeklerde ise yaklaşık olarak %92'dir (Salaken et al., 2017). Akciğer kanseri dünya genelindeki yaygınlığının yanı sıra, Türkiye'de de ölüme en çok sebep olan kanser türleri arasındadır. Amerikan Kanser Topluluğu'nun istatistiklerine göre akciğer kanseri, teknoloji ve tıp alanındaki gelişmelere rağmen dünya genelindeki tüm kanser sebepli ölümlerin %28'ini oluşturmaktadır (Bray et al., 2018). Akciğer kanserinin erken teşhis edilerek tedavi edilmemesi sonucunda bir bireyin 5 yıl içerisinde hayatta kalma şansı yaklaşık olarak %15 civarındadır (C. Li et al., 2019). Fakat hastalığın erken teşhis edilerek tedavi yöntemlerinin uygulanmaya başlanmasıyla bu oran yaklaşık %51'e kadar çıkabilmektedir (Pati et al., 2020). Ayrıca hastaların %85'inde hastalığın teşhisi için geç kalındığı ve bu sebeple de akciğer kanserinin erken teşhis oranının da oldukça düşük denilebilecek bir oran olan yaklaşık %15 civarında olduğu ifade edilmektedir (Rawat et al., 2018). Türkiye Cumhuriyeti Sağlık Bakanlığı verilerine göre, cinsiyete ve yıllara göre akciğer kanseri her geçen yıl artış göstermektedir (Durmuş, 2020).

Şekil 1.1'de görüldüğü üzere yaş, alkol ve sigara kanserin başlıca nedenleri arasında sayılmaktadır. Sonuç grafiğinde 0'lar sağlıklı, 1'ler ise kanserli hastaları temsil etmektedir.



**Şekil 1.1:** Alkol, sigara, yaş, genetik faktörlerden kaynaklı akciğer kanseri grafiği

Akciğer kanseri en çok erkeklerde görülse de son yıllarda kadın hastaların oranında da bir artış olduğu görülmektedir.


### **Kanser hastalığı:**

Tıbbi tanımıyla "kötü huylu bir neoplazm" olan kanser, düzensiz hücre büyümelerini kapsayan bir çeşit hastalık grubudur. Kanserli hücreler kontrol edilemez bir biçimde bölünüp büyüyerek bulunduğu çevreye yayılan kötü tümörleri meydana getirmektedir (Ayub et al., 2017). Bilinen 200'den fazla kanser türünün insanları etkilediği ifade edilmektedir. Kanserın sebepleri

oldukça karmaşık olup, bugüne kadar kısmen anlaşılabilmiştir. Fiziksel aktivite eksikliği, diyetler, obezite, tütün ürünlerinin kullanımı, radyasyona maruz kalma ve çevreyi kirletici etkenler de dâhil olmak üzere kanser riskini arttırdığı belirtilen birçok faktör bulunmaktadır. Söz konusu bu faktörler kanserli bir mutasyona sebep olabilecek şekilde hücre içerisindeki mevcut genetik dizilim ile birleşebilir ve dolayısıyla genler açısından önemli bir zarara yol açabilir (Liao et al., 2019).

### **Akciğer kanseri:**

Nefes alan tüm canlıların temel solunum organı akciğerdir. Koni şeklinde süngerimsi bir yapıya sahip olan akciğer; hava yolları, hava kesecikleri ve kan damarlarından oluşmaktadır. Akciğerler, kalbin her iki yanında iki parça şeklinde ve göğüs kafesinin içerisinde yer almaktadır (Türkçetin et al., 2019). Akciğerlerde çeşitli hastalıklar meydana gelebilmektedir. Kanser hastalığı, genelde hastalığın ortaya çıktığı dokunun ismine göre adlandırılmaktadır. Buradan hareketle akciğer kanseri, akciğerlerde ortaya çıkan ve akciğer dokularındaki hücrelerin kontrolsüz biçimde çoğaldığı bir hastalık çeşididir. Yaşam için hayati organlardan biri akciğerdir. Solunum sisteminin en önemli parçası olan akciğer, vücuda oksijenin alınması ve vücuttan karbondioksitin atılmasını sağlamaktadır. Aşağıda verilen Şekil 1.2'de sağlıklı ve kanserli akciğer BT görüntüsü gösterilmektedir.



**Şekil 1.2:** a) Akciğer kanseri nodülü görüntüsü, b) Sağlıklı akciğer BT görüntüsü

Akciğerlerde meydana gelen kanser hastalığı, kontrolsüz bir şekilde büyümektedir. Vücut da akciğerlerde meydana gelen bu kontrolsüz büyümeyi engelleyememektedir. Söz konusu kontrolsüz büyümeye, mutasyon sonucu ortaya çıkan DNA bozulması neden olmaktadır (Miranda-Filho et al., 2020).

Şekil 1.2 a'da da görüldüğü üzere hücre normal olmayan bir biçimde büyüdüğüde de kanser ortaya çıkmaktadır.

Akciğer kanserlerinde, bazı kanserler çok hızlı bir şekilde metastaz yapabildiği için tedavi yöntemleri farklılık gösterebilmektedir. Dolayısıyla hastalığın erken teşhis edilmesiyle tedaviye başlanması oldukça önemlidir. Bugünün teknolojik gelişmeleri, kanser hastalığı için erken safhalarda doğru tanı ihtimallerini gözle görülür bir şekilde artırmıştır. Teknolojinin henüz bu amaçlar için kullanılmadığı geçmiş tarihli vakalar incelendiğinde yalnızca hekim görüşü alınması sebebiyle hatalı yorumlanmış olan vaka analizleriyle karşılaştırılabilir.

- Akciğerde nodülün yalnızca sınırlı bir alanı vardır ve henüz yayılmamıştır.
- Kanser hücreleri yakındaki lenf düğümlerine yayılmıştır.
- Kanser hücreleri, orada bulunan akciğerler veya lenf düğümleri arasındaki boşluğa yayılmıştır
- Kanser hücreleri, karaciğer, kemik, böbrek üstü bezi vb. diğer uzak organlara yayılmıştır.

Akciğerlerde meydana gelen tümör yapıları temelde, malignite tümör (kötü huylu tümör) ve benign tümör (iyi huylu tümör) olmak üzere iki ayrı sınıfa ayrılmaktadır. Malignite tümörler, kanser hücrelerine sahip tümörlerdir. Bu tümörler, çevrelerindeki hücelere yayılarak hayati bir tehlike oluşturmaktadırlar. Kötü huylu tümörlere sahip olan bu kanser türünün erken teşhis edilmesi ve tedaviye başlanmasıyla hastanın kurtulma şansı artacaktır. Benign tümörler ise malignite tümörlerin aksine genellikle kanser olarak değerlendirilmemektedir. Vücuttan alınırlarsa bir daha tekrarlanma ihtimali olmayan benign tümörler yayılma göstermemektedir. Bu sebeple de yaşamsal faaliyetlerde herhangi bir aksaklığa sebep olmamaktadırlar.

### **Tanı yöntemleri:**


Akciğer kanserini, semptom ve bulguların takip edilmesiyle teşhis ve tedavi etmek oldukça önemlidir. Ancak herhangi bir belirti göstermeksizin sinsice ilerleyen akciğer kanseri çeşitleri de bulunmaktadır. Özellikle tütün ürünleri

kullanan hastalar açısından öncelikli belirtilere bakılırsa öksürük ve balgama sıklıkla rastlanılmaktadır. Ayrıca nefes darlığı, göğüste ağrı vb. şikâyetler ile balgamın kanlı olması da öne çıkan belirtilerdendir. Ek olarak hastada yorgunluk, iştahsızlık, kilo kaybı gibi belirtilere de rastlanılabilmektedir. Daha genel bir ifadeyle hastalığın hangi aşamada olduğuna bağlı olarak, örneğin hastalık başka organlara da yayılmışsa, belirtilerde farklılıklar görülebilir. Fakat hastalığa ilişkin herhangi bir belirti görülmediğinde, elde edilmiş bir bulgu olmadığı için hekimler tarafından yapılan fiziksel muayene esnasında hastalık gözden kaçırılabilir. Dolayısıyla bu gibi durumların yaşanmaması için hastalığın tanısında Manyetik Rezonans Görüntüleme (MR), BT vb. tekniklerin kullanılmasıyla akciğer bölgesinin detaylıca görüntülenmesi oldukça önemlidir.

### **Görüntüleme yöntemleri:**

1963 yılında Allan McLeod Cormack ve Godfrey Hounsfield tarafından tasarlanan ve radyoloji alanında bir çığır açan kesitsel görüntüleme yöntemine BT adı verilmektedir (Goodwin et al., 2019). BT sayesinde tüm göğüs boşluğu ve akciğer bir veya birkaç santimetre aralıklarla taranabilmekte ve böylece akciğerlere dair detaylı görüntü elde edilebilmektedir (Bkz. Şekil 1.3). Tomografi, bilgisayar teknolojisi kullanılarak x-ışınları ile vücudun incelenmesine olanak sağlayan radyolojik bir tanı şeklidir. Geleneksel yöntemler ile görüntülenemeyen yumuşak dokular, BT teknolojisi sayesinde detaylı bir şekilde görüntülenebilmektedir. Bu sayede ise hastalığa dair teşhis ve tanı koyulabilmesi için daha güvenilir ve net sonuçlar elde edilebilmektedir.






**Şekil 1.3:** Bilgisayarlı Tomografi görüntüleme cihazı

BT taraması sadece pek çok açıdan tıpta çığır açan bir teknik değil aynı zamanda birtakım sınırlamaların da üstesinden gelebilmeyi mümkün kılan bir yöntemdir. BT taraması ile akciğer yoğunlukları ölçülerek, zayıf veya hastalıklı bölgeler ile sağlam bölgeler kolaylıkla ayırt edilebilmektedir. BT taraması; apselerin drenajı, biyopsi, radyasyon implantlarının yerleştirilmesi, kontrast enjeksiyonları ve ortopedik pim yerleştirme gibi bazı klinik prosedürlere yardımcı olması için kullanılmaktadır. Ayrıca BT görüntüsü ile lezyon (doku bozukluğu) ve kitleler net bir şekilde görüntülenebilmektedir. Söz konusu görüntülerin formatı genellikle Tıpta Dijital Görüntüleme ve İletişim (DICOM: Digital Imaging and Communications) şeklindedir (Kaur & Bhatia, 2017).

BT görüntülerinin matrisi sırasıyla 256 X 256, 320 X 320 veya 512 X 512 büyüklüğündedir. Bu sayıların çarpımı, görüntüye ilişkin matris eleman sayısını vermektedir. Ayrıca yeni üretilen cihazlarda matris sayılarının daha büyük olması sebebiyle görüntüler de daha detaylı olmaktadır.

BT taraması esnasında genellikle kesit kalınlığının 2 cm'nin altına düşmesiyle bir gürültü meydana gelmektedir. Dilim kalınlığının daha da azalmasıyla bu gürültüde artış olmaktadır. Ayrıca çekimlerde kişiden kişiye değişiklik gösterebilen durumlar sebebiyle; akciğerlerin görüntüdeki yerlerinde bir farklılık, eksenlerde tam olarak yerleşmeme ve çekimin çözünürlüğünde düşüklük vb. sorunlarla karşılaşılabilir.

**Hounsfield skalası:** Organizmalardan geçebilen x-ışınlarının zayıflama değerini sayısal olarak tespit edebilen Hounsfield Ünitesi (HÜ)'in içerisinde, her bir voksel için karşılığı olan bir sayısal değer bulunmaktadır. Voksel, piksel yüzeyi ile seçilen kesit kalınlığının çarpımı sonucu oluşan hacme karşılık gelen sayısal değere verilen addır. Bu sayısal değer, sudaki zayıflama değerini sıfır olarak kabul etmektedir. Ayrıca pek çok BT aygıtında kesit kalınlığı 1,5 ile 12 mm arasındadır. Şekil 1.4'te vokseller genellikle 12 bit ile temsil edilmekte ve  $2^{12} = 4096$  çeşit değer alabilmektedir (Zhang et al., 2017). Söz konusu değerler -1024 HÜ ile +3071 HÜ arasındaki ölçekte düzenlenmiştir (Romme et al., 2012). Şekil 1.4'te HÜ hakkında genel bilgiler verilmektedir. Skala üzerinde hava -1000 iken su 0 olarak kabul edilmektedir.



**Şekil 1.4:** Hounsfield skalası

**Kaynak:** (Güray, G. 2011)

Organizmayı geçen X-ışınlarının attenuasyon (zayıflama) değerleri sayısal olarak saptanmaktadır. Her pikselin bir sayısal karşılığı vardır. Bu değerlere göre havanın zayıflama değeri -1000 HU, suyun zayıflama değeri ise 0 HU olmaktadır. Ayrıca kemiklerin zayıflama değeri +400 HU veya üstü iken; metal implantların zayıflama değeri genellikle +1000 HÜ'dür. BT verilerinin HU birimine çevrilebilmesi için veriye aşağıdaki (1.1) eşitliğinde yer alan dönüşümün uygulanması gerekmektedir.

$$HU = I(x, y)s + 1 \quad (1.1)$$

Yukarıdaki eşitlikte, "I" (x, y) x ve y noktalarındaki görüntülerin piksel değerlerini; "s" (slope) eğim değerini; "i" (intercept) ise kesişim değerini ifade etmektedir.

Hounsfield skalası, MR ve BT görüntüleme içerisindeki her voksel için x-ışınlarının zayıflama miktarını tanımlamaya yarayan bir ölçü birimidir (Levine

et al., 2018). Örneğin akciğer bölgesi -500 HÜ'den daha düşük iken kontrast madde verilmiş kan damarları ve kemikler ise 200 HÜ'den daha yüksektir.

**DICOM görüntü formatı:** Tıbbi görüntüleme yaygın şekilde kullanılan bir format olan DICOM; BT taramalarını, MR görüntülerini ve ultrason sonuçlarını görüntüleyebilmek, saklayabilmek ve yazdırabilmek amacıyla Ulusal Elektrik Üreticileri Birliği (NEMA) tarafından geliştirilmiştir. DICOM, TCP/IP ağ haberleşme protokolü ile dosya format tanımlarını içermektedir. Şekil 1.5'te DICOM formatlı görüntü özellikleri verilmiştir. Görüntülerde başlık ve başlığın altında ise önek bilgisi yer almaktadır.

<b>Başlangıç (128 bayt)</b>	<b>Başlangıç (128 bayt)</b>
<b>ÖRNEK-</b> 'D', 'I', 'C', 'M'	<b>ÖRNEK-</b> 'D', 'I', 'C', 'M'
<b>BAŞLIK</b> <b>VERİ SETİ</b> - Group 1 (0002) - Element 1 (0002,0000) - Element 2 (0002,0001) - Element 3...etc. - Group 2 (0008) - Group 3...etc.	<b>BT GÖRÜNTÜ PİKSEL YOĞUNLUĞU</b> 10011010011001011010100 01011010100100110100110 10100110010110101001001 10011010011001011010100 01011010100100110100111 10100110010110101001 .....

**Şekil 1.5:** DICOM formatlı görüntü özellikleri

1980'li yıllarda BT makinelerinin oluşturduğu görüntülerin kodları yalnızca üretici firmalar tarafından çözülebiliyordu ve bu nedenle TCP/IP kullanılmaktaydı. Takip eden yıllarda radyologlar tarafından radyasyon tedavisi kapsamında doz planlama amacıyla görüntülerin kullanılmak istenmesi sonucunda DICOM görüntü formatı ortaya çıkmıştır. NEMA tarafından geliştirilen üçüncü standart versiyon olan DICOM formatı ile görüntüler, çeşitli üreticilerin sunucuları, tarayıcıları, yazıcıları, iş istasyonları ve ağ donanımları sayesinde Resim Arşivleme ve İletişim Sistemi (PACS: Picture Archiving and Communication System) üzerinden kullanılabilir. Bilgileri veri kümeleri şeklinde gruplandırabilmesi açısından DICOM, diğer görüntü türlerinden farklılık göstermektedir. DICOM dosyası, tamamı tek bir dosyada toplanmış olan bir başlık ve görüntü veri kümelerinden oluşmaktadır.

**Problem için çözüm önerileri:**

Bugün akciğer kanserinin, dünya çapında gerçekleşen ölümlerin başlıca sebeplerinden biri olarak kabul edildiği ifade edilmektedir. Özellikle de gelişmemiş ülkelerde çok daha yaygın olduğu çeşitli araştırmalar vasıtasıyla ortaya koyulmuştur. Hastanın hayatta kalma şansını artırabilmek açısından, akciğer kanserine sebep olan pulmoner nodüllerin erken teşhisi büyük önem taşımaktadır. Hastalığın tespit ve teşhisi için BT görüntülerinin uzmanlar tarafından detaylı bir şekilde incelenmesi gerekmektedir, fakat bu incelemeler gerek zaman gerekse maliyet açısından birtakım olumsuzluklar içermektedir. Her bir BT görüntüsünün değerlendirilmesi için çok fazla zaman harcanması ve bu durum sonucunda yorgunluk yaşayan radyologların yorum yapabilme becerilerinde performans düşüşlerinin yaşanması söz konusu olumsuzluklara örnek olarak gösterilebilir. Literatür incelendiğinde, söz konusu olumsuzlukların en aza indirgenebilmesi amacıyla çeşitli çalışmalar yapıldığı görülmektedir. Örneğin geçmişte Bilgisayar Destekli Tanı (BDT) kullanılırken bugün çok daha başarılı ve tıpta kullanımı her geçen gün daha da yaygınlaşan teknikler (Evrışimli Sinir Ağları, bilgisayar görüşü vb.) kullanılmaktadır.

#### **Donanım gereksinimleri:**

Tıbbi görüntüler genellikle geniş dinamik yapıda ve çok boyutludurlar. Bu verilerin bilgisayarda saklanıp işlenebilmesi için oldukça yüksek kapasiteli bellek ve işlemci hacmine ihtiyaç vardır. Örneğin, dijital fotoğraflarda her bir piksel için 8 bit veya 1 bayt yeterli iken; tıbbi görüntülerde her bir piksel için 12 bit veya 2 bayt kapasiteye ihtiyaç duyulmaktadır. Özellikle de üç boyutlu görüntü verilerini saklayabilmek için çok daha geniş kapasiteli belleğe gereksinim vardır. Yüksek çözünürlüklü bir BT görüntüsünün; her biri 512 X 512 piksel olan 1000 görüntü içerebilmesi, dolayısıyla her bir görüntüleme için 5 GB bellek kapasitesine ihtiyaç duyulması ve bunun da neredeyse 50 milyondan fazla voksele denk gelmesi bu duruma örnek olarak gösterilebilir. Buradan hareketle; bu gibi büyük veri sistemlerinde çok fazla veri ile çalışabilmek için sistem işlemcilerine ilişkin konfigürasyonların da oldukça yüksek olması gerekmektedir.

## 1.2 Tezin Amacı ve Yaklaşımı

Çalışmanın amaçları sırasıyla; akciğerlerde bulunan nodüllerin tespit edilebilmesi amacıyla yapılan araştırmalar ve bu araştırmalar neticesinde elde edilen çıktılara ilişkin genel bir değerlendirmede bulunulmasıdır. Söz konusu bu araştırmalardaki muhtemel eksikliklerin tespit edilebilmesi, yeni gelişen bir teknik olan Evrişimli Sinir Ağları (ESA) sayesinde akciğerlerde potansiyel olarak kanserli nodül barındıran bölümlerin sınıflandırılmasıdır. Potansiyel hastanın kanser hastalığına yakalanıp yakalanmadığına dair bulgu elde edilebilmesi ve şayet yakalandıysa bunun hangi türde bir kanser olduğunun belirlenebilmesi konularına ilişkin verilerin ortaya koyulmasıdır.

Çalışmanın ana başlıkları; akciğer kanserinin Derin Öğrenme (DÖ) metotlarıyla kısa sürede doğru bir şekilde teşhis edilebilmesi, hastalığa yönelik tedavi şeklinin hızlıca seçilerek uygulanabilmesi ve elde edilen verilerin yönetiminin kolaylaştırılabilmesine ilişkin konulardan oluşmaktadır. Söz konusu başlıklar ile ulaşılmak istenen temel hedef, bilişim sektörünün tıp alanında faydalanılabilir hale getirilmesidir. Tıp ile teknolojinin birleşimiyle gerek maliyet gerekse zaman açısından oldukça fazla tasarruf edilebilir. Dahası, alınan/verilen hizmetin daha kaliteli hale gelmesiyle ortaya çıkan sonuçların pozitif yönlü bir gelişim göstermesi de ulaşılmak istenen hedef açısından olumlu etkiler olarak değerlendirilebilir.

Çağın vebası şeklinde de tanımlanan akciğer kanseri üzerine odaklanılarak hazırlanmış olan bu çalışmada; Kanser Arşiv Merkezi (KAM)'nden (NLST, 2015) alınan DICOM formatlı BT akciğer kanseri görüntüsüne ilişkin veri setleri belirli formatlara dönüştürülerek tekrarlardan kurtarılmış, hatalardan ayrıştırılmış ve hazırlanan veri ambarında tutulmuştur (American College of Surgeons & American Cancer Society, 2017). Elde edilen ve hastalara ilişkin bazı önemli detayları da içeren bu veriler; röntgen sonuçları ve röntgenler ile saptanan anormallikler, komplikasyonlar, teşhis ve tedavi gibi başlıklardan meydana gelmektedir. Çalışmanın ilerleyen aşamalarında, veriler arası ilişkilerin incelenbilmesi amacıyla Derin Öğrenme (DÖ) tekniklerinden faydalanılarak; bireyin kanser hastalığına sahip olup olmadığı, sahipse de

bunun hangi tür bir kanser olduğuna ilişkin bilgilerin işlenebilmesi için veri sınıflandırmaları yapılmıştır.

Ayrıca bu çalışma ile akciğer kanserini tanımlayabilmek ve sınıflandırabilmek için DÖ ile Ayrık Dalgacık Dönüşümü (ADD: Discrete Wavelet Transform) tekniklerini birleştiren yeni bir yöntemin sunulması amaçlanılmıştır. Çalışmada ADD'nin yanı sıra 4 adet geleneksel DÖ mimarisi ve yenilikçi bir algoritma da önerilmektedir. Söz konusu yeni yöntem üzerinde yapılan çalışma ve eğitimlerin tamamlanmasıyla test performansının ölçülmesi amaçlanılmıştır. Yenilikçi model için uygunluk fonksiyonları; ortalama kare hatası, sınıflandırma hatası, doğrulama hatası, mimaride hata azaltma veya bir kombinasyonu dikkate almaktadır. Bununla birlikte çalışmada farklı parametre değerlerini kullanan çeşitli algoritmalar da (AlexNet, ResNet vb.) denenmiştir. Bu algoritmalar için en iyi parametre değerleri, optimum sonuçlar elde edebilmek için deneysel aşamalarla belirlenmektedir. Bunun yanı sıra; en iyi konfigürasyon kullanılarak seçilen her bir sınıflandırma problemi, istatistiksel olarak geçerli bir dizi deneyden meydana gelmektedir. Önerilen yeni yöntemin sonuçları, bağlantı sayısı, nöron sayısı ve her bir DL mimarisi için seçilen ÖA yöntemi de tartışılmaktadır.


### **1.3 Çalışmada Karşılaşılan Zorluklar**

Çalışmanın bu başlığı altında, çalışmayı tamamlayabilmek amacıyla üstesinden gelinen zorluklar ele alınmaktadır. Karşılaşılan zorluklar, büyük verilerden ve bilgisayar konfigürasyonları sebebiyle ortaya çıkan problemler takip eden alt başlıklarda detaylandırılmaktadır.

#### **Veri kümesi yönetimi ve ön işleme:**

Bu çalışma için aşılması gereken en temel zorluk, oldukça büyük olması sebebiyle veri kümesi ile çalışmaktır. Fakat çalışmadan elde edilebilecek en iyi sonuca ulaşabilmek için oldukça büyük boyutlarda (elde edilen veri miktarı yaklaşık 1 TB) veriye gereksinim duyulmaktadır. Veri kümesinin yönetimi ve analizi sonucunda çok hesaplamalı bir model oluşturularak elde edilen verinin eğitim ve test açısından ayrıştırılması, karşılaşılan önemli bir problemidir. Şekil

1.6'da KAM veri merkezinden alınan akciğer kanseri BT taramasının bir örneği yer almaktadır.



**Şekil 1.6:** Kanser arşiv merkezinden alınan veri kümesi

Veri kümesinin yönetimi ve analizi sonucunda çok hesaplamalı bir model oluşturularak elde edilen verinin eğitim ve test açısından ayrıştırılması, karşılaşılan önemli bir problemdir. Dolayısıyla bu oldukça büyük verinin ayrıştırılabilmesi açısından potansiyel çözüm; hesaplama için gerekli olan iş yükünün Google Cloud bulut hizmetine taşınması ve bu sayede projede daha verimli bir iş akışı sağlanabilmesidir. Çünkü özellikle boyut seçimi ve veri hazırlama esnasında tek bir BT taraması bile çalışmayı oldukça karmaşık bir hale getirebilen 3 boyuttan meydana gelmektedir.

#### **Derin öğrenme mimari tasarım seçimleri:**

DÖ; türlü problemleri çözebilmek amacıyla yapısında birçok mimari barındıran ve kendi içinde tasarlanmış bir yapıdır. Çalışmada karşılaşılan temel zorluklarından biri, derin öğrenme ile verilerden benign veya malignite tümöre dair farkları anlayarak bunları sınıflandıracak olan mimariyi seçebilmektir. Söz konusu zorluğun üstesinden gelmek için çeşitli deneyler yaparak en doğru mimariyi bulabilmek oldukça önemlidir.

#### **Derin öğrenme kavramlarını anlama:**

DÖ, son zamanlarda sıklıkla tercih edilmesine rağmen hala keşfedilmesi gereken pek çok yönü olan mimari bir yapıdır. Dolayısıyla bu durumun çalışma açısından bir eksikliğe neden olmaması veya problem oluşturmaması için DÖ mimarisinin detaylı bir şekilde incelenerek anlaşılması gerekmektedir.

### **Derin öğrenme entegrasyonu:**

Geleneksel Makine Öğrenme (MÖ) algoritmalarına kıyasla DÖ modellerinin Python programlama dili kullanılarak uygulamalara entegre edilmesi oldukça farklıdır. Standart MÖ algoritmaları ile bir dosya serileştirilebilir bir uygulamaya yüklenilebilir şekilde getirilebilir. DÖ modelleri ise Tensorflow'u bir çerçeve şeklinde kullanmaktadır. Tensorflow ve Keras çerçeve uygulamaları Google kütüphanesinden çağrılmaktadır. Bu konu, uygulama bölümünde daha ayrıntılı olarak açıklanmaktadır.

## **1.4 Tez Düzeni**

**Bölüm 1: Giriş**— Çalışmanın birinci bölümünde sırasıyla; akciğer kanserinin ne olduğu, nodüllerin çeşitleri ile büyüklüklerine ilişkin temel bilgiler, kanser tanı yöntemleri ile en hızlı tanı koymanın nasıl mümkün olabileceği, akciğer görüntülemesine ilişkin çeşitli yöntemler, BT cihazları ile çeşitli görüntüleme teknikleri ve tüm bu süreçlerde karşılaşılan bazı problemler ve bu problemlerin çözümlerine yönelik geliştirilmiş olan proje yer almaktadır. Özetle çalışmanın giriş ana başlığı altında; problemin tanımı, çalışmanın amacı, uygulanan teknikler, çalışmanın literatüre katkıları ve çalışmada kullanılan araştırma yöntemlerine dair alt başlıklar ele alınmıştır.

**Bölüm 2: Literatürde Yapılan Araştırmalar**— Çalışmanın ikinci bölümünde, literatürde yer alan akciğer kanseri tanısı ile ilgili yapılmış benzer çalışmalar ve bu çalışmalardaki eksiklere değinilmiştir.

**Bölüm 3: Veri ve yöntem**— Çalışmanın üçüncü bölümde, akciğer BT görüntülerine ilişkin veri seti ve söz konusu veri setinin elde edilmesine yönelik bilgiler yer almaktadır. Ayrıca elde edilen verilerde format değişikliği yapılması ve de verilerin ön işleme aşamalarından geçirilmesine dair bilgiler sunulmuştur.



**Bölüm 4: Model Çalışmalarına Yönelik Veri Önışlem Süreci** — Çalışmanın dördüncü bölümünde; ihtiyaç analizi oluşturmaya ilişkin aşamalara yer verilerek akciğer kanserine dair tanı yöntemleri geliştirilirken yararlanılan araçlar detaylıca incelenerek açıklanmıştır. Ayrıca DÖ mimarisinin nasıl geliştirildiği, hangi amaçlar için kullanıldığı, verileri nasıl işlediği, yenilikçi modelin kaç katman olması gerektiği gibi sorular ile kullanılabilir aktivasyon yöntemleri ve kullanılan verilerin anlamlı hale gelerek, kesin ve anlamlı sonuçlar elde edilmesini sağlayan modelin geliştirilmesine dair bilgilere yer verilmiştir. Bunlara ek olarak; konuyu desteklemek amacıyla çeşitli şekil ve çizelgelerden de faydalanılmıştır.

**Bölüm 5: Uygulama ve Analiz:** Çalışmanın beşinci bölümünde; akciğer kanserine ait BT veri kümesinin yardımıyla öznitelik oluşturabilmek için DD ve ADD kullanımına ve DÖ algoritmasının ADD ile oluşturulan öznitelik kümesi üzerinde kullanılmasına yer verilmiştir. Ayrıca DÖ metodu ve ADD kullanılarak BT görüntülerinden elde edilen akciğer kanseri teşhisine ilişkin modellerin değerlendirilerek, uygulanan farklı tekniklerin karşılaştırılması yapılmıştır. Daha sonra karşılaştırmadan elde edilen bu sonuçların belirsizlik ölçümüne göre ne kadar başarılı ve de ne kadar başarısız oldukları açıklanmıştır. Çalışmada veri eksikliğinden kaynaklanan Epistemik belirsizlikler ve olasılıksal değişkenlikten kaynaklanan içsel belirsizlik olan Aleatorik belirsizlik türleri kullanılmıştır.

**Bölüm 6 Sonuçlar**— Çalışmanın son yani altıncı bölümünde ise çalışmadan elde edilen bulgular doğrultusunda; sınırlamalar ve eksikler tartışılarak, gelecek çalışmalara önerilerde bulunulmuştur.

Akciğer kanseri, kansere bağlı ölümlerin en önemli nedenidir ve her yıl 1 milyonun üzerinde insan bu nedenle ölmektedir [1]. Günümüzde akciğer kanserinin tedavisinde radyoterapi çok önemli bir yer tutar. Radyoterapi, iyonlaştırıcı radyasyon kullanarak kanser hastalığının tedavi edilmesidir. Radyoterapinin amacı, tümörlü dokunun yok edilmesi ve aynı zamanda sağlıklı dokuların korunmasıdır. Hastalığın tedavisi tümörün evresine, tümörün nerede olduğuna ve hastanın genel sağlık durumuna göre planlanmaktadır. Akciğer kanseri tedavisinde hastalığın evresine göre cerrahi, kemoterapi ve radyoterapi tedavi yöntemleri olarak kullanılmaktadır. Üç tedavi şeklinin klinik sonuçları

farklıdır. Akciğer kanseri tedavisinde cerrahiye uygun olmayan hastalar için radyoterapi oldukça etkili bir yöntemdir [2].

Gelişen teknoloji ile birlikte birçok etkili radyoterapi yöntemleri kullanılmaktadır. VMAT (volümetrik ark tedavi) ve IMRT (yoğunluk ayarlı radyoterapi ) bu etkili yöntemlerden birisidir. VMAT tekniği çok yüksek dozlardaki radyasyonun yüksek hassasiyetle farklı açılardan hedef organa gönderildiği tedavi yöntemidir. Gönderilen radyasyonun hedefte en yüksek dozu alması amaçlanırken çevre dokuların en az dozu alması sağlanmaktadır. VMAT tek doz şeklinde yada birkaç doz olarak uygulanabilmektedir. IMRT ise yoğunluk farklılıkları oluşturulmuş alanlardan tedavi yapılan bir yöntemdir. Her iki yöntemde de çevredeki sağlam dokular korunarak etkili bir tedavi uygulaması amaçlanmaktadır.

Bu çalışmada; İstanbul Bahçelievler Medikal Park Hastanesi Radyasyon Onkolojisi Anabilim Dalında, akciğer kanseri tanısı almış hastalarda Tomoterapi cihazında VMAT ve IMRT teknikleri kullanılarak elde edilen doz dağılımlarının ve çevre dozların karşılaştırılması hedeflenmiştir.

Her plan için Tomoterapi cihazında tümör boyutu ve cihazın çene açıklığı (jaw) parametreleri değiştirilip her hasta için 18 farklı tedavi planı oluşturulmuştur. Tedavi planları oluşturulup doz-hacim histogramları elde edilerek karşılaştırılmıştır. İstatistiksel analiz sonucunda, akciğer kanserli hastalar için en uygun ve doğru tedavi tekniğini bulmak amaçlanmıştır.

## 2. GENEL BİLGİLER

Literatürde yer alan pek çok araştırma ve metodolojiler çerçevesinde değerlendirildiğinde; kanser hastalığına ilişkin araştırmalarda yaygın olarak karşılaşılan "yanlış sonuçlar" dikkat çekmektedir. Bu sebeple; teknoloji sayesinde daha hızlı ve daha doğru sonuçlara ulaşmayı kolaylaştıran ve de insan kaynaklı hataların en aza indirgenmesine katkı sağlayan teknolojik yöntemlerin geliştirilmesi oldukça önemlidir. Çalışmanın bu bölümünde söz konusu önemden hareketle; akciğer kanserini tanımlama yöntem ve prosedürleri, DÖ algoritmaları ile ilişkili çeşitli görüşler ve BT görüntülerinin işleme evreleri ele alınmaktadır.

Akciğer nodüllerinin tespit edilebilmesi amacıyla otomatik veya yarı otomatik sistemlerin geliştirilmesine yönelik olarak literatüre katkı sağlayan çok sayıda araştırma yapılmış ve hala da yapılmaya devam etmektedir. Bunun yanı sıra, yapılan çalışmalar sayesinde akciğer kanserinin tespit edilmesine yönelik olarak da pek çok farklı algoritma geliştirilmiştir. Söz konusu algoritmalarından bazılarına takip eden paragraflarda değinilmiştir:

DÖ tekniğini kullanarak, akciğer nodülünün sınıflandırılabilmesi için BT görüntü verilerini şekil ve doku açısından ele alan bir algoritmayı öneren bazı çalışmalar bulunmaktadır (Bhatia et al., 2019). Önerilen bu algoritmada; nodüllerin heterojenliğini betimlemek için bir Fourier-Şekil Tanımlayıcı ile bir "Gri Seviye Eş Oluşum Matrisleri" tabanlı yüzey tanımlayıcıdan ve düğümlerin özelliklerini eğitmek için de Evrişimli Sinir Ağlarından (ESA) yararlanılmıştır. Diğer bir çalışma ise geleneksel BDT teknikleri üzerine odaklanmış olan ve manuel olarak tasarlanan sistem akciğer kanseri erken teşhisi için ideal görünmemektedir (Lakshmanaprabu et al., 2019). Bazı bilim insanları tarafından akciğer kanserinin tanısı için; sınıflandırıcı olarak Destek Vektör Makinelerinden (DVM) yararlanılması ve çalışmalarında epidemiyoloji materyalin, klinik semptomların ve miRNA (mikroRNA) biyobelirteçlerin esas alınmasıyla bir DVM modeli geliştirilmiştir (Jiang et al., 2018). Bunların yanı

sıra, Doğrusal Ayırıcı Analiz (LDA) tekniğinden (düzenleme parametresine ait geleneksel çapraz doğrulama algoritmasının hesaplandığı teknik) yararlanarak lineer yapıyı odak alan bir yöntem de bulunmaktadır (C. Li et al., 2019). LDA, BT görüntü veri setini daha kolay ayrılabilir hale getirebilmek kullanılmıştır fakat veri setini daha kolay ayrılabilir hale getirmek yalnızca Covariance Matris tekniğiyle mümkün olmaktadır. Dolayısıyla LDA tam anlamıyla bir sınıflandırma algoritması olmadığı için de sadece mimari kısmı açısından bir başarı sağlamıştır (Jye Kho et al., 2017). Bir diğer sınıflandırma ise; BT görüntüleri için geliştirilen Yapay Sinir Ağları (YSA) bazlı bir kanser sınıflandırmasıdır (Song et al., 2017). Ancak söz konusu bu sınıflandırma modeli için kullanılan istatistik ile yalnızca kısmi bir başarı elde edilmiştir. Liu vd. (Liu et al., 2020) çalışmalarında, DÖ metotlarının başarımını ortaya koymak ve var olan dezavantajlar ile başa çıkabilmek özellik çıkarımı sağlayan iki temel yöntem uygulamışlardır. Olasılık dağılımı ve Gauss dağılımına ilişkin işlevlerin hesaplanmasıyla görüntüde yer alan piksellerin dağılımını inceleyen çalışmalar da bulunmaktadır. Piksellerin dağılımlarının incelenmesi hususunda, piksel dağılımı yapıldıktan sonra komşu piksellere ilişkin benzerliğin hesaplanması oldukça önemlidir. Fakat bilindiği üzere piksel tabanlı nodül tespit yöntemleri pek başarı sağlayamamıştır (Choe et al., 2019). Bunun yanı sıra, BT görüntülerinin odak alınmasıyla akciğer kanserinin tespit edilmesini hedefleyen bir Bilgisayar Destekli Tanı (BDT) sistemi geliştirilerek, söz konusu sistemde özellikle İlgi Alanı (IA) üzerine yoğunlaşmıştır (Sun et al., 2017). Gelecek vaat eden bir çalışma alanı olan nodül saptama, son yıllarda birçok araştırmacı tarafından ele alınmıştır. Nodüllerin daha iyi tespit edilebilmesi hususunda son derece önemli bir yardımcı olarak görülen BDT sistemleri, radyologlara akciğer kanserinin erken teşhis edilebilmesi için ikinci bir görüş sunabilmektedir. Ayrıca akciğer kanserinin erken safhalarda tespit edilebilmesi için Bulanık C-Ortalama kümeleme ve Hopfield Sinir Ağı (HSA) olmak üzere iki adet bölümlenme yöntemi geliştirilmiştir (Celeng et al., 2020). ESA yönteminin kullanılmasıyla BT taramalarında görüntülenen akciğer nodülleri üzerine odaklanılmış olan bir çalışmada; LIDC ve IDRI veri tabanı görüntüleri elde edildikten sonra bu görüntüler üzerinde işlem yapılması yönündeki prensip esas alınarak, akciğer kanserinin iyi huylu ya da kötü huylu

olduđuna ilişkin sınıflandırma amacıyla Derin Sinir Ađı (DSA) tekniđinden yararlanılmıřtır.

Bir alternatif olarak akciđer kanserinin tespiti için 3D-ESA ile gerekleřtirilen bir sınıflandırma da bulunmaktadır (Alakwaa et al., 2017). Dahası, BDT sisteminden yararlanılarak BT grntlerinde yer alan akciđer nodllerinin sınıflandırıldıđı alıřmalar da ortaya konmuřtur. Ayrıca akciđer kanserinin sınıflandırılması amacıyla tasarlanan  tip DSA zerine odaklanılarak geliřtirilmiř olan bir yntem de bulunmaktadır (Skourt et al., 2018). Bir alıřmada da akciđer kanserine ilişkin belirtilerin tespit edilebilmesi amacıyla Hcresel Sinir Ađları algoritması geliřtirilmiř ve bu alıřmada ESA algoritması kullanılarak akciđer kanserinin saptanabilmesi için X-Ray grntlerinden yararlanılmıřtır (Pandiangan et al., 2019). Buradan hareketle; BT taramalarıyla akciđer kanserinin teřhisi için ESA'nın geliřtirilmesi zerine odaklanan alıřmalar da grlmektedir (Xie et al., 2018). Birtakım uygulamalar kapsamında bileřen analizi ile ok katmanlı sinir ađlarının kullanılmasıyla akciđer kanseri tespitinin yapıldıđı bilinmektedir (Mesleh, 2017). te yandan Otomatik Kodlayıcı'nın (OK) kullanımıyla %75.01 oranında dođruluk sunan bir metodoloji geliřtirilmiřtir (Shaffie et al., 2018). Akciđer kanserinin LIDC veri tabanında ok lekli iki katmanlı ESA tekniđiyle alıřılmasına imkn veren ve yapılan deneylerde %86,84 oranında bařarı elde edilmesini sađlayan bir metot olduđu da bilinmektedir (Song et al., 2017).

Akciđer nodllerinin 3D-ESA tekniđi kapsamında sınıflandırılmasını hedefleyen bir yntemde ise veri kmesi n iřleme tabi tutulmadıđı için ıkan sonular beklentiyi karřılamamıřtır. Ayrıca akciđer nodllerinin iyi huylu mu yoksa kt huylu mu olduklarını ayırt edebilmek amacıyla YSA topluluk řeması kullanılan bir yntem de nerilmiřtir (Ardila et al., 2019). nerilen yntemden elde edilen deneysel sonular neticesinde, řemanın %78,7 oranında sınıflandırma dođruluđuna sahip olduđu grlmřtr. Yaptıkları deneylerde YSA modelinden yararlanan bařka bilim insanları (Mirsky, Y., vd. (2019), Jin, D., vd. (2018)) da bulunmaktadır (Mirsky et al., 2019). Buradan hareketle; akciđer kanserini LIDC veri tabanında ok lekli iki katmanlı ESA zerinde ele alan ve dođruluk oranı %86,84 řeklinde kaydedilen alıřma dikkat

çekmektedir (Wang et al., 2018). 39 örnek üzerinde yapılan bir başka çalışmada ise küçük boyutlu pulmoner nodüllerin tespitinde %80-86 oranında duyarlılık oranına ulaşıldığı belirtilmiştir (Avanzo et al., 2020). Wang vd., YSA gelişimi amacıyla; gizli katmanlardaki nöron sayılarının veya kullanılan evrimsel algoritmaların gelişimi üzerine yoğunlaşmıştır (Wang et al., 2017). Bazı çalışmalar, her nöron çıktısının belirlenmesini sağlayan Öğrenme Aktarımı (ÖA) fonksiyonlarının evrimini içermemektedir. Fakat söz konusu çalışmalardan birinde; aynı problem, araştırmacıların Diferansiyel Evrim (DE) algoritmasını kullanmasıyla çözülmüş ve yeni bir Parçacık Sürü Eniyilemesi (PSE) modeli önerilmiştir (Weng et al., 2017). Söz konusu çalışmalardan bir diğesinde ise; araştırmacılar tarafından Yapay Arı Kolonisi (YPK) kullanılarak iki farklı kondisyon fonksiyonuna sahip bir YSA tasarımı geliştirilmiştir (Chen & Shen, 2017).

Bunlara ek olarak son yıllarda Takviyeli Öğrenim (TÖ) yönteminden yararlanılarak, ideal tasarımlar aramak amacıyla tekrarlanan sinir ağlarının kullanımına katkıda bulunulmuştur (Gong et al., 2019). Ayrıca bir başka çalışmayla da %86 doğrulukla akciğer nodülünü sınıflandıran derin bir ESA tasarımı geliştirilmiştir (Dey et al., 2018). Bu çalışmada, BT görüntülerinden çeşitli akciğer dilimlerini içeren bir veri seti kullanılmıştır. Çalışmada, altı farklı akciğer kanseri varyantına ilişkin görüntü alınarak deneyler yapılmıştır. Diğer bir çalışmada ise akciğer kanseri görüntülerinin BT veri seti kullanılarak benign veya malignite olarak ayırt edilebilmesi için AlexNet'ten faydalanılmıştır (Sajja et al., 2019). Çalışmadan elde edilen sonuçları tanımlayabilmek amacıyla yüksek çözünürlüklü görüntüler elde etmek için çeşitli teknikler (DÖ, TBA) üzerine odaklanılmışlardır.

Yukarıda ifade edilen bilgilerden hareketle; görüntü işleme algoritmalarına ilişkin algılama becerilerinin var olan tanı yöntemlerine göre daha erken algılamaya izin verdiklerinin kanıtlandığı söylenebilir. Söz konusu kanıtlara dayanarak araştırmacılar tarafından, kanser türünü herhangi bir belirtiyeye sebep olmadan önce yakalayabilmek için erken safhalarda tarama gibi farklı yöntem ve teknikler uygulanmıştır. Dahası, akciğer kanserinin tedavisiyle ortaya çıkacak olan sonucun erken tahmini için de yeni konseptler geliştirilmiştir. Farmasötik alanındaki yeni gelişmelere ilişkin yaklaşımlarla çok sayıda

malignite bilgisi toplanarak, restoratif arařtırma grubu tarafından eriřilebilir hale getirilmiřtir. Bylece her ne olursa olsun testlerden elde edilecek sonulara iliřkin kesin bir kt sonu beklentisi dikkat ekici bir Őekilde doktorların gzne arpmaktadır. Tm bu sebepler neticesindeyse D teknikleri bir seenek haline gelmiřtir. D teknikleriyle karmařık veri kmeleri arasındaki baėlantılar ve rnekler bulunabilir, tanınabilir ve bir tmr trnn gelecekteki muhtemel sonuları ngrlebilir.

alıřmanın bu blmnde deėinilen arařtırmalar; ne ıkan bir model, genomik ve klinik gibi karıřık bilgi kombinasyonlarını iermektedir. Deėinilen birka arařtırmada grlen tipik bir eksiklik olarak, modellerin nceden oluřturulmasına ynelik bir dıř onay mekanizması ya da testin olmayıřı sylenebilir. Dolayısıyla sz konusu eksiklikten hareketle; D stratejilerinin kullanılmasıyla hastalıėın zayıflaması, tekrarlaması ve hastanın hayatta kalması hususlarında yapılan tahminlerin kesinlik yzdelerinin arttırılabilmesi mmkndr. Aynı Őekilde son zamanlarda D stratejileri esas alınarak gerekleřtirilen tmr arařtırmalarında da kesinlik aısından %15-20 oranları arasında bir artıř grlmřtir. Sonu olarak BDT algoritmaları aracılıėıyla akciėer kanserinin ikili sınıflandırılmasında etkinliėini yitirip yerini tamamen D'ye bırakmıřtır.





### 3. VERİ VE YÖNTEM

Çalışmanın bu bölümünde; deneylerde kullanılan verilere, kullanılan bu verilerin güvenilirliğine, elde edilmelerine ve verilerin kullanılabilir düzeye getirilmelerine ilişkin başlıklar yer almaktadır.

#### 3.1 Deneylerde Kullanılan Veri Kümeleri ve Yönetimi

BT görüntüleri ile akciğer kanseri tanısı koymak için kullanılan DÖ algoritmasının, ne derece başarılı olduğunun test edilebilmesi ve BDT yönteminden daha iyi olduğunun deneysel olarak ölçülebilmesi amacıyla KAM veri tabanlarına ait çeşitli veri kümelerinden faydalanılmıştır (Kumar et al., 2015). Faydalanılan söz konusu veri kümelerine ilişkin bilgilere takip eden alt başlıklarda değinilmiştir.

- **Kanser arşiv merkezi:**


Çalışmada kullanılan veri seti, İnternet'te yayınlanmış olan KAM'dan elde edilen akciğer BT taramalarına ait DICOM görüntüleridir. Dolayısıyla bir etik komite onayına ve aydınlatılmış onama gerek duyulmamıştır. Çalışmanın veri seti, toplam 26.254 hastalık şüphesi taşıyan bireyden alınan 639.598 BT göğüs görüntüsünden oluşmaktadır. Ağustos 2002-Nisan 2004 yılları arasında, yaklaşık 54.000 katılımcıdan alınan söz konusu görüntüler; KAM BT veri seti testlerine ilişkin kontrollü bir klinik araştırmasına aittir. Katılımcılar eşit oranlarda (rastgele olacak şekilde) iki gruba ayrılmıştır. İlk gruptan düşük doz helisel BT alınırken ikinci gruptan tek görüntülü göğüs radyografisi alınmıştır. Ortalama takip süresi 6,5 yıl süren bu çalışmadan elde edilen BT veri seti ile ortaya çıkan kanserlerin teşhis edilme durumları ve ölüm oranları hakkında bilgiler edinilmiştir. Çalışmadan elde edilen BT veri seti, BT cinsinden ve toplam 26.254 hastalık şüphesi taşıyan birey üzerinde gerçekleştirilen 73.118 çalışma neticesinde oluşturulan 13 TB veriden meydana gelmesine rağmen

çalışma için yalnızca 124 GB (Eğitim ve Test verisi dengelenmiş) veriden faydalanılmıştır. Aşağıdaki Çizelge 1.1’de veri özellikleri gösterilmektedir.

**Çizelge 3.1:** Veri kümesinin özellikleri

Veri	Özellikleri
Katılımcı sayısı	54.000
Modaliteler	BT
Çalışma Sayısı	1308
Görüntü Sayısı	639.598
Boyut	124 GB

Aşağıda verilmiş olan Şekil 3.1’de farklı akciğer BT görüntüleri bulunmaktadır. Şekil 7’de yer alan görüntülerde sırasıyla a) kötü huylu, b) iyi huylu, c) nodül yok ve d) normal BT görüntüleri yer almaktadır.



**Şekil 3. 1:** a) Kötü huylu, b) İyi huylu, c) Nodül yok, d) Sağlıklı görüntüsü

Farklı BDT sistemlerinin karşılaştırılmasını sağlayarak, gelişimlerini teşvik etmek amacıyla KAM imaj veri tabanı konsorsiyumu birçok alan için veri seti sağlamaktadır. KAM, akciğer nodülleri akredite ve halka açık torasik BT taramaları veri tabanıdır. Aşağıda verilmiş olan Şekil 3.2’de, KAM veri kümesindeki aynı BT taramasından elde edilen farklı sonuçlara ilişkin örnek görüntüler gösterilmektedir.



**Şekil 3.2:** KAM’da yer alan aynı BT taramasından elde edilen farklı sonuçlar


Şekil 3.2’de yer alan görüntülere ilişkin her tarama, radyologlar tarafından incelenerek işaretlenmiştir. Şekilde de görüldüğü üzere, BT görüntülerinin dengeli olmasına özen gösterilmiştir. Denge problemi olan veriler ise Rastgele

Üst Örnekleme (RoS) ve Rastgele Alt Örnekleme (RuS) teknikleri kullanılarak dengeli hale getirilmiştir.

- **BT görüntü veri seti kullanımı:**


Herkesin erişimine açık olmaları sebebiyle eğitim ve test için uygun veri örnekleri sağlayan KAM veri setleri; hasta sayısı, tarama başı dilim sayısı, dilim kalınlığı, dilim aralığı vb. konfigürasyonlar açısından değişkenlik göstermektedirler. Fakat tüm bu değişkenlere rağmen hepsi için esas görev sabit kalmaktadır. Esas görevin sabit kalmasına ilişkin sorunu çözmeye süreç genellikle iki adımdan oluşmaktadır. Söz konusu adımlardan ilki şüpheli nodüllerin tespit edilmesi, ikincisi ise yanlış sonuçların azaltılmasıdır. Tek adımlı nodül tespitine göre iki adımlı bu süreç ile daha iyi sonuçlar alındığı açıkça kanıtlanmaktadır. Nodüllerin tespit edilmesine ilişkin adım, nodül olmadıkları halde nodülmüş gibi yorumlanan yapılara (kan damarları gibi) karşı yüksek duyarlılığının bulunmayışı sebebiyle çok sayıda yanlış sonucu meydana getirebilmektedir. Bu sebeple de ikinci bir adıma gerek duyulmuştur. Söz konusu ikinci adım, sürece ilişkin nihai performanstan sorumlu olan nodüllerin sınıflandırılmasını temel almaktadır.

BT görüntüleri sayesinde akciğer kanserinin saptanması ve tanısı kolaylaşmıştır. Bir araştırmada BT ile yapılan taramanın akciğer kanseri tanısını standart akciğer grafisine kıyasla yaklaşık %80 artırdığı ifade edilmektedir (National Lung Screening Trial Research Team 2019). Araştırmaya ilişkin tarama süreci, yüksek risk grubuna (sağlık durumunun iyi olduğu düşünülen mevcut veya çok miktarda tütün ürünü kullananlar) tomografi çekilmesini kapsamaktadır. Araştırmada BT kullanımı ile tehlikeli nodüllerin tespit edilebildiği ve de akciğerlerde oluşan nodüllerin erken evrede olduklarında, tedaviyi gerçekleştirmek için yeterli zaman sağlanabildiği belirtilmektedir. Araştırma neticesinde 5 yıllık sağkalım oranının %80'inden fazlası cerrahi olarak tedavi edilen periferik akciğer kanseri kapsamında rapor edilmiştir (Yip et al., 2018). Aynı araştırmada, BT sayesinde doktorlar tarafından çapı 2 cm'den küçük akciğer tümörlerinin tespit edilebilmesinin sağlandığı da ifade edilmektedir. Aşağıda verilen Şekil 3.3'te söz konusu araştırmada yer alan çapı 2 cm'den küçük BT taramalarına ait görüntüler gösterilmektedir.



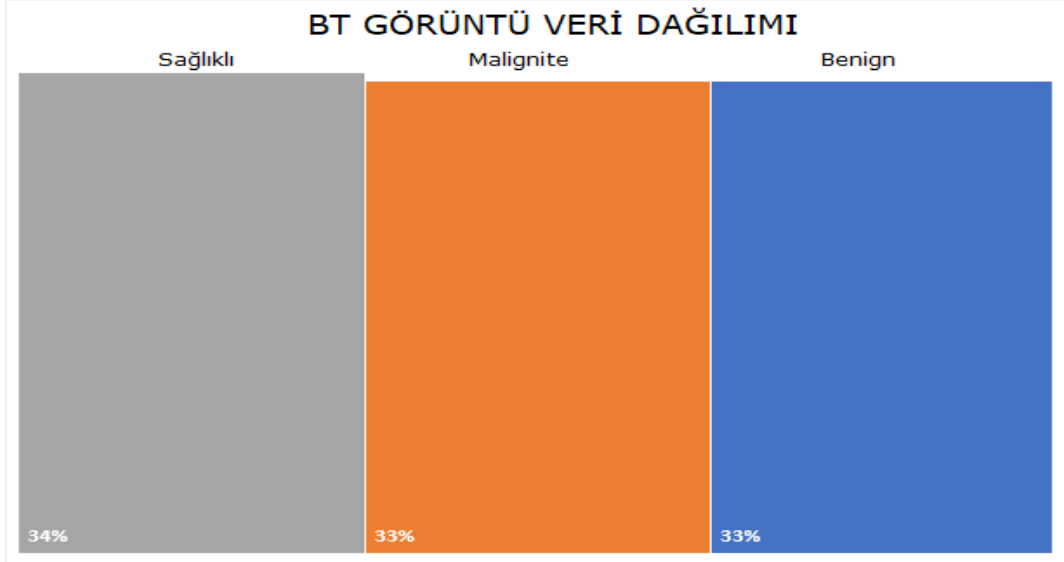
**Şekil 3.3:** Çapı 2 cm'den küçük BT taramaları

KAM veri tabanında bulunan 639.598 taramadan yalnızca dilim kalınlığının 2,5 mm'den küçük olanlar incelemeye kayda değer görülmemiştir. 2,5 mm'den büyük tüm pozitif tüm nodüller 4 radyologdan en az 3'ü tarafından kabul edilmiştir. Aşağıda verilen Şekil 3.4'te nodül olarak kabul edilmeyen BT tarama görüntüleri gösterilmektedir.



**Şekil 3.4:** Nodül olarak kabul görmeyen BT taramaları

Şekil 3.4'te yer alan görüntülerde; üç boyutlu görüntünün merkezinde konumlandırılmış lezyon ve lezyonun etrafında çok fazla gürültü bulunmaktadır. Nodüller farklı büyüklükte olabileceğinden, bazı dilimler temel olarak arka plandan oluşur ve genellikle üç veya beş dilimle sınırlıdır. Öte yandan iki boyutlu verilerle çalışabilmek için pozitif sınıf olarak yalnızca nodül içeren adaylardan gelen dilimlerin etiketlenmesi gerekmektedir. Şekil 3.5'te Benign, malignite ve sağlıklı BT verisinin korelasyonu gösterilmektedir.



**Şekil 3.5:** Benign, malignite ve sağlıklı BT verisinin korelasyonu

Yukarıda verilen Şekil 3. 5'te verilen BT görüntü dağılımında yapılan çalışmada pozitif veri ile negatif veri arasında bir korelasyon olduğu gözlemlenmektedir. Elde edilen BT veri kümesinin %34'ü sağlıklı, %33 malignite ve geriye kalan %33 ise benign veriden oluşmaktadır.

Ayrıca Eğitim veri setinde yanlış etiketlenmiş veri olup olmaması incelenmiş ve yanlış etiketli veri bulunması durumunda yapılması gereken adımlar tartışılmıştır. Bunun sonucunda voksellerden daha çok yararlanılmıştır.

### 3.2 Deneylerde Kullanılan Araçlar

Bu başlık altında çalışmada kullanılan araçlara ilişkin detaylı bilgiler yer almaktadır. Deneylerde kullanılan araçlar detaylı bir şekilde işlenmiştir.

#### 3.2.1 Makine öğrenimi

MÖ, bilgisayarın gelecekte meydana gelebilecek benzer olaylar hakkında kararlar alabilmesi ve bir olay hakkında edinilen bilgi ve tecrübeyi öğrenerek oluşacak sorunlara çözüm üretebilmesidir. MÖ bazı yöntemler kullanarak geçmiş verilerden yararlanır ve yeni veriler için en uygun modeli bulmaya çalışır. Böylece geçmiş verileri kullanarak gelecekteki durumlar için tahminlerde bulunabilmektedir. Büyük miktarda veriyi manuel bir şekilde işleyerek analiz etmek çok zordur. MÖ'nün tahminde bulunmak ve karar vermeye yardımcı olabilmek amacıyla büyük miktarda veriyi analiz etmedeki

yeteneđi sayesinde uygulama alanı her ne olursa olsun MÖ yöntemlerinin önemi gün geçtikçe artmaktadır. Fakat MÖ'nün kullanımında meydana gelen bu artışa rağmen; MÖ'nün bir alt dalı olan DÖ, son yıllarda var olan avantajları sebebiyle daha çok kullanılan bir yöntemdir. Bugün çok sayıda kullanım alanına (görüntü işleme, duygu analizi vb.) sahip olan DÖ sistemleri, modern toplumu pek çok yönden güçlendiren teknolojik sistemlerdir. DÖ'de büyük ilgi uyandıran MÖ sistemleri görüntü işleme amaçlı; Görüntülerde nesnelere tanımlamak, konuşmayı metne dönüştürmek, ilgili arama sonuçlarını seçmek için de çokça başvurulan bir yöntemdir (Burkov, 2019). Genellikle bir sınıflandırıcı olan öğrenme alt sistemi, girdilerdeki kalıpları algılama veya sınıflandırma gibi işlemleri gerçekleştirebilmektedir. Bir makinenin ham verilerden beslenmesini ve sınıflandırma, kümeleme algoritmalarını algılama için gereken temsilleri otomatik olarak keşfetmesini sağlayan yöntemle Temsili Öğrenme denir. DÖ yöntemleri, birden çok temsil düzeyine sahip olan temsil öğrenme yöntemleridir. Ham girdiden başlayarak, her biri temsili düzeyde daha yüksek ve biraz daha soyut düzeyde bir temsile dönüştürülen basit fakat doğrusal olmayan modüller oluşturmaktadırlar. Söz konusu bu özellik katmanlarına tasarımcı tarafından çok fazla müdahale edilmesi yerine genel amaçlı bir öğrenme prosedürü kullanılarak verilerden sınıflandırmayı öğrenilebilmesi DÖ'nün kilit yönünü oluşturmaktadır. Bu tür dönüşümlerin yeterli düzeydeki bileşimi sayesinde çok karmaşık fonksiyonlar öğrenilebilir. Ayrıca sınıflandırma görevleri için daha yüksek temsil katmanları sağlarken; girdi için önemli olan yönleri güçlendirmekte ve ilgili olmayan varyasyonları da bastırmaktadır.

Örneđin; bir dizi piksel değeri biçiminde gelen bir görüntüye ilişkin ilk gösterim katmanındaki öğrenilen özellikler, özgün bir şekilde görüntüdeki belirli yön ve konumlara dair kenarların varlığını veya yokluđunu temsil etmektedir. İkinci katman; kenar konumlarındaki küçük deđişikliklerden bağımsız olarak özgün bir şekilde, belirli kenar düzenlemelerini tespit edip motifleri algılamaktadır.

YZ ile ilgili en yenilikçi girişimler karşısında bile direnç gösteren problemlerin çözülebilmesinde büyük gelişmeler kaydedilmesine katkıda bulunan DÖ, boyutları yüksek verilerin karmaşık yapılarını keşfedebilme hususunda oldukça

başarılı olması sebebiyle bilim ve iş dünyası gibi pek çok alanda ilgi görmektedir. Daha önce de ifade edildiği gibi geleneksel MÖ tekniklerinin yetenekleri, sadece doğal verileri ham formlarda işleyebildikleri için oldukça sınırlıydı. Bir MÖ sistemi oluşturmak veya örüntü tanımak için ham verileri uygun bir dâhili formata veya özellik vektörüne dönüştüren bir özellik çıkarıcı tasarlamaya ihtiyaç duyuluyordu; bu da dikkatli bir mühendislik ve önemli bir alan uzmanlığı gerektiriyordu. DÖ'nün kilit yönü, bu özellik katmanlarının tasarımcının çok da müdahil olmamasıdır. Genel amaçlı bir öğrenme prosedürü kullanılarak verilerden öğrenilirler. DÖ, yıllardır YZ topluluğunun en iyi girişimlerine bile direnen sorunların çözümünde büyük ilerlemeler kaydedilmesini sağlamaktadır.

MÖ'de tercih edilen en yaygın teknik derin olması veya olmaması fark etmeksizin denetimli öğrenmedir. Örneğin; bir araba, ev, kişi veya evcil bir hayvana ilişkin görüntüleri sınıflandırabilecek bir sistem kurulmak istendiğinde; ilk olarak bunların her birinden, kendi kategorisiyle etiketlenen geniş bir veri görüntü seti toplanılmaktadır. Eğitim aşamasında söz konusu bu görüntülerden biri makineye öğretilerek, her kategori için bir adet çıktı vektörü olacak şekilde bir çıktı üretilmektedir. Daha sonra söz konusu görüntülere ilişkin kategoriler arasında herhangi bir kategorinin diğerlerine göre daha yüksek puana sahip olması istenebilir ancak eğitimden evvel böyle bir durumun gerçekleşebilmesi mümkün olmamaktadır. Sonuç olarak istenen çıktı ile elde edilen çıktı skorları arasındaki hatayı ölçümleyen bir objektif fonksiyon hesaplanmaktadır. Hesaplama sonrasında, parametreler ayarlanabilir veya hatayı azaltabilmek amacıyla dâhili parametreler değiştirilebilir. Bu parametreler genellikle "ağırlık" (weights) olarak adlandırılmaktadır. Sıradan bir DÖ sisteminde, makineyi eğitmek amacıyla bu ayarlanabilir ağırlıklara ilişkin yüz milyonlarca etiket olabilir.

Öğrenme algoritması, her bir ağırlık için ağırlığın az miktarda artırılmasıyla hatanın ne miktarda azalacağını veya artacağını belirten bir gradyan vektörü hesaplaması yapmaktadır. Daha sonra gradyan vektörünün ters yönünde bir ağırlık vektörü ayarlanmaktadır. Tüm eğitim örnekleri üzerinde objektif fonksiyonun ortalaması alınmaktadır. Böylece objektif fonksiyon, ağırlık

değerinin yüksek boyutlu uzayında bir tür tepelik manzara şeklinde görülebilmektedir.

### 3.2.2 Derin öğrenme

Son yıllarda öne çıkmaya başlamış olmasına rağmen DÖ terminolojisi aslında 1950'li yıllara dayanan yaklaşık 70 yıllık bir geçmişe sahiptir. Rosenblatt tarafından üretilen ve en erken YSA'dan biri olan algılayıcının tarihi 1958'e dayanmaktadır (Jyotiyana & Kesswani, 2020). MÖ'nün özellikle görüntü işleme hususunda yetersiz kalması sebebiyle ortaya çıkan DÖ, verilen bir veri seti ile sonuçların tahmin edilmesini sağlayan ve de birden fazla katmandan oluşan bir MÖ yöntemidir. DÖ, verilen bir veri seti ile çıktıları tahmin edecek olan modelin eğitilmesine olanak tanımaktadır. Modelin eğitilmesi amacıyla denetimli veya denetimsiz öğrenmenin her ikisi de kullanılabilir. Denetimli öğrenme, girdiler ve beklenen çıktılara ilişkin etiketli veri setlerinin kullanılmasını içermektedir. Örneğin; bir model eğitilirken denetimli öğrenme kullanıldığında, ona bir girdi verilmekte ve beklenen çıktı istenmektedir. Modelin ürettiği çıktının yanlış olması durumundaysa hesaplamalar tekrar ayarlanmaktadır. Bu hesaplama işlemi, modelin hata oranı en aza indirilene kadar veri seti üzerinde tekrar tekrar yapılmaktadır. Denetimsiz öğrenme ise belirli bir yapıya sahip olmayan veri kümeleri üzerinde işlem yapılmasıdır. Bir diğer ifadeyle; model verilerin mantıksal olarak sınıflandırmasını yapmaktadır.

DÖ; görsel algı, doğal dil işleme, ses tanıma, konuşma gibi karmaşık işlemlerin bir makine tarafından yapılabilmesini ifade etmektedir. Söz konusu bu karmaşık işlemlerin yapılabilmesi yalnızca çok katmanlı bir yapı sayesinde mümkün olmaktadır. YSA aracılığıyla sağlanan bu katmanlı yapı; beşerî bilimler, bilgisayar bilimi, nöroloji, matematik ve psikoloji gibi birçok disiplinin ilgi odağı haline gelmiştir. MÖ'nün bir alt dalı olan DÖ tarafından, çok sayıda doğrusal olmayan işlem birimi katmanı kullanılarak özellik çıkarma ve dönüştürme işlemleri gerçekleştirilmektedir. Çıktı her ardışık katman için bir önceki katmandan alınarak, sonraki katmana iletilmektedir. MÖ algoritmalar denetimli ya da denetimsiz olabilir.

DÖ'nün yapısı, verilere ilişkin birden fazla özellik seviyesi ya da temsillerinin öğrenilmesine dayanmaktadır. Diğer bir ifadeyle; alt düzey özelliklerden üst



düzey özellikler türetilerek, hiyerarşik bir temsil oluşturulmaktadır. Oluşturulan bu temsil sayesinde değişik soyutlama düzeylerini karşılayan çoklu temsil düzeyleri öğrenilmektedir. Buradan hareketle; DÖ'nün, verilerin temsili sayesinde öğrenmeye dayalı bir teknik olduğu belirtilebilir. Örneğin bir görüntünün temsili için; her bir piksel başına düşen yoğunluk değerinin vektörü, spesifik şekiller ya da kenar kümeleri gibi özellikler belirtilebilir ve bu özelliklerden bazıları verileri temsil etme hususunda diğerlerine göre daha iyi olabilir. DÖ yöntemleri, elle çıkarılan özelliklerden (handcrafted features) ziyade veriyi en uygun şekilde temsil eden hiyerarşik özelliklerin çıkarımı amacıyla otomatik etkin algoritmalar kullanmaktadır.

Genellikle DÖ görüntü tanıma ve konuşma tanımanın yanı sıra partikül hızlandırıcı verilerini analiz etme, potansiyel ilaç moleküllerinin aktivitesini tahmin etme, mutasyonların etkilerini tahmin etme ve birçok hastalığın erken tanısı gibi konular amacıyla da kullanılmaktadır. Ayrıca DÖ; özellikle konuların sınıflandırılması, doğal dil işleme, soru cevap, duygu analizi ve dil çevirisi için oldukça derece umut verici sonuçlar da üretmektedir. Basiri, M. E vd., (2020) bunu etkin şekilde kullanmışlardır. MÖ alanında yeni olmasına rağmen çok büyük başarılar gösteren DÖ, temel olarak YSA'dan esinlenilerek geliştirilmiştir. DÖ algoritmaları bugün, çok sayıda insanın bir araya gelmesiyle bile yapılamayacak olan karmaşık işleri çok daha kısa sürede ve doğru bir şekilde yapabilmektedir. DÖ algoritmalarının verilerde öznelik çıkarmak gibi bir zorunlulukları olmaması sebebiyle DÖ yöntemleri DVM ve YSA gibi geleneksel MÖ algoritmalarına göre çok daha avantajlıdır.

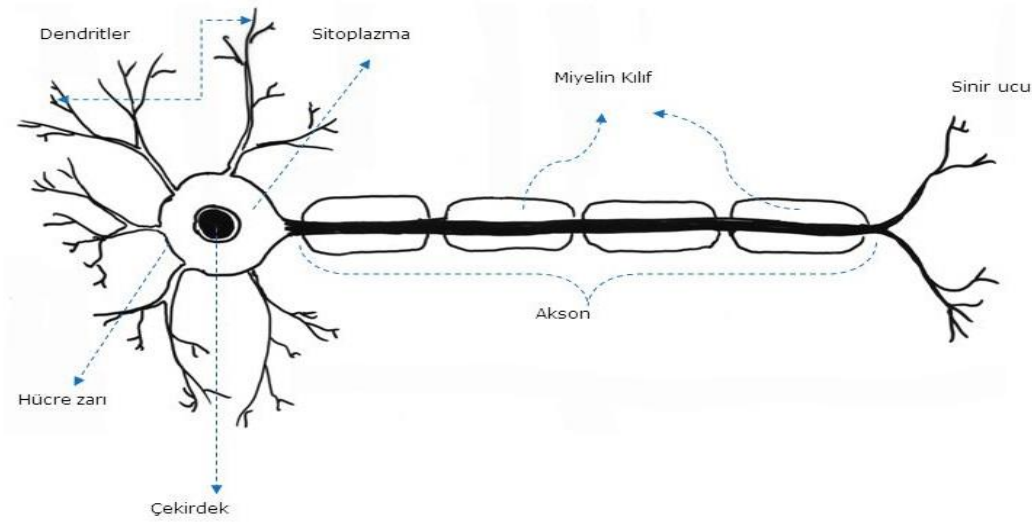
### **3.2.3 Sinir ağı**

Sinir ağları insan beyninin özelliklerini taklit ederek geliştirilen ve öğrenme yoluyla yeni bilgiler türetebilme veya yeni bilgiler oluşturabilme yeteneğidir. Sinir ağları öğrenme için herhangi bir yardım almadan otomatik olarak gerçekleşen algoritmalarıdır. İnsan beyni örnek alınarak öğrenme sürecinin matematiksel olarak modellenmesi sonucunda yapay sinir ağları ortaya çıkmıştır. Beyindeki biyolojik sinir ağlarının yapısını, öğrenme, hatırlama ve genelleme yeteneklerini taklit eder. Yapay sinir ağlarında öğrenme süreci

örnekler kullanılarak gerçekleştirilir. Öğrenme sırasında girdi ve çıktı bilgileri verilerek kurallar belirlenir.

### Nöronlar:

YSA'yı teorik açıdan anlayabilmek ve çalışma şeklini çözümlenebilmek için biyolojik sinir ağı ve biyolojik nöron sistemlerinin yapıları araştırılmalıdır. Nöronlar; elektriksel açıdan uyarılabilen ve bilgileri elektrik sinyali aracılığıyla işleyerek iletebilen hücrelerdir. Tipik bir nöron; soma, dendritler ve akson olmak üzere üç bölgeye ayrılmaktadır. Çoğu nöron, dendritleri yoluyla giriş sinyalleri almaktadır. Aşağıda verilen Şekil 3.6'da girdi, gizli katman ve çıktı katmanlarından oluşan bir sinir hücresinin temsili gösterilmektedir.



**Şekil 3.6:** Bir sinir hücresi yapısı

**Kaynak:**(Da Silva et al. 2017)

Giriş sinyalinin bir hareket potansiyeli yaratması durumunda, nöron sinyali akson üzerinden gönderilmektedir. Pek çok akson, aksiyon potansiyelinin hızlı iletimini sağlayan bir miyelin kılıfı ile kaplıdır. Nöron aksonunun diğer nöronların dendritlerine bağlı olması sebebiyle bir nöron diğer nöronları uyarabilmektedir. Bilgi, "nörotransmitter" denilen kimyasal haberciler şeklinde aktarılmaktadır. Nörotransmitter denilen kimyasal haberci molekülleri de sinapstan geçerek diğer nöronları etkilemektedir. Vücutta bulunan sinir ağı yapısının oluşabilmesi için bu nöronların bir araya gelmeleri gerekmektedir.

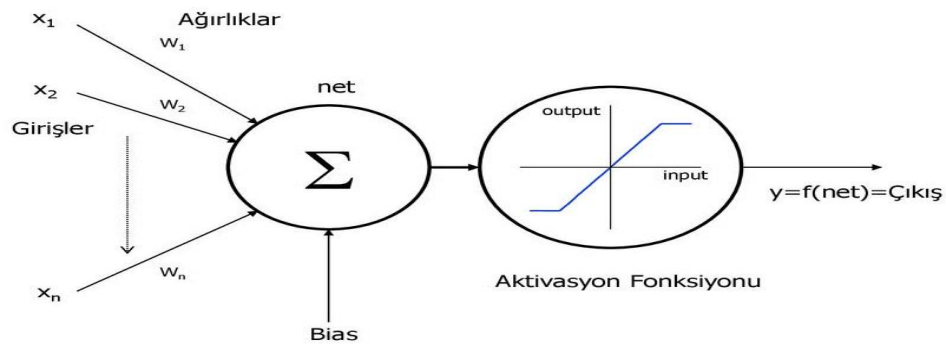
Yetişkin bir insan beyninde ortalama 100 milyar nöron bulunmaktadır. Bu nöronlar kendi aralarında yaklaşık 10 bin bağlantı oluşturmaktadırlar. İnsanın zeki olmasını sağlayan ve insan beynini diğer canlıların beyinlerinden ayıran temel fark budur. Yapay nöronların ağı olan YSA ise; biyolojik nöronların oldukça basitleştirilmiş bir modelidir ve bu durum MÖ açısından YSA'nın gücünü açıkça ortaya koymaktadır. Ayrıca DSA sistemlerindeki nöron sayısı ile insanlardaki nöron sayısını karşılaştırmak mümkün değildir.

### Algılayıcı:

F. Rosenblatt tarafından üretilen ve ilk YSA'dan biri olarak kabul edilen algılayıcının (algılayıcı) tarihi 1958'e dayanmaktadır. Rosenblatt tarafından algılayıcının; insanlar verileri duyuları aracılığıyla nasıl algılamakta ve öğrenmektedir, bilgiler nasıl saklanabilir ve hatırlanabilir ve bu süreç matematiksel olarak nasıl ifade edilebilir şeklindeki bazı teorik sorulara bir cevap ararken ortaya çıktığı belirtilmektedir (da Fonseca, 2013). Dolayısıyla algılayıcı, ikili bir sınıflandırıcıyı öğrenmek amacıyla geliştirilen bir tür algoritmadır. Biyolojik bir nöronun basit matematiksel bir modeli olan algılayıcının çıkışı aşağıda yer alan Denklem 3.1'de gösterilmektedir:

$$f(x) = \begin{cases} 1, & \text{if } w \cdot x + b > 0, \\ 0, & \text{otherwise,} \end{cases} \quad (3.1)$$

Denklem 3.1'de görüldüğü üzere;  $f(x)$  nöronun çıktısını,  $w$  gerçek değerli ağırlıkların bir vektörünü;  $w \cdot x$  ağırlık vektörünün nokta çarpımını ve  $b$  ise sapmayı ifade etmektedir. Aşağıda verilen Şekil 3.7' de algılayıcının yapısı gösterilmektedir.



Şekil 3.7: Basit algılayıcının yapısı

**Kaynak:** (Tang et al., 2015)

Tek bir algılayıcı giriş katmanı, hesaplama katmanı ve çıkış katmanı olmak üzere 3 bölümden oluşmaktadır. Algılayıcı bir ya da birden fazla girdi alarak, hesaplama katmanı sonucuna göre bir çıktı üretmektedir. Rosenblatt tarafından giriş katmanındaki her bir ağırlık  $w_1, w_2, \dots, w_n$  ve her bir katman ise  $x_1, x_2, \dots, x_n$  şeklinde belirtilmiştir (da Fonseca, 2013). Giriş katmanındaki her bir ağırlık ve katman için tanımlanan bu değerler gerçek sayıları ifade etmektedir. Ağırlık, algılayıcı modeline belirli bir amaç doğrultusunda çıktı üretim yeteneği kazandırdığı için oldukça önemlidir. Algılayıcı, "1"ler ve "0"lardan oluşan bir değer üretmektedir. Giriş katmanında ağırlık değerleri optimize edilip ağırlıklar yeniden hesaplanır ve bunun toplamına polarizasyon değeri eklendiği zaman eğer sonuç eşik değerinden büyük ise algılayıcı "1" küçük ise "0" olmaktadır. Aşağıdaki denklemde girdi değerleri ile ağırlıklar arasında hesaplamalar yapılarak, elde edilen sonuçların eşik değeri ile toplanmasıyla bir çıktı elde edilmektedir.

$$x = \sum_j w_j x_j + b \quad (3.2)$$

$$y = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

Denklem 3.2'de görüldüğü üzere;  $X_j$  girdi katmanını,  $y$  çıktı katmanını,  $b$  kutuplama (bias) değerini ve  $W_j$  ise ağırlıkları ifade etmektedir. İlk etapta her ne kadar umut verici olsa da bu algoritmanın birçok görev için yetersiz kaldığı görülmüştür. Bu algoritma, doğrusal olmayan bir fonksiyon olmasına rağmen giriş alanını hiper bir düzlem ile ayırmaktadır. Dolayısıyla bir veri kümesinin doğrusal olarak ayrılabilmesi algılayıcı algoritmasının birleşmeyeceği anlamına gelmektedir. Buradan hareketle; 1969 yılında Papert ve Minsky tarafından yayımlanan algılayıcı adlı kitapta da algılayıcıya yönelik bir sorun olan temel algılayıcıların sınıflar doğrusal olarak ayrılabilirken sınıfları ayıramaması üzerine odaklanılmıştır (Minsky & Papert, 2017).

MÖ'de bilgisayarların yeterli işlem gücüne sahip olmaması sebebiyle bir duraklama dönemi meydana gelmiştir. Bilgisayarların yeterli işlem gücüne sahip olmaması, büyük sinir ağlarının etkin biçimde işlenemeyeceği anlamına gelmektedir. Uzun yıllar süren yetersizlik kaynaklı bu durum, sinir ağı alanına olan ilgi ve alakayı olumsuz yönde etkilemiştir. Stephen Grossberg tarafından yayınlanmış olan XoR fonksiyonlarını öğrenebilen ağlara ilişkin bir dizi

makaleye rağmen söz konusu duraklama süresi 1980'lere kadar devam etmiştir (Keller et al., 2016). 1980 yılında Fukushima tarafından, orijinal algıyla uzantılı hiyerarşik çok katmanlı bir YSA olan Neocognitron tanıtılmıştır (Basiri et al., 2020). O zamanlar Neocognitron, el yazısı rakamları tanımada kullanılmış ve oldukça iyi bir performans göstermiştir. Fakat her ne kadar Neocognitron sayesinde sinir ağlarına yönelik ilgi artmış olsa da bu tür büyük modellerin nasıl eğitileceği bir sorun olarak görülmeye devam etmiştir. Modelleri eğitmek amacıyla kullanılan geri yayılım algoritması 1970'lerden beri bilinmesine rağmen; Chakraborty tarafından yaklaşık 16 yıl sonra 1986 yılında standart geriye yayılım algoritması çok katmanlı YSA'ya uygulanmıştır (Chakraborty & Goswami, 2017).


Bugün uzun-kısa süreli bellek ağı, pek çok doğal dil işleme ve dizi modelleme görevinde yaygın şekilde kullanılmaktadır. Teknolojinin gelişmesiyle birlikte grafik ve çekirdek modeller gibi diğer MÖ alanlarındaki birçok önemli görevde de iyi sonuçlar elde edilmeye başlanmıştır. Bilgisayar teknolojisindeki gelişmeler ve DÖ tekniklerinin hızla yükselmesi YSA'nın popüleritesinde düşüşe sebep olmuştur. Bu düşüşün ardından, sinir ağlarının eğitilmesinin oldukça zor olduğuna inanılmaya başlanmıştır. Fakat 2006 yılında Geoffrey Hinton tarafından derin inanç ağı adı verilen bir yöntem ortaya atılmıştır (Cifci & Aslan, 2020). Ortaya atılan bu yöntem ile test örneklerinin genelleştirilmesi önemli ölçüde artırılmıştır. Takip eden süre zarfında ise Grafik İşlem Birimleri (GPU) üzerine uygulanarak, paralel programlama ve daha hızlı matris çarpımları sağlayan ESA ve YSA geliştirilmiştir. Sonuç olarak, araştırmacılar tarafından daha önce mümkün olmayan daha derin bir YSA eğitilmiştir.

2012 yılında (Krizhevsky et al., 2017) tarafından, yüksek çözünürlüğe sahip olan 1,3 milyon görüntüyü sınıflandırabilmek amacıyla derin bir ESA eğitilmiştir. Bu sayede de ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC-2012) oldukça başarılı bir sonuca imza atmışlardır. DÖ teriminin yaygınlaşması hususunda sinir ağlarının araştırılması önemli derecede etkili olmuştur. Bugün; DSA, doğal dil işleme, görüntü tanıma, konuşma tanıma, ses sınıflandırma vb. görevler için DÖ teknikleri, MÖ teknolojileriyle ilişkili diğer YZ sistemlerine oranla daha iyi performans göstermektedirler. Bunun yanı sıra gün geçtikçe çeşitli görevlerde gelişim

göstermeye ve performanslarını arttırmaya da devam etmektedirler. Söz konusu performans artışı ve gelişimin temel sebeplerinden biri, daha fazla veri toplanmasının daha fazla teknoloji kullanımıyla mümkün olabilmesidir. Dolayısıyla DÖ algoritmaları büyük oranda verilerin hacmine bağlı olmaları sebebiyle daha iyi performans göstermektedirler. Söz konusu performans artışı ve gelişimin temel sebeplerinden bir diğeri ise artan mikroişlemci ve GPU gücünün aynı anda çok fazla veriyi işleyebilmesi ve buna bağlı olarak da çok daha hızlı sonuç elde edilebilmesidir. Bu durum, algoritmalar üzerinde daha fazla değişiklik ve deneme yapılmasını sağlayarak, en uygun model için çok daha hızlı bir yakınsama oluşturmaktadır.

### Çok katmanlı algılayıcı:

En az 3 düğüm katmanından oluşan çok katmanlı algılayıcı (ÇKP) bir çeşit ileri beslemeli YSA'dır. Söz konusu katmanlardan ilki "giriş katmanı", ortadaki "gizli katmanlar", son sonuncusu ise "çıkış katmanı" şeklinde ifade edilmektedir. Şekil 3. 8'de Çok katmanlı ağ yapısı gösterilmektedir.



Şekil 3.8: Çok katmanlı ağ yapısı

ÇKP sisteminde, giriş ve çıkış düğümlerine ilişkin sayı verilere göre belirlenmektedir. Gizli katmanlar ile gizli katmanlarda yer alan düğüm sayıları tasarım sorunu olabilmektedir. Literatürde gizli katmanların sayısını belirleyebilmek amacıyla oluşturulmuş genel bir formül yer almamaktadır. Fakat elde edilen deneyimler neticesinde; gizli katman sayılarının artırılmasıyla eğitim hatalarının azaltılabileceği, algoritma karmaşıklığının artabileceği ve sistemin genelleme yeteneği açısından bir azalma görülebileceği söylenebilir (Lakshmanaprabu et al., 2019). Bunların yanı sıra gizli katman sayılarının artırılmasıyla sistem tarafından ağırlıkların

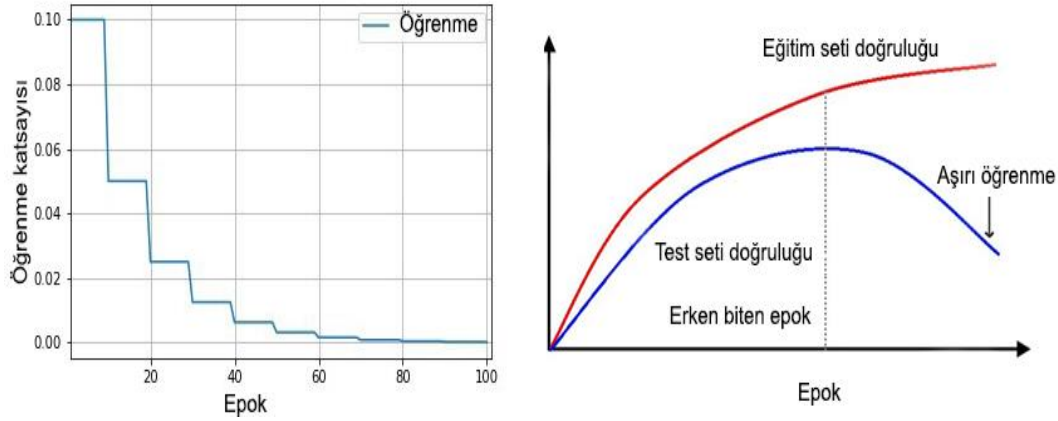
güncellenemediği ve daha fazla yerel minimumun olduğu gözlemlenmiştir. Ayrıca bu orta katmanlarda yer alan gizli katman ve düğüm sayıları sistem açısından yeterli değilse model düzgün çalışmamaktadır. Gizli katman sayılarında olduğu gibi gizli katmanlarda yer alan düğüm sayılarını belirlemek de bir tasarım sorunudur. Çok fazla düğümün eğitimi uzatması sebebiyle ağ genelleme yeteneğini kaybedebilmektedir. Ayrıca, az sayıdaki düğümle ağın çok az bilgi kullanmak zorunda kalmasıyla da ağ karmaşık modelleri çözümleyemeyebilir. Bu hiper parametreler test sürecinde test sonuçlarına göre belirlenmektedir. ÇKP ağlarında, düğümlerde bulunan aktivasyon fonksiyonları çoğunlukla doğrusal olmayan fonksiyonlar şeklinde seçilmektedir. ÇKP ile modeli eğitirken; ileri yönde yayılım ve geri yönde yayılım olmak üzere iki temel adım bulunmaktadır. Aşağıda verilen Çizelge 3.1'de ÇKP'ye ilişkin eğitim algoritmasının özeti yer almaktadır.

**Çizelge 3.2:** Çok katmanlı algılayıcı eğitim algoritması

- 
- Ağırlıklar başlatılır.
  - Her BT görüntüsü için ileri besleme prosedürü uygulanır.
  - Ağırlıkları güncellemek için geri yayılım kullanılır.
  - Bir yakınsama oluşana kadar sırasıyla 2. ve 3. adımlar tekrarlanır.
- 

**Kaynak:** (Bello, 1992)

Global minimum değere yakınsamayı garanti etmesi, global yayılım algoritmasından beklenmemelidir. Eğitim sürecinin tamamı boyunca yerel minimaların meydana gelebilir olmaları sebebiyle eğitim süreci bu minima alanlarında sıkışabilmektedir. Yakınsamayı optimize etmenin bir yolu, uyarlanabilir öğrenme oranını kullanmaktır. Öğrenme oranının yüksek bir değerde başlayıp süreç boyunca yavaş bir şekilde azalmasıyla salınımlardan kaçınılabilmektedir. Bu global minima algoritması, yakınsama hızını arttırması olası olan uyarlanabilir öğrenme hızı tekniklerindeki en basit yöntemlerden biridir. Aşağıda verilen Şekil 3.9'da epok sayısı ve minima ilişkisi gösterilmektedir.



**Şekil 3.9:** Artan epok ile test ve eğitim doğruluğu arasındaki ilişki

Sinir ağlarının eğitiminde az sayıda epok (epoch/döngü) kullanılıyorsa model gerek yeterince öğrenemeyişi gerekse test ve eğitim seti doğruluklarının düşüklüğü sebebiyle uygun olmayabilir. Ayrıca sinir ağlarının eğitiminde çok fazla epok kullanılıyorsa da model, gereğinden fazla takılabilmesine rağmen eğitim örneklerini ezberleyebilir. Fakat aşırı öğrenme, eğitim seti doğruluğu çok iyi olsa da test setinin düşük hassasiyete sahip olduğu anlamına gelmektedir. Sinir ağları bakımından doğruluk, doğru sınıflandırılmış örnek sayısının tüm örnekler ile olan oranını ifade etmektedir. Söz konusu durumların üstesinden gelebilmek için farklı epok oranları denenerek eğitim setinin doğruluğu ile test setinin sonucu analiz edilmelidir. Şekil 15'te de görüldüğü üzere; bu analiz sayesinde kullanıcı, eğitim sürecini ne zaman durduracağını da bilebilmektedir. Modelin eğitim seti üzerinde eğitilmesi sebebiyle; eğitim seti doğruluğu ile test seti doğruluğu arasında her zaman küçük de olsa bir fark meydana gelmektedir. Meydana gelen bu farkın eğitim boyunca artış göstermesi, eğitim sürecinin sonlandırılması gerektiğine dair bir işarettir. Sinir ağlarında, eğitim öncesi verilerin ön işleme alınarak işlenmesiyle modelin daha hızlı öğrenme ve daha iyi performans gösterdiği görülmektedir. Ön işlemenin en yaygın biçimlerin biri ise mean yani ortalama çıkarmadır. Veriler, her öğeden ortalamanın çıkarılmasıyla her bir boyut boyunca başlangıç noktası etrafında toplanmaktadır.

Aykırı değerler açısından mean değeri çok hassas olması sebebiyle her zaman bazı sorunlara sebep olabilmektedir. Söz konusu sorunlarla başa çıkabilmek amacıyla ortanca değerler (median) ölçülmelidir. Tek başına bir ölçüm yeterli




olmadığı için ortanca değerlerin yanı sıra ortanca (mode) en sık tekrarlanan ölçüm de dikkate alınmalıdır.

Normalleştirme, aynı ölçekte olacak şekilde veri boyutunu normalleştirmeyi ifade etmektedir. Her boyutu standart sapmasına göre bölmek verileri normalleştirmenin bir yoludur. Verilerin minimum ve maksimum değerlerini bularak, verileri -1 ile 1 arasında yeniden ölçeklendirmek ise verileri normalleştirmenin bir başka yoludur. Sinir ağı başlatılırken ağırlık değerleri de bazı değerler ile başlatılmalıdır. Tüm ağırlıkların sifira ayarlanması tüm nöron çıkışlarını da aynı değerde yapmaktadır. Geriye doğru yayılım algoritmasında bu durum, aynı gradyanların hesaplanmasıyla sonuçlanarak aynı parametre güncellemelerini vermektedir. Dolayısıyla ağırlık değerleri açısından herhangi bir simetri olmaması gerekmektedir. Bu sebeple de ağı başlatılmasında, sıfır olmayan ancak sifira çok yakın ağırlıklar tercih edilmektedir. Örneğin; ağırlıkların sıfır ortalama ve birim standart sapması ile rastgele başlatılması durumunda Gaussian metodu tercih edilir. Ayrıca her sinir ağı açısından küçük ağırlıklar her zaman uygun olmamaktadır. Gradyanın ağırlıkla doğru orantılı olması sebebiyle küçük ağırlıklarda güncelleme de çok küçük olabilmektedir. Model eğitimi aşamasında meydana gelebilecek sorunları tespit edebilmek için doğruluk ve kayıp grafiklerinin ayrıntılı bir şekilde analiz edilmesi gerekmektedir.

Eğitim aşamasında aşırı öğrenmeyi önleyebilmek amacıyla seyreltme (dropout) tekniği kullanılabilir. Seyreltme tekniği, tasarlanan modelde aşırı öğrenmeyi (overfitting) engelleyebilmek için kullanılan ve de eğitim aşamasında rastgele seçilen nöronların dikkate alınmadığı basit bir yöntemdir. Bir diğer ifadeyle; seyreltme tekniği eğitim süresince aşırı öğrenmeyi engelleyebilmek amacıyla bazı nöronları unutmak için faydalanılan bir tekniktir. Teknik, büyük modellerde ve uzun süreli eğitimlerde gerçekleşen aşırı öğrenme ile başa çıkabilmek için kullanılmaktadır. Seyreltme prosedürünü uygulayabilmek için bir hiper parametre  $p$  ( $0 \leq p \leq 1$ ) belirlenmektedir. Bireysel düğümler, her eğitim aşamasında olasılık  $p$  ile tutulmaktadır.  $p$  ( $0 \leq p \leq 1$ ) adımı eğitimi esnasında, yalnızca kalan düğümler kullanılmaktadır. Eğitim adımından sonra dikkate alınmayan düğümler,  $p$  ile orijinal ağırlıklarının çarpılması sonucunda tekrar ağına yerleştirilmektedir.

Seyreltme tekniđi ESA aısından yalnızca TBK'larda kullanılabilir. Diđer katmanlarda seyreltme tekniđi yerine paket normalizasyon tekniđi kullanılmalıdır. Bu kullanım, modeli daha dzenli ve eđitim esnasında daha stabil hale getirmektedir. Ařađıda verilen Őekil 10'da standart bir sinir ađı ile seyreltme tekniđi uygulanmıř bir sinir ađının temsili gsterilmektedir.



**Őekil 3.10:** a) Standart sinir ađı, b) Seyreltme uygulanmıř sinir ađı


Őekil 3.10'dan hareketle; farklı mimarilerin sonularının ortalamasını almak çođunlukla farklı modellerden gelen grlty ortadan kaldırır bu da performansa yansır. Birok ayrı ađın eđitilmesi hesaplama aısından olduka maliyetlidir. Fakat seyreltme tekniđi sayesinde aynı model iin neredeyse farklı mimariler oluřabilmektedir. Bunun yanı sıra seyreltme tekniđi ile komřu nronlar aynı rntleri ezberleyebilmektedir. Bu durumun ok ileri gitmesi modelin ok kırılğan bir yapıya sahip olmasına sebep olmaktadır. Bu da eđitim verilerinin ok zel olduđu anlamına gelmektedir. Ancak yine de model nronların, her birinin bađımsız bir zellik dedektr niteliđinde olması gerekmektedir. Seyreltme tekniđi, ađın belirli modellere karřı daha az hassas olmasını sađlamaktadır. Bu durumsa daha iyi genelleme yapabilmesine rađmen eđitim verilerinin olması gerekenden daha fazla gecikmesine sebep olabilir.

- **İleriye yayılım modeli:**

Problemlerin ok karmařık olması sebebiyle bu tr problemlerin (ezberleme, karmařık veri setleriyle bařa ıkama gibi.) zmnde tek algılayıcı yetersiz kalmıřtır. Bu yetersizliđin bir sonucu olarak da ařađıda verilen Őekil 3.11'de gsterilmekte olan KP yapısı; bilinen genel adıyla "sinir ađları" ortaya

çıkıştır. Giriş katmanından çıkış katmanına doğru tek yönlü bağlantılar aracılığıyla nöronlar arası iletişimin sağlandığı sinir ağına "İleri Besleme Sinir Ağı" denmektedir. Aynı tabakada yer alan nöronlar birbirlerine bağlı olmamalarına rağmen bir tabakadan diğerine bağlanabilmektedirler. Bu durum, ileri beslemeli sinir ağlarında nöronlar arasında bağlantıların bir döngü oluşturmamasının sebebi olsa da bu ağlar, girilen veriler için oldukça hızlı şekilde çıktı üretme yeteneğine sahiptirler.

İleri beslemeli ağlara örnek olarak ÇKP ve Öğrenmeli Vektör Kuantalama (LVQ) verilebilir. Söz konusu ağlarda, bir katmana ilişkin tüm hücrelerin çıktısı sonraki katmanda yer alan tüm hücreler için girdi olmaktadır. Giriş katmanı, dış ortamdan aldığı bilgilerin tamamını hiçbir bir değişiklik yapmadan gizli katmanda yer alan hücrelere ileten katmandır. BT girdi verisi gizli katmanla çıktı katmanlarda işlenmesiyle ağın çıktısı belirlenmektedir. İleri doğru yayılım yapısı sayesinde ileri beslemeli ağlar doğrusal olmayan statik bir fonksiyon oluşturmaktadır. Gizli katmanlarda yeterli sayıda sinir hücresinin bulunmasıyla ileri beslemeli ağın doğruluk oranında da düzenli bir artış meydana gelmektedir. Aşağıda verilen Şekil 3.11'de gösterildiği gibi, ileri beslemeli tipteki YSA'yı eğitmek için genellikle Yayılım Yoluyla Öğrenme Algoritması kullanılmaktadır.



**Şekil 3.11:** İleri yönde yayılım modeli

Girdi katmanı içerisinde yer alan her bir nöron, girdiye ait olan vektörün değerlerinden birini kendine değer olarak belirlemektedir. RGB formatlı bir görselin piksel değeri, bir sayı ya da siyah-beyaz el yazısı görüntüsü bu değerlerden biri olabilir. Daha sonra, girdi katmanındaki her nöronun kendisinden sonraki gizli katmanda yer alan her bir nöronla olan bağlantısı için belli bir ağırlık değeri atanmaktadır. Ağın doğruluğunu ve performansını

etkilemeleri sebebiyle atanan bu ağırlık değerlerinin daima dikkatli seçilmeleri gerekmektedir. Takip eden adım; ağ içerisinde bulunan her girdinin, ilgili ağırlık değeriyle çarpılması ve elde edilen çarpımın üzerine kutuplama değeri eklenerek aktivasyon fonksiyonundan geçirilmesidir. Tüm nöronlarda aktivasyon fonksiyonu bulunmaktadır. Nörondan elde edilen çıktıları standart hale getirmek söz konusu aktivasyon fonksiyonunun amaçlarından biridir. Aşağıda verilen Denklem 3.3'te yukarıda bahsedilen işlemlerin tamamı gösterilmektedir.

$$v_j = \sum_i w_{ij}x_i + b_j \quad (3.3)$$

$$y_j = \sigma(v_j)$$

Çıktı değerinin hesaplanmasının ardından, bu sonucun atanmış olan kutuplama değeri ve ağırlık değeri açısından doğruluk değeri belirlenmelidir. Bu belirleme için daha önceden etiketlenmiş olan eğitim seti kullanılmaktadır. Süreç, hata sinyalini bulmak suretiyle gerçekleştirilebilir. Hata sinyali, çıkış nöronundan çıkarak ağ boyunca katmandan katmana geriye doğru yayılan sinyaldir. Bu sinyalin hata sinyali adını alma sebebi, ağda yer alan tüm nöronlara bağlı bir hesaplama ve hataya bağımlı bir fonksiyon içermesidir. Maliyet (loss veya cost) fonksiyonunun hata sinyaliyle birlikte hesaplanmasına ilişkin önem ve bu önem neticesinde ortaya çıkan görev, çalışmanın ilerleyen bölümlerinde detaylıca tartışılacaktır. Aşağıda verilen Denklem 3.4'te ileri yönde yayılım formülize edilmektedir.

$$y_j^{(l)}(n) = \sigma[\sum_i w_{ji}^{(l)}(n)Y_i^{(l-1)}(n)] \quad (3.4)$$

Denklem 3.4'te görüldüğü üzere;  $w_{ji}^{(l)}(n)$  l-1'inci katman tarafından beslenen l'inci katmandaki j nöronuna ilişkin sinaptik ağırlık değerini,  $Y_i^{(l-1)}(n)$ , bir önceki katmanın çıktısını,  $Y_i^{(l)}(n)$  ise çıkış katmanındaki nöronun değerini ifade etmektedir. Aşağıda verilen Denklem 6'da ise nöronun j çıktı katmanında yer aldığı ve ağın derinliğini L'nin belirttiği ifade formülize edilmektedir.

$$y_j^{(L)}(n) = o_j(n) \quad (3.5)$$

Denklem 3.5'te  $o_j(n)$  j'inci nörondaki çıktıyı belirtir.

$$e_j(n) = d_j(n) - o_j(n) \quad (3.6)$$

Denklem 3.6'da görüldüğü üzere; j'inci nörondaki çıktıyı  $o_j(n)$  belirtmektedir. Hata sinyalini ifade eden  $d_j(n)$  j'inci nöronun ise beklenen çıktısını belirtmektedir. Aşağıda verilen Denklem 7'de de işlemin hesaplanma şekli gösterilmektedir.

- **Geriye yayılım modeli:**

Geri Beslemeli YSA, dinamik bir yapıya sahip olmayan ileri beslemeli ağların aksine dinamik bir yapıya sahiptir. Geri beslemeli sinir ağlarındaki çıktı diğer katmanlara girdi olarak da kullanılabilir. Böylece bilgi hem ileri hem de ters yönde aktarılmış olmakta; geri beslemeli sinir ağları ise çıkışa gerek önceki girişleri gerekse mevcut girişi tek seferde yansıtabilmektedir. Geri yayılım algoritmasının temel hedefi uygunluk fonksiyonunu en aza indirebilmektir. Uygunluk fonksiyonunun YSA'ya ait ağırlık değerlerine bağlı olması sebebiyle geri yayılım algoritma, YSA'ya ait ağırlıkların uygun şekilde değiştirilmesiyle ilgili işlemlerden meydana gelmektedir. Geri yayılım algoritmasına ilişkin her bir yineleme (iterasyon), ileri yayılım ve geri yayılım şeklinde belirtilen iki aşamadan oluşmaktadır (Chakraborty, A., & Goswami, D. 2017). İleri yayılım aşamasında; YSA'nın o anki durumunda YSA'ya uygulanan giriş sinyallerine göre YSA'nın çıkışlarında meydana gelen değerler bulunmaktadır. Geri yayılım aşamasında ise çıkışlarda meydana gelen hatalardan yola çıkılarak, algoritma bulunan ağırlıkların tekrar düzenlenmesi yapılmaktadır. Olabildiğince karmaşık bir çalışma yapısına sahip olan geri yayılım sinir ağları, dinamik hafızaları sebebiyle sınıflandırma ve tahmin süreçlerinde son derece başarılı sonuçlar ortaya çıkarmaktadırlar. Örneğin algoritmada maliyet fonksiyonunun kullanımıyla çıkış katmanlarının tamamında bulunan nöronların hatalarının hesaplanması mümkün olmaktadır. Aynı ayrı hesaplanan hata değerlerinin toplanmasıyla da toplam hata elde edilmektedir. Geriye doğru yayılım algoritmasının amacı; maliyet fonksiyonu aracılığıyla katmanların tamamında bulunan ağırlık değerlerinin tekrar hesaplanmasıyla hatanın en aza indirgenebilmesidir. Bu amaç doğrultusunda, maliyet fonksiyonundaki azalma göz ardı edilebilir bir seviyeye ulaşıncaya kadar bu süreç devam etmektedir.

Geriye doğru yayılımda ortaya çıkan eğim düşüş fonksiyonu sayesinde maliyet fonksiyonunun hangi yönde değişim göstermesi gerektiği belirlenebilmektedir. Bu belirleme ile ulaşılmak istenen, "global minimum" olarak bilinen en düşük

noktadır. Söz konusu isteğin gerçekleştirilebilmesi için her bir yerel eğim türevinin, eğim düşme algoritması ile küresel minimum noktaya ulaşıncaya kadar hesaplanması gerekmektedir. YSA'nın konveks olmayan bir fonksiyona sahip olması sebebiyle birden çok global minimum noktası bulunmaktadır. Konveks olan bir fonksiyon açısından başlangıç değeriyle global minimum noktasına ulaşmak kolay olmaktadır ancak söz konusu fonksiyon dışbükey olmayan bir fonksiyon ise bu daha zor olmaktadır. Dolayısıyla ağda kullanılacak olan hiperparametrelerin, küresel minimum noktaya ulaşabilmek amacıyla uygun şekilde ayarlanmaları gerekmektedir. Bu MÖ parametreleri; epok, başlangıç ağırlıkları, öğrenme katsayısı ve eğim düşme tipleri olmak üzere çeşitleri bulunmaktadır. Tüm bu bilgilerden hareketle; bir sinir ağı, giriş verilerine ilişkin sinyali karar anına doğru parametreleri vasıtasıyla ileri yönde iletmekte ve sonra parametreleri değiştirebilmesi için hataya ilişkin bilgileri ağ üzerinden ters yönde çoğaltmaktadır. Aşağıda verilen Denklem 3.7'de basit bir sinir ağının kaybı formülize edilmektedir. (Lima et al., 2020).

$$E = (O_{\text{çıkış}(i)} - y_{(i)})^2 \quad (3.7)$$

Denklem 3.7'de görüldüğü üzere;  $O_{\text{çıkış}(i)}$  değeri, bir önceki nöronun değeri ile ağırlık parametresinin çarpımı ve kutuplama değerinin toplamının bir aktivasyon fonksiyonundan geçirilmiş halini ifade etmektedir. Bu örnek için aktivasyon fonksiyonu aşağıda verilen Denklem 3.8'de formülize edildiği gibi sigmoid kullanılmıştır.

$$O_{\text{giriş}(i)} = w^{(L)} h_{\text{çıkış}(i)}^{(L-1)} + b^{(L)} \quad (3.8)$$

$$O_{\text{çıkış}(i)} = \sigma(O_{\text{giriş}(i)})$$

Denklem 3.8'de görüldüğü üzere;  $a^{(L-1)}$  değeri, kendinden önceki nörona bir diğer ifadeyle  $a^{(L-2)}$ 'ye bağlıdır. Ağırlık değerine göre maliyet fonksiyonunun türevi  $(\frac{\partial E}{\partial w^{(L)}})$  şeklinde hesaplanarak, ağırlık değişiminden değer maliyet fonksiyonunun ne kadar etkilendiğini bulmak mümkün olmaktadır. Aşağıda verilen Denklem 3.9'da türev kuralları arasındaki zincir kuralının uygulanması gösterilmektedir (Jain et al., 2020).

$$\frac{\partial E}{\partial w^{(L)}} = \frac{\partial E}{\partial O_{\text{çıkış}(i)}} \frac{\partial O_{\text{çıkış}(i)}}{\partial O_{\text{giriş}(i)}} \frac{\partial O_{\text{giriş}(i)}}{\partial w^{(L)}} \quad (3.9)$$

$$\frac{\partial E}{\partial O_{\text{çıkış}(i)}} = 2(O_{\text{çıkış}(i)} - y_{(i)})$$

$$\frac{\partial O_{\text{çıkış}(i)}}{\partial O_{\text{giriş}(i)}} = \sigma'(O_{\text{giriş}(i)}) \quad (3.10)$$

$$\frac{\partial O_{\text{giriş}(i)}}{\partial w^{(L)}} = h_{\text{çıkış}(i)}^{(L-1)}$$

$$\frac{\partial E}{\partial w^{(L)}} = 2(O_{\text{çıkış}(i)} - y_{(i)})\sigma'(O_{\text{giriş}(i)})h_{\text{çıkış}(i)}^{(L-1)}$$

Öte yandan Denklem 3.9'da ise Denklem 3.10'da gösterilen eşitliklerin ayrı ayrı türevi alınır ve böylece eşitlik elde edilir.

- **Maliyet fonksiyonu:**


MÖ, bir kayıp fonksiyonu ile sınırlandırmayı daha iyi öğrenir, maliyet fonksiyonu hata fonksiyonunun ortalamasıdır. Modeller kayıp fonksiyonu ile öğrenirler. Kayıp fonksiyonu belirli bir algoritmanın verilen verileri ne kadar iyi modellediğini değerlendirmenin bir yöntemidir. Tahminler gerçek sonuçlardan çok fazla saparsa, kayıp fonksiyonunun büyük olması gerektiği anlına gelir. Ayrıca Matematiksel optimizasyon ve karar teorisinde, bir kayıp fonksiyonu veya maliyet fonksiyonu, bir veya daha fazla değişkenin ağırlığını sezgisel olarak temsil eden gerçek bir sayıya eşleyen bir fonksiyondur. Maliyet (kayıp) fonksiyonu öğrenmenin en iyi şekilde gerçekleşmesine yardımcı olur. Öğrenme problemini bir optimizasyon problemine dönüştür, kayıp fonksiyonu tanımlanır ve ardından kayıp fonksiyonunu en aza indirmek için algoritma optimize edilir.

Gerçek çıktı değerleri ile tahmin edilen çıktı değerleri arasındaki farka maliyet fonksiyonu adı verilmektedir. Aşağıda verilen Denklem 3.11'de maliyet fonksiyonu formülize edilmektedir.

$$c(w) = \sum_{k=0}^m y^k - f(x^k))^2 \quad (3.11)$$

Denklem 3.11'de görüldüğü üzere;  $y^k$  veri setindeki k kadar verinin özelliğini,  $f(x^k)$  ise tahmin edilen y değerini ifade etmektedir.

Aşağıda verilen Şekil 3.12'de akciğer BT görüntüsü girdi olarak alınarak, ağırlıkları hesaplanması ve hangi ağırlığın alınacağına aktivasyon fonksiyonu ile belirlenişi gösterilmektedir.



**Şekil 3.12:** Bir ağıın BT görüntüsüne bağlı olarak bir sonuç üretmesi

Veriler ESA modelinde işlenmeden önce temizlenmesi, ön işlem sürecine tabii tutulması doğruluk ve performans açısından önemlidir. Sonrasında Maliyet fonksiyonları, aktivasyon fonksiyonları, eğim iniş fonksiyonlarının düzgün bir şekilde hesaplanması modeldeki başarıyı artıracaktır

Daha az maliyet ve daha yüksek performans ile YSA eğitimini sağlayabilmek için uygun hiper-parametre seçimi oldukça önemlidir. YSA'da kullanılan hiper-parametreler; olmak üzere başlıca 6 grup altında açıklanmaktadır (Cifci & Aslan, 2020).

Verilerden MÖ modelleri tasarlanırken modelde kullanılan teknik veya algoritmalar, tasarımcı tarafından ne olması gerektiği yönünde karar verilmesi gereken bazı parametreleri de beraberinde getirmektedir. K En Yakın Komşu (k-NN) sınıflandırma algoritmasında modeli tasarlayan kişinin k değerinin ne olacağına kendisinin karar vermesi, DVM algoritmasında hangi çekirdek işlevinin kullanılacağına tasarımcı tarafından karar verilmesi ve seyreltme değerinin, katman sayısının ve derin ağ modellerindeki nöron sayılarının da modeli tasarlayan kişi tarafından belirlenmesi bu duruma örnek olarak gösterilebilir. Örneklerden hareketle; genellikle tasarımcı tarafından verilmesi gereken parametreler açısından hangi seçeneğin tercih edilmesinin gerektiği veri seti, problem vb. faktörlere göre değişkenlik göstermesi sebebiyle parametre seçimi, modeli tasarlayan tasarımcıya bırakılmıştır. Dolayısıyla veri seti ve probleme göre değişkenlik göstermesi sebebiyle seçimi modeli tasarlayan tasarımcıya bırakılan parametrelere "hiper-parametreler" adı verilmektedir.




- **Öğrenme katsayısı:**

Öğrenme katsayısı veya öğrenme oranı, öğrenme sürecindeki hız ve işlev açısından oldukça önemlidir. DÖ'de öğrenme gücü ile öğrenme hızı arasında ters orantı bulunmaktadır. Başka bir ifadeyle; daha fazla hız, daha az öğrenme anlamına gelmektedir. Sonuç olarak, "Bir ağ ne kadar eğitilebilir?" sorusuna ilişkin cevabın öğrenme hızına bağlı olduğu ifade edilebilir. Öğrenme hızının belirlenmesinde ağın mimarisi, ağın karmaşıklık düzeyi, ağın boyutu, kullanılan öğrenme kuralı, istenen doğruluk derecesi, istenen çözüm hızı vb. değişkenler önemli bir rol oynamaktadır.

Birçok öğrenme fonksiyonunda öğrenme katsayısına ilişkin olarak belirlenen standartlar bulunmaktadır. Öğrenme katsayısı aralığı genellikle (0,1) gibi bir değer aralığında belirlenmektedir. Bu katsayının kullanılmasıyla ağdaki ağırlıklar artırılmaktadır. Öğrenme katsayısında bulunan küçük değer, öğrenme sürecinin yavaş olduğunu belirtmektedir. Bunun yanı sıra maksimum doğruluğa yakınsama getirebilmek de olasıdır. Öğrenme katsayısının arttırılmasıyla öğrenme hızı da artmaktadır. Ağın mutlak minimum seviyeye ulaşmaması büyük öğrenme katsayılarının kullanıldığına işaret etmektedir. "Salınım" şeklinde ifade edilen bu durumu önleyebilmenin yollarından biri, momentum teriminin kullanılmasıdır.

Öğrenme katsayısı, eğim düşme algoritmalarında kullanılan katsayılardan biridir. Bu katsayının amacı, eğim düşme algoritmalarının yakınsamasını sağlayabilmektedir. Öğrenme katsayısının çok büyük olması halinde hedefe ulaşamaması olasıdır. Böyle bir durumun gerçekleşmesi halinde ise öğrenme katsayısı, global minimum noktasının çevresinde hareket edebilmekte ya da ayrılabilir. Aynı şekilde öğrenme katsayısının çok küçük olması halinde de tüm döngülerde algoritmanın oldukça küçük adımlarla hareket etmesi sebebiyle yakınsama uzun zaman almaktadır.

Öğrenme katsayısı, her bir modelin ağırlık güncellemesinde oluşacak olan tahmini hatanın bir cevabı olarak modelin ne kadar değiştirilmesi gerektiği yönündeki kontrolü sağlayan bir hiper-parametredir. Aşağıda verilen Şekil 3.13'te öğrenme katsayısı gösterilmektedir.



**Şekil 3.13:** Öğrenme katsayısı ile yineleme arasındaki korelasyon

Şekil 3.13'te görüldüğü üzere; öğrenme oranı küçük değerler olarak seçilmemelidir, çünkü bu uzun sürecek eğitim sürecine neden olabilmektedir. Şayet bu seçilen değer çok yüksek olursa bu da hızlı öğrenme ve ezberciliğe neden olmaktadır. Bunun için pek çok deney yapılarak en uygun öğrenme katsayı ve en uygun epok sayısı hesaplanmalıdır. Öğrenme oranı, sinir ağı yapılandırılırken seçilen en önemli hiperparametre olabilir. Bu sebeple model performansı üzerinde öğrenme hızının etkilerinin nasıl araştırılacağını bilmek, model davranışı ve öğrenme hızının dinamiklerine dair bir sezgi oluşturmak oldukça önemlidir.

- **Aktivasyon fonksiyonu:**

DÖ'de, aktivasyon fonksiyonları anahtar bir rol oynar ve başarı oranlarını doğrudan etkiler. Bunun temel nedeni, YSA'larda çıkış katmanlarında başarı değerlerine ulaşmadan önce, aktivasyon fonksiyonu sayesinde belirleyici katsayıların ve ağırlıkların değişmesi ile başarı değerinin değişimine ulaşabilmesidir. Basitçe ifade etmek gerekirse, bir aktivasyon fonksiyonu, ağırlık verilerdeki karmaşık kalıpları öğrenmesine yardımcı olmak için DÖ modeline eklenen bir işlemdir.

Aşağıda verilen Çizelge 3.2'de aktivasyon fonksiyonları gösterilmektedir. Günümüzde en çok kullanılan aktivasyon fonksiyonları ReLU ve softmax olarak karşımıza çıkmaktadır.

**Çizelge 3.3:** Aktivasyon fonksiyonları

İsim	Fonksiyon	Tanımı
Sigmoid (3.12)	$f(x) = x \cdot \sigma(x)$	Sınıflandırma hesaplamaları yapılırken elde edilen değer fonksiyona bağlı olarak 0 ya da 1 yahut -1 ya da 1 arasına sıkışmasını sağlar.
Tanh (3.13)	$f(x) = 2 \sigma(2x) - 1$	Tanh Fonksiyonu: [-1,1] aralığında çıktı üreten doğrusal olmayan bir fonksiyondur.
ReLU (3.14)	$f(x; \beta) = 2x \cdot \sigma(\beta x)$	ReLU fonksiyonu negatif girdiler için 0 değerini alırken, x pozitif girdiler için x değerini almaktadır
Leaky ReLU (3.15)	$f(x) = \begin{cases} ax, & x > 0 \\ x, & x \leq 0 \end{cases}$	Bu 0'a yakın ama 0 olmayan değer sayesinde ReLU'daki kayıp olan gradyanları kazanmak için kullanılır.
ELU (3.16)	$f(x) = \begin{cases} x, & \text{if } x > 0 \\ a(e^x - 1), & \text{if } x \leq 0 \end{cases}$	ELU fonksiyonu, RELU fonksiyonunun sağladığı avantajlara sahiptir. exp () olduğu için yavaştır.
SELU (3.17)	$f(x) = \lambda \begin{cases} ae^x, & \text{if } x > 0 \\ -a, & \text{if } x \leq 0 \end{cases}$	Selu'da eğer çıktı pozitif ise olduğu gibi alınır aksi takdirde çıktı sıfır olur.
Softmax (3.18)	$f(x) = \frac{e^{z_j}}{\sum_k e^{z_k}}$	Çoklu sınıflandırma problemleri için kullanılan bu fonksiyon, verilen her bir girdinin bir sınıfa ait olma olasılığını gösteren [0,1] arası çıktılar üretir.

**Kaynak:** (Lima et al., 2020)

Beynimizdeki nöron temelli bir modelle karşılaştırıldığında, aktivasyon fonksiyonu bir sonraki nörona neyin gönderileceğine karar veren fonksiyondur. DÖ'de bir aktivasyon fonksiyonunun yaptığı tam olarak da budur. Önceki hücreden çıkış sinyalini alır ve bir sonraki hücreye girdi olarak alınabilecek bir biçime dönüştürür.

Zaman zaman aktarım fonksiyonu şeklinde de ifade edilen aktivasyon fonksiyonu, YSA'da sinir düğümlerine ilişkin çıktıyı almak amacıyla kullanılmaktadır. Bu fonksiyon hücredeki net girdi işleminin yanı sıra hücrede bu girdiye cevap olarak üretilen çıktıyı da belirlemektedir. Aktivasyon fonksiyonu genellikle doğrusal olmayan fonksiyon olarak belirlenmektedir. YSA'ya ilişkin bir özellik olan "doğrusal olmama" hali aslında aktivasyon fonksiyonlarının "doğrusal olmayan" özelliğinden kaynaklanmaktadır. Ayrıca aktivasyon fonksiyonu seçiminde, fonksiyon türevine ilişkin hesaplamaların kolay olmasına da mutlaka dikkat edilmesi gerekmektedir.

Softmax yapısı itibariyle sınıflandırma problemlerinde en çok başvurulan yöntemdir. Softmax, sigmoid'in daha genelleştirilmiş bir şeklidir. Daha fazla

çoklu sınıflandırma problemlerinde kullanılsa da Sigmoid'in benzer şekilde 0–1 aralığında değerler üretir, bu nedenle sınıflandırma modellerinde en son katmandır. Çizelge 3.2'de de görüldüğü üzere, aktivasyon fonksiyonları tek tek gösterilmiştir. Bunlardan en önemlisi softmax günümüzde sınıflandırma problemi için en çok tercih edilendir. Çünkü bu tür aktivasyon fonksiyonunun türetilmesi, geri besleme ağlarında da kullanıldığı için hesaplamaların yavaşlamaması adına hesaplaması kolay olan bir fonksiyon seçilmektedir.

### 3.2.4 Eniyileme türleri:

Eniyileme, ağ ve gerçek değer tarafından üretilen çıkış değerleri arasındaki farkı minimize etmek amacıyla kullanılan bir tekniktir. Eğitim düşümü ise sinir ağlarını eniyilemek için kullanılan en popüler algoritmadır. Verilere göre kullanılacak olan üç adet eğitim düşümü bulunmaktadır.

Öğrenme sürecinin sağlıklı bir şekilde sonuçlanabilmesi için DÖ uygulamalarında hata fonksiyonunun mutlak bir minimum değere sahip olması gerekmektedir. Bu sürecin eniyilmesi çeşitli yöntemlerin kullanılmasıyla gerçekleştirilmektedir. Öğrenme katsayısının eniyileme algoritmalarında ayarlanması, modelin eğitimi açısından oldukça önemi bir role sahiptir. Bu eniyileme algoritmaları sayesinde ağırlıklar, aşırı değerde olanlar veya öğrenme sorununa neden olacak ağırlıklar temizlenir. Bunların yanı sıra modeldeki öğrenme katsayısını her algoritma ile tam olarak ayarlamak mümkün değildir.

- **Eğitim inişi türleri (paket eğitim düşümü):**

Tüm veri seti üzerinden hesaplanabilen ve Standart Eğitim Düşümü şeklinde de ifade edilebilen Paket Eğitim Düşümü (PED), eğitim düşümleri arasında en çok faydalanılanıdır. PED veri kümesinin tamamını tek seferde kullandığı için bellek eksikliği sorunları ortaya çıkabilmektedir. PED diğer eğitim düşme tiplerine göre daha kararlı olmasına rağmen hesaplama maliyeti açısından daha yüksektir. Her durumda sinir ağının kayıp fonksiyonu olan belirli bir işlevi en aza indirmek PED amacını oluşturmaktadır.

Tek seferde tüm veri seti eğimler hesaplanırken ele alındığı için PED yöntemi son derece yavaştır. Bunun yanı sıra belleğe sığması mümkün olmayan veri setleri açısından uyarlanması da oldukça zor olmaktadır. Aşağıda verilen

Denklem 3.19 da  $\theta$  parametresine bağılı olarak maliyet fonksiyonuna ait eğimin hesaplanması gösterilmektedir.

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t) \quad (3.19)$$

$\nabla_{\theta} J(\theta)$

Denklem 3.19'da görüldüğü üzere;  $\nabla_{\theta} J(\theta)$  parametrelere bağılı hedef fonksiyon eğimini,  $\eta$  öğrenme katsayısını ve  $\theta \in \mathbb{R}^d$  ise model parametrelerini ifade etmektedir (Bottou, 1991).

- **Olasılıksal eğitim düşümü:**


PED'nin aksine Olasılıksal Eğitim Düşümü (OED) her eğitim örneği  $x(i)$  ve her etiket  $y(i)$  için bir parametre güncellemesi yapmaktadır. Dolayısıyla OED'de her bir tekrarlamaya için veri kümesinin tamamı yerine rastgele birkaç örnek seçilmektedir. OED'yi hesaplamak için kullanılan veri kümesindeki her tekrarlama, "toplu" adında toplam örnek sayısını gösteren bir terim bulunmaktadır. Toplu iş OED eniyilemesinde tüm veri kümesi olarak alınmaktadır. Bunun yanı sıra, minimuma daha az gürültülü ve daha az rastgele bir şekilde ulaşabilmek amacıyla veri kümesinin tamamının kullanılması faydalıdır; fakat veri kümesi büyüdüğünde sorunlar ortaya çıkabilir. Aşağıda verilen Denklem 3.20'de OED'nin matematiksel açıdan ifade edilmiş şekli göstermektedir.

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)}) \quad (3.20)$$

Denklem 3.20'de OED yöntemi eğitim verisinin tamamını değil, yalnızca eğitim örneğini alarak güncelleme yapmakta ve bu durum eğitimi daha verimli kılmaktadır [59].

- **Mini paket eğitim düşümü:**

Mini Paket Eğitim Düşümü, eğitim setinde yer alan her mini paket için bir güncelleme yapan pakettir. PED yöntemine göre ESA modelinde meydana gelen güncelleme daha fazladır. Eğitim açısından asıl önemli olan yerel minimum noktasından uzaklaşıp global minimum noktasına yaklaşmaktır. Şekil 3. 14'te, a) Batch ve b) Mini-batch'ın uygulandığı durumda hata değeri değişimi gösterilmektedir.



**Şekil 3.14:** a) Batch ve b) Mini-batch'ın uygulandığı durumda hata değeri değişimi. Aşağıda verilen Şekil 3.14'te epok sayısı ile kayıp oranları gösterilmiştir. Modellerde epok sayısı arttıkça kayıp değerlerin azaldığı işlenmektedir. Literatür incelendiğinde yapılan çalışmaların bu paket yöntemi ile kayıp değerinin arttığını fakat mini-toplu veri işleme durumunda da zaman kazanıldığı göstermektedir (Cifci & Aslan, 2020).

DÖ uygulamalarında zaman ve bellek açısından, veri kümesinde bulunan verilerin tamamını aynı anda işleyerek öğrenmek maliyeti yüksek bir iştir. Bunun sebebi; öğrenmeye dair her bir tekrarlama, geri yayılım süreci tarafından ağdaki gradyanın geriye dönük olarak hesaplanması ve ağırlık değerlerinin de bu yöntemle güncellenmiş olmasıdır. Veri sayısı ile hesaplama arasında doğru orantı bulunmaktadır. Veri sayısının yükselmesiyle maliyet de artmaktadır. Bu maliyet sorunu çözebilmek için veri seti, küçük gruplara bölünmektedir. Bölünen bu gruplardan seçilen veri kümeleri üzerinde ise öğrenme gerçekleştirilmektedir. Mini paket yönteminin kullanılmasıyla çoklu girdilerin parçalar halinde işlenmesine "mini-batch" denmektedir. Model tasarlanırken bir mini-batch parametresi olarak belirlenen değerler, modelin aynı anda ne kadar veri işleyeceğini belirlemektedir.

**Eğim düşümü eniyileme algoritmaları:** Eğim düşümü eniyileme algoritmaları, eniyileme için en popüler algoritmalarından biridir ve sınır ağlarını optimize etmek için en yaygın kullanılan yöntemdir. Aynı zamanda, en gelişmiş DÖ kütüphanesinden her biri, eğim düşümü eniyileme algoritmalarının inişini optimize etmek için çeşitli algoritmaların uygulamalarını içerir. Bununla birlikte, güçlü ve zayıf yönlerinin pratik açıklamalarını yapmak zor olduğundan, bu algoritmalar genellikle kara kutu olarak bilinir. Aktivasyon fonksiyonları, bir katmandaki nöronların çıktı değerini sonraki katmanlara iletirken kullanılmaktadır. Bu çıktı değerinin diğer

katmanlara aktarılıp aktarılmayacağına karar vermek için bir eşik değeri belirlenmektedir. Çünkü YSA hücreesindeki bilginin değeri artı sonsuz ile eksi sonsuz aralığında olabilir ve nöron gerçek değerlerin sınırlarının farkında olmayabilir. Bu nedenle, eğitim boyunca nöronun aktif olup olmayacağına karar vermek için aktivasyon fonksiyonlarına ihtiyaç vardır. Böylece, bir nöron tarafından üretilen çıktı değerini kontrol edebilecek ve harici bağlantıların nöronu aktif olarak görüp görmeyeceğine karar verebilecek olan aktivasyon fonksiyonudur. Aşağıda verilen Çizelge 3.3'te, Eğitim Düşümü Eniyileme Algoritmalarında kullanılan fonksiyonlar açıklanmaktadır.

**Çizelge 3.4:** Eğitim düşümü algoritmaları

Adaptif Öğrenme Katsayısı	Fonksiyon
OED (3.21)	$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)})$
(3.22)	$v_{t+1} = \gamma v_t + \eta \nabla_{\theta} J(\theta)$
Momentum	$\theta_{t+1} = \theta_t - v_{t+1}$
Nesterov (3.23)	$v_{t+1} = \gamma v_t + \eta \nabla_{\theta} J(\theta - \gamma v_{t-1})$
Hızlandırılmış Eğitim	$\theta_{t+1} = \theta_t - v_t$
RMSprop (3.24)	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_{t+\epsilon}}} g_t$
Adagrad (3.25)	$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii+\epsilon}}} g_{t,i}$
(3.26)	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_{t+\epsilon}}} g_t$
Adadelata	


**Kaynak:** (Hoffer et al., 2017; Luo et al., 2018)

Çizelge 3.3'te formüle edilen eğitim düşümü eniyileme algoritmaları takip eden alt başlıklarda detaylıca incelenmektedir.

- **Momentum:**

OED'nin en küçük değere ulaşabilmesine kolaylık sağlamak amacıyla maliyet fonksiyonunun azaltılması esnasında momentum kullanılmaktadır. Geri yayılım yapılarak hesaplanan maliyet değerleri, maliyet fonksiyonunun kutuplama ve ağırlık değerlerine göre azaltılması esnasındaki her bir t adımı için farklı olmaktadır. Bu, her bir seviye için farklı türev değerlerinin meydana geldiğinin işaretidir. Önceden hesaplanmış olan türev değerlerinin üssel ağırlıklı ortalamaları momentum yönteminin kullanılmasıyla alınmaktadır. Daha sonra bu değerler, kutuplama ve ağırlık değerinin güncellendiği denklem içerisinde bir çarpan olarak kullanılmaktadır. Başlangıç aşamasında belirli bir boyutta bulunan maliyet değeri, eğer OED tek başına uygulanırsa, her bir

adımında hesaplanan farklı türev değerleri açısından en küçük noktaya doğru fazladan salınım yaparak ilerlemektedir. Aşağıda verilen Şekil 3.15'te gösterildiği gibi momentum olmadan OED işlemi yapıldığında düşey yöndeki her adım bir önceki adıma zıt yönde hareket eder ve bu adımlar birbirini dengeler. Eğer düşey yönde hareket gerçekleşirse bu hareketin ortalama değeri sıfıra yakındır.



**Şekil 3.15:** Momentum ile olasılıksal eğim düşümü

**Kaynak:** (Du, 2019)

Momentum algoritması yerel bir minimumda kolayca çıkmaza girebilmektedir. Global minimuma ulaşıldığında artık bunun son adım olduğu düşünülebilir. Böyle bir durumdan kaçınmak amacıyla objektif fonksiyonda 0'dan 1'e kadar bir değere sahip olan bir momentum terimi kullanılmaktadır. Öğrenme oranı, momentum teriminin büyük olması halinde daha düşük verilmelidir. Büyük momentum değerinin bir diğer anlamı, hızlı yakınsama halidir. Ancak hem öğrenme oranı hem de momentumun aynı anda büyük değerlerde tutulmasıyla büyük bir adım sayesinde minimum değer atlanması da mümkün olmaktadır.

Küçük bir momentum değeri, yerel minimumu güvenilir olarak önleyememesinin yanı sıra sistemin eğitimini de yavaşlatabilmektedir. Momentum varyasyonları degrade yön değiştirmeye devam ederse yavaşlamaya yardımcı olmaktadır. Deneme ya da çapraz doğrulama yoluyla doğru bir momentum değeri öğrenilebilmektedir. Aşağıda verilen Denklem 3.27'de, momentum ile eğim düşümü yapılması durumunda gerçekleşen akış formülize edilmektedir.

$$v_{t+1} = \gamma v_t + \eta \nabla_{\theta} J(\theta) \quad (3.27)$$

$$\theta_{t+1} = \theta_t - v_{t+1}$$



Denklem 3.27’de görüldüğü üzere;  $\eta$  öğrenme katsayısını,  $\gamma$  önceki momentum değerinin katsayısını ( $1$ 'den küçük sayı),  $v_t$  ise momentum değerini ifade etmektedir.

- **Nesterov hızlandırılmış eğim:**

Nesterov Hızlandırılmış Eğim (NHE), momentum ifadesine öngörü kazandıran bir yöntemdir. Momentum ifadesi  $\gamma v_t$  ile  $\theta$  parametre değerleri ile güncellenir. Momentum yöntemi, maliyet değerinin en küçük değere ulaşmasını kolaylaştıran yöntemdir. Eğimleri kullandığı esnada ters yönde bir eğimle karşılaşması halinde ilerlemeyi kendi kendine yavaşlatabilecek bir tür akıllı algoritmaya MÖ ihtiyaç duymaktadır. Aşağıda verilen Çizelge 3.4’te NHE algoritması gösterilmektedir.

**Çizelge 3.5:** Nesterov hızlandırılmış eğim algoritması (62)


Eğitim zamanı $T$ , öğrenim katsayısı $\gamma$ , momentum $\mu$ , parametre başlangıcı $x_0$
başla
$y_0 \leftarrow X_0$
yap $t \leftarrow 0$ kadar $T - 1$
$y_{t+1} = x_t - \gamma \nabla f(x_t)$
$x_{t+1} = y_{t+1} + \mu(y_{t+1} - y_t)$
Son

NAG, önceki iki parametre değerinin yumuşatıldığı ve bu yumuşatılmış değerden bir eğim iniş basamağının atıldığı yorumlanabilir. NAG, MÖ topluluğunda genellikle gizemli bir algoritma olarak görülerek; ileri doğru bir degrade değerlendirmesi yapılması ve ardından bir düzeltme oluşturulması şeklinde açıklanmaktadır. Aşağıda verilen Denklem 3.28’de NHE algoritması gösterilmektedir.

$$v_{t+1} = \gamma v_t + \eta \nabla_{\theta} J(\theta - \gamma v_t) \quad (3.28)$$

$$\theta_{t+1} = \theta_t - v_{t+1}$$

Denklem 3.28’de NHE algoritmaları sezgisel açıdan,  $v_t$  güncellemesine göre hedefi optimize etme bakış açısıyla anlaşılabilir. Yukarıda verilen Şekil 3.16’da Momentum ile NHE gösterilmektedir.



**Şekil 3.16:** a) Momentum tabanlı hızlandırılmış eğim, b) Nesterov tabanlı hızlandırılmış eğim karşılaştırılması

**Kaynak:** (Chandra L.2019)

NHE Momentum eniyileme fikri, kayıp fonksiyonunun eğim yerel konumda değil de momentum yönünde biraz ileride ölçmesi anlamına gelir. Şekil 3.16'da NHE güncellemesi en iyi duruma gelebilmesi için momentumu biraz daha yavaşlattığı görülmektedir.

- **Adagrad:**

Uyarlanabilir bir gradyan algoritması olan Adagrad, büyük ölçekli MÖ görevlerinde iyi sonuçlar vermektedir. Eğitimin her bir yinelemesi için MÖ algoritmaları, manuel olarak seçilen ve bir hiper-parametre olan öğrenme oranını ( $\eta$ ) kullanmaktadır. Öğrenme hızı, algoritmanın sapmaları ve ağırlıkları önceki yinelenen gradyanının aksine, otomatik olarak ne kadar değiştireceğinin bir yansımasıdır. Burada asıl hedef, kayıp işlevini kabul edilebilir bir seviyeye indirebilmektir. Adagrad, farklı parametreler açısından bireysel öğrenme hızlarını hesaplamaktadır. Adagrad bu açıdan, OED sağlamlığına dair önemli bir gelişme olarak kabul edilmektedir. Özellikle DSA'da olduğu gibi bir MÖ algoritması açısından en uygun öğrenme oranını bulmak, değişecek binlerce boyut söz konusu olduğunda karmaşık bir sorun olarak ortaya çıkabilir. Öğrenme hızı çok yüksek ayarlanırsa, parametre kabul edilebilir bir kayıp seviyesine ulaşmak için çok fazla hareket eder bu da öğrenme sorunlarına neden olmaktadır. Diğer taraftan, öğrenme oranının çok düşük ayarlanması ise ilerlemenin yavaşlığına sebep olacaktır.

Boyutların hacmi nedeniyle Adagrad, soruna ilişkin her boyutu açısından manuel şekilde farklı öğrenme oranlarının seçilmesinin pratik olmadığı büyük ölçekli problemlerde kullanılmak amacıyla tasarlanmıştır. Eğitim sürecinin ne

çok deęişken ve kesin ne de çok yavaş olduęundan emin olabilmek amacıyla her bir boyut için öğrenme oranı parametresi uyarlanmaktadır. Adagrad algoritmaları bunu yapabilmek için, geçmiş yinelemelerde gözlemlenen verilerin geometrisine ait bilgileri dinamik bir şekilde birleştirmektedir.

Elde edilen bu bilgiler ışığında optimize edilmiş öğrenme ortamı sağlanabilir. Sonuç olarak nadiren görülen özelliklerin göze çarpmasıyla son derece öngörücü özelliklerin tanımlanmasını sağlamaktadır. Aşağıda verilen Denklem 3.29'da parametre güncelleme yöntemi formülize edilmektedir.

$$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} \cdot g_{t,i} \quad (3.29)$$

Denklem 3.29'da görüldüğü üzere; " $G_{t,ii}$  her bir  $i$ ,  $i$  konumundaki köşegen elemanı;  $\theta_i$  parametresine göre,  $t$ . yinelemeye kadar hesaplanmış eğim değerlerinin kareleri toplamıdır.  $G$ , bir köşegen matristir.  $g_{t,i}$ : anında,  $\theta_i$  parametresine göre hesaplanmış, maliyet fonksiyonun eğim değeridir.  $\epsilon$ : Öğrenme katsayısının 0'a bölünmediğinden emin olmak için atanan bir sabit değerdir" (Kurt, F. 2018).

- **Adam:**

Adam, SDG ve RMSprop'un momentum ile birleşimi şeklinde görülebilmektedir. Adam, momentumlu OED gibi degradenin kendisi yerine hareketli degrade kullanarak momentumdan faydalanırken; RMSprop gibi de öğrenme hızını ölçeklemek için kare degradeleri kullanmaktadır. Adam, çalışma şekli açısından uyarlanabilir bir öğrenme oranı yöntemi olarak ifade edilebilir. Bir diğer ifadeyle; farklı parametreler için bireysel öğrenme oranlarını hesapladığı da söylenebilir. Adam adını; sinir ağının her ağırlığının öğrenme hızını uyarlamak için degradenin birinci ve ikinci moment tahminlerini kullanması sebebiyle uyarlanabilir moment tahmininden almıştır. Aşağıda verilen Denklem 3.30'da Adam eniyileme değerinin güncellemesi formülize edilmektedir (Rossetto & Zhou, 2019).

$$E[g^2]_t = yE[g^2]_{t-1} + (1 - y)g_t^2 \quad (3.30)$$

Denklem 3.30'da görüldüğü üzere;  $E[g^2]_t$  geçmiş eğim karesi değerlerinin ortalamasını ve  $g_t^2$  ise  $t$  anında  $\theta$  parametresine göre hesaplanmış maliyet fonksiyonunun eğitim karesini ifade etmektedir. Öğrenme katsayısının,

Adadelta yöntemine ilişkin parametre güncelleme ifadesinde eşitlikten çıkarılması gerekmektedir. Bu durumun gerçekleştirilmesiyle herhangi bir varsayılan öğrenme katsayısının başlangıç esnasında belirlenme zorunluluğu ortadan kalkmaktadır.

Genellikle bazı küçük rastgele veri yığınları üzerinde değerlendirilmesi sebebiyle sinir ağı maliyet fonksiyonu gradyanı, rastgele bir değişken şeklinde düşünülebilmektedir. Gradyanını ilk anı ortalamayı, ikinci anı ise merkezsiz varyansı belirtmektedir. Bu gradyan değerlerin nasıl kullanıldığı bir sonraki adımdır; ilk olarak bu değerlerin nasıl elde edildiğinin anlaşılması gerekmektedir. Mevcut durumdaki var olan parametre ise beklenen değeri belirtmektedir. Parametre özelliklerinin doğru olması eğitim kusursuz olduğu anlamına gelmektedir.


- **RMSprop:**

Gradyan tabanlı bir optimizasyon tekniği olan ve geri yayılım mucidi Geoffrey Hinton önerilmesiyle YSA eğitiminde kullanılan eniyileme türüne RMSprop denir. YSA'da ağırlıklar fonksiyonun içinden geçerken sinir ağırları gibi çok karmaşık fonksiyonların gradyanları yok olmaya meyillidir. Bu durumla başa çıkmak için RMSprop önerilmektedir. RMSprop, gradyanı normalleştirebilmek amacıyla hareketli ortalama kare eğim iniş yöntemi kullanarak ağırlıkların yok olmasını önler. RMSprop, Adagrad algoritmasında meydana gelen öğrenme katsayısının aşırı azaltılmasına ilişkin sorununun bir çözümü olarak geliştirilmiştir. Ayrıca RMSprop, Adagrad'daki geçmiş tüm yamaçların kareleri aracılığıyla sağlanan değerlerin tamamını kullanmak yerine, değer miktarını belirli kare boyutuyla sınırlamaktadır.

Doğruluk ve kayıp oranları: Genellikle bir modelin doğruluğu, modele ait parametrelerin öğrenilerek sabitlenmesinden sonra ve herhangi bir öğrenme gerçekleşmeden önce belirlenmektedir. Test verilerinin modele sunulmasıyla da model eğitilmektedir. Modele ilişkin hata sayısı, hedefler ile karşılaştırıldıktan sonra kaybedilmektedir. Son olarak, kayıp oranına ilişkin yüzde hesaplanmaktadır.

Aşağıda verilen Şekil 3.17'de epok sayısı artıkça doğruluk oranının yükseldiği ve hata oranının düştüğü gözlemlenmektedir. Şekil 3.17'de hem paket boyutu

hem epok sayısına vurgu yapılmaktadır. Paket sayısı mümkün olduğu derecede iyi ayarlanmalıdır. Çok yüksek ya da çok düşük epok sayısı eğitim kaybına neden olabilmektedir. Kayıp oranı, her eğitim seti grubundaki kayıpların ortalamasını ifade etmektedir. Uygulanan derin öğrenme modelinin zamanla değişmesi sebebiyle ilk sefer için bir adımın kaybı çoğunlukla bir önceki kayıptan daha fazladır. Kayıp oranı, eğitim esnasında ortaya çıkarılan modelin her yinelemesinden sonra ne kadar zayıf veya güçlü işlem yapıldığını göstermektedir. Genellikle birkaç yineleme sonrası kayıp oranı düşmektedir.



**Şekil 3.17:** Epok sayısı eğitim hatası ve doğru tahmin grafiği

**Batch (paket):** Batch, bir grup eğitim örneği anlamına gelmektedir. Batch, eğitim iniş algoritmalarında türlü örnekler göre degradelerin toplamını hesaplayarak, bu kümülatif degradenin kullanılmasıyla da parametreleri güncelleyebilmektedir. Tüm eğitim örneklerinin bir güncellemeden önce bütün eğitim setini öğrenmesine Tam Toplu Öğrenme adı verilmektedir. 300.000 görüntünün hepsinin bilgisayar açısından çok maliyetli olan bir belleğe yüklenmesi yerine, küçük parçacıklara ayrılmış olarak yüklenilebilmesi ve böylece tüm veri kümesinin yüklemeye kıyasla çok daha az bellek gerektirmesi bu duruma örnek olarak söylenebilir. DÖ modelinin toplu işlere bölünmeden eğitildiği zaman; DÖ algoritmasının söz konusu bu 300.000 görüntünün tamamına ilişkin için hata değerlerini bellekte saklamasının gerekmesi ve böylece bu durumun hızda büyük çaplı bir düşüşe sebebiyet vermesi de toplu iş kullanımı düşünülmesinin başka bir nedenidir.

- **Düzenleştirme:**

Düzenleştirme, ağırlarındaki gürültüleri öğrenerek daha fazla parametreye sahip olunmasını engelleyen tekniğe verilen addır. Gürültüyle beraber ağırların öğrenilmesi ile ağırların ezberlemesine ilişkin durum ortaya çıkmaktadır.

Dolayısıyla düzenleme tekniđi, ađın ezberlemesini önlemeye yaramaktadır. Ayrıca düzenleme tekniđi ile algoritmanın genelleştirilmesinin sađlandığı da bilinmektedir. Böylece ađın karmaşıklığının artmasıyla katsayıların girdi ile mükemmel uyumuna engel olmaktadır.

Aşağıda verilen Çizelge 3.5'te düzenleme algoritmaları gösterilmektedir. Bunlardan sadece en iyi öznelik üzerine yoğunlaşan L1 ve veya az etkili olanlara penaltı uygulayan L2 algoritması şeklinde açıklanabilir.

**Çizelge 3.6:** Düzenleme algoritmaları

Düzenleme	Fonksiyon	Tanım
L1 Düzenleme (3.31)	$ w[1]  +  w[2]  + \dots +  w[N] $	Sadece en iyi öznelik üzerine yoğunlaşır. Her öznelik sonuca aynı oranda etki edemez.
L2 Düzenleme (3.32)	$w[1]^2 + w[2]^2 + \dots + w[N]^2$	Karmaşıklık penaltı eklenir. Az etkili olan özneliklere penaltı uygular.
Seyreltme (3.33)	$\bar{y}^{(1)} = r^{(1)} * \bar{y}^{(1)}$	Nöron değerini sıfırlar.
Ağırlık sıfırlama (3.34)	$r = a(u) = a((M * W)v)$	Seyreltmeye benzer fakat nöron değil de ağırlıkların bir bölümünü sıfırlar

**Kaynak:** (Yoshida & Miyato, 2017)

Ezberlemeyi önleyebilmek amacıyla veri setinin artırılması bir çözüm olabilir. Fakat bu çözümün yanı sıra Ağırlık Sıfırlama (Dropconnect), L1 ve L2 Düzenlemesi, Seyreltme ve Veri Genişletme yöntemlerini kullanmak da olasıdır. L1 ve L2, en sık kullanılan düzenleme yöntemleridir. L1 düzenleme tekniđinde fonksiyona, düzenleme terimi eklenmektedir ve bu sayede parametrelerin mutlak değerler toplamları azaltılmaktadır. L2 düzenleme tekniđinde ise yine fonksiyona, düzenleme terimi eklenmektedir ancak bu kez amaç parametre karelerinin toplamlarının azaltılmasıdır.

Bazı parametrelerin düzenleme tekniđi vasıtasıyla sıfıra eşitlenmesi sebebiyle parametre vektörünün L1 tekniđi kullanımında seyrek bir hal aldığı görülmektedir. Modelin özgürlüğünü azaltabilmek amacıyla düzenleme, modelin farklı parametrelerine bir penaltı uygulamaktadır.

### 3.3 Evrişimli Sinir Ağları


Son dönemlerde, uygulama ve araştırma alanlarında ESA önemli gelişmeler göstermiştir. Sebebi ise günümüzde ESA'nın üretilen büyük miktarda verilerle çalışabiliyor olmasıdır. Genel bir ifade ile söylenecek olursa; uydulardan üretilen videolar, resimler vb. veriler ile sınıflandırma işlemi, ESA kullanılarak yüksek bir doğruluk oranı ile gerçekleştirilmektedir. ESA yüksek doğruluk oranına sahip görüntü işleme uygulamalarından biridir. ESA'nın başarısı, çevrimiçi servisler ve otonom araç teknolojilerinde görülmektedir; Tesla ve Google gibi büyük firmalar bundan faydalanmaktadır. Performansı yüksek GPU'lar, ESA algoritmalarında yeni nesil yaklaşımlar ve yüksek miktardaki veriler sayesinde hayatımıza dahil olan robotlar ve otonom araç teknolojileri, endüstri devriminde yeni bir sayfa açmaya olanak sağlamıştır. ESA'lar normal sinir ağı modellerine kıyasla çok az ön işleme kullanır. ESA'daki ağ modeli, bitişik düğümler arasındaki ilişkileri oluşturduğu için özelliklerin kendisini öğrenir. Örneğin; elle yazılmış yazıları (28x28 piksel) sınıflandırırken, ÇKP her pikseli ayrı ayrı alır ve boyutu 784 olan bir vektör oluşturur. Ancak, bitişik pikseller arasındaki bilgileri kaçıır. Her pikselin komşu piksellerle uzamsal bir ilişkisi vardır fakat girdi vektörleştirildiğinde bu bilgiler kaybolur. Doğal dil işleme için de aynı şey geçerlidir. Her kelime veya hece önceki veya sonraki kelimesine veya hecesine bağlıdır. Yine de ÇKP'ler bu uzamsal bilgiyi atar ve her bir giriş düğümünü bağımsız olarak işler. Bu durumun üstesinden gelmek için genellikle ön işleme adımı uygulanır.

ESA'da bu uzamsal bilgi, bir evrişim adımı ile dikkate alınır. Filtreler, eğitim sırasında değerlerini otomatik olarak öğrenir ve verilerdeki belirli kalıpları gösterir. ESA'lar genellikle evrişim katmanları, tam bağlı katman (TBK, fully-connected layer) ve havuzlama (ortaklama, pooling) katmanlarından oluşur. Kısacası ESA'lar filtreleri kullanarak belirli kalıpları çıkarır, daha sonra havuz katmanları modelin gereksiz verileri yok saymasına yardımcı olur. Sırasıyla havuzlamayı uygulayarak, sadece belirli kalıpları bırakır. Son bir adım olarak, elde edilen veriler vektörleştirilir ve son aşamada ÇKP kullanılır. ESA'da ham veriler tensor olarak temsil edilir. Tensor konsepti daha yüksek mertebeden matrisler olarak genelleştirilebilir. Örneğin; bir vektör bir sıra 1 tensorüdür, gri ölçekli görüntü bir sıra 2 tensorüdür ve üç kanalı (R, G ve B) olan bir görüntü

sıra 3 tensorüdür. Girdi, ara gösterimler ve parametrelerin tümü ESA modelinde tensörler olarak temsil edilir.

### 3.3.1 ESA Mimarisi

Bir ESA modeli, iki bileşenden meydana gelmektedir. Bunlar özellik çıkarma bölümü ve sınıflandırma bölümü olarak sıralanabilir. Evrişim ile havuzlama katmanları özellik çıkarımını gerçekleştirir. Örneğin, bir BT görüntüsü verildiğinde, evrişim katmanı bu görüntüdeki özellikleri inceler ve özellik çıkarımına yardımcı olur. Daha sonra TBK bu özelliklerin üzerinde bir sınıflandırıcı olarak hareket eder ve bizi istenilen çıktıya ulaştırır. Evrişim katmanları, bir ESA modelinin ana güç merkezidir. Yalnızca bir görüntü ve bir etiketten anlamlı özelliklerin otomatik olarak algılanması basit olarak algılanmamalıdır. Evrişim katmanları, bu tür karmaşık özellikleri birbirinin üzerine inşa ederek öğrenmektedir. İlk katmanlar kenarları algılar, sonraki katmanlar onları şekilleri algılamak için birleştirir, sonraki katmanlar bu bilgiyi birleştirerek istenilen çıktıya ulaşır. Şekil 3.18’de ESA, 4 evrişimli katman, 3 maksimum havuz katman ile iki TBK ve bir softmax çıktı katmanına sahiptir.



Şekil 3.18: Evrişimli sinir ağı mimarisi grafiği

ESA mimarileri, araştırmacıların çalışmalarına destek olmaktadır. Bu bölümde ESA Mimarisine ait 3 ana katmanın incelenmesi planlanmıştır. Şekil 3.18’de örnek ESA yapısı görülmektedir.

Ek olarak bir BT taramasındaki görsel içeriği tanımak amacıyla kullanılan katmana Evrişim katmanı adı verilmektedir. Şekil 3.18’de görüldüğü üzere ilk katmana BT görüntüsü verildiğinde çıktı olarak bir aktivasyon haritası




döndürülmektedir. Evrişim katmanında yer alan filtreler öğrenme performansını maksimize edebilmek için BT görüntüsündeki özellikleri ekstrakt etmektedir. Uygulanan her filtre doğru tahmine yardımcı olabilmekte amacıyla farklı özellikler sergilemektedir. Evrişim katmanından sonra parametre sayısını indirgeyebilmek için ortaklama katmanı uygulanmaktadır. Bu uygulama, mimariyi geliştiren uzmanlara göre, farklı senaryolarla devam ederek, bazen modele birkaç tane erişim ve ortaklama eklenebilir. Modele ortaklama katmanının ardından düzleştirme katmanı eklenmektedir. Düzleştirme, tüm özellik haritası matrisini tek bir sütuna çevirmektedir. Daha sonra modele dense katmanı eklenmektedir. ESA'daki ilk parametre, gizli katmanda bulunan düğüm sayısı, ikinci parametre ise aktivasyondur. Aktivasyon fonksiyonu olarak ReLU kullanılmaktadır. Ezberlemeye sebep olan düğümleri etkisizleştirmek amacıyla seyretme yöntemi uygulanmaktadır. Bundan sonraki katman ise TKB'dir. TBK, ESA'daki çıkış katmanına bağlıdır. Bu katmandan, girdi katmanından gelen veriyi sınıflara ayırmak için yararlanılmaktadır. En son katman ise gerçek değerler ile tahmin edilen değerlerin karşılaştırıldığı çıktı katmanıdır. Aktivasyon fonksiyonu hatalı tahminleri belirleyerek, yeni ağırlıklar ile eşik değerlerinin güncellenmesi için elde edilen sonuçlar geri gönderilmektedir. ESA'da model derlenirken; optimizasyon, kayıp ve metrikler olmak üzere üç ayrı fonksiyondan yararlanılmaktadır. Optimizasyon fonksiyonları olarak Adam, NAG, Adagrad ve RMSprop'dan; metrikler olarak sınıflandırma başarısı, logaritmik kayıp, hata matrisi, AUC, ortalama mutlak ata ile ortalama kare hatası; kayıp fonksiyonları olaraksa SGD, Hinge loss, Cross entropy loss, Binary cross entropy ve Sparse categorical cross entropy gibi fonksiyonlar denenmiştir.

### **3.3.2 Evrişim Katmanı**

Bir evrişim katmanında birincil işlev, giriş verilerinden özellikler elde edilmesidir. Konvolüsyon işlemi, iki fonksiyonun matematiksel bir işlemi olarak tanımlanabilir. ESA konseptinde evrişim işlemi, filtre olarak da adlandırılan bir çekirdek işlevini her bir ögenin öge bazında çarpımını gerçekleştirerek ana veriler üzerinde kaydırır. Kayma işlemindeki her pencere için, öge-bazlı çarpma işleminin toplamı o pencere bazında sonuç verir. Pencereyi tüm görüntü boyunca kaydırarak, özellik haritası adı verilen

evrişim işleminin çıktısı üretilir. Evrişim katmanı, ESA'nın anahtar bileşenidir ve en az bir katmandan oluşur. Amacı, girdi olarak alınan görüntülerde bir dizi özelliğin varlığını tespit etmektir. Bu, evrişim filtreleme ile yapılır, görüntü üzerindeki özelliği temsil eden bir pencereyi "sürüklemek" ve özellik ile taranan görüntünün her bir bölümü arasındaki evrişim ürününü hesaplamaktır. Evrişimsel katman böylece girdi olarak birkaç görüntü alır ve her filtre ile her birinin evrişimini hesaplar. Filtreler, görsellerde bulmak istediğimiz özelliklere tam olarak karşılık gelir. Şekil 3.19'da evrişim uygulaması gösterilmektedir.



**Şekil 3.19:** Evrişim uygulaması

Şekil 3.19'da birinci blok, bir özellik çıkarıcı olarak işlev gördüğü için bu tür bir sinir ağının özgünlüğünü oluşturur. Bunu yapmak için evrişim filtreleme işlemleri uygular. İlk katman, görüntüyü birkaç evrişim çekirdeği ile filtreler ve daha sonra normalleştirilen veya yeniden boyutlandırılan "özellik haritalarını" döndürür. İkinci blok ise bir ESA özelliği değildir. Aslında sınıflandırma için kullanılan tüm sinir ağlarının sonundadır. Giriş vektör değerleri, çıkışa yeni bir vektör döndürmek için dönüştürülür. Bu son vektör, sınıflar kadar çok eleman içerir. Dolayısıyla her eleman 0 ile 1 arasındadır ve hepsinin toplamı 1 değerindedir. Bu olasılıklar, bir lojistik fonksiyon (ikili sınıflandırma) veya bir softmax fonksiyonu kullanan bu bloğun son katmanı tarafından hesaplanır. Şekil 3.20'de evrişimli sinir ağında girdi ve çekirdek temsili gösterim yapılmaktadır.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

 $\times$ 

1	0	1
0	1	0
1	0	1

 $=$ 

4	3	4
2	4	3
2	3	4

**Şekil 3.20:** Evrişimli sinir ağında girdi ve çekirdek temsili gösterim

Şekil 3.20’de ise 5x5 büyüklüğünde bir matris, 3x3 büyüklüğünde bir çekirdek ile kıvrılmıştır. Sol üst köşeden başlayarak, çekirdek tüm görüntüyü kaydırır ve son resimdeki kıvrımlı özellik haritasını gösterir. Çekirdek ve giriş görüntüsü arasında bir korelasyon olduğunda ortaya çıkan özellik haritasının bu alanlarda daha yüksek değerlere sahip olduğu görülebilir. Herhangi bir benzerlik olmadığında, sonuçlanan özellik haritasının bu bölgelerdeki değerleri daha düşüktür. Bu nedenle çekirdeklere "özellik dedektörleri" de denir. Evrişim katmanında orijinal veriler üzerinde birçok çekirdek kullanılır. Bu çekirdeklerin her biri, giriş verilerinin farklı desenlerini ve özelliklerini öğrenir. Örneğin; kenarları, eğrileri, gürültüleri ve pürüzsüz alanları tespit etmeyi öğrenebilirler.

ESA'larda evrişim işlemi göz önüne alındığında, üzerinde düşünülmesi gereken 3 farklı tasarım sorunu göze çarpar: Bunlar çekirdek boyutu, çekirdek sayısı ve kaydırma adımı (stride) olarak ifade edilebilir. Bu hiper parametreler, çıktı verilerinin şekli ve bellek kullanımı üzerinde etkilidir. Çekirdek boyutu, evrişim tabakasının çıkışındaki her bir nöronun alıcı alanını belirler. Çekirdeğin değerleri, modelin ağırlıklarını temsil eder. Örneğin; çekirdek 3x3 boyutuna sahipse, çıktısının da giriş katmanında 9 farklı düğümle bağlantısı vardır. Genel olarak çekirdek boyutu, giriş veri boyutuyla aynıdır. Girişin sahip olduğu görüntü 1 kanallı gri tonlamalı bir görüntü ise çekirdek de 1 kanala sahiptir. Girişin sahip olduğu görüntü 3 kanallı bir RGB görüntüsü ise bu kez de çekirdek 3 boyutlu bir yapıda seçilir. Eğer çekirdek boyutu fazla küçük olursa yeterli özellikleri ayıklaması mümkün olmaz. Küçük çekirdekler büyük ve karmaşık desenleri algılayamazlar. Fakat küçük çekirdek boyutlarına sahip kıvrımlar art arda uygulanırlarsa, özellikleri ayıklamaları mümkün hale

gelebilir. Öte yandan çekirdek boyutunun büyük olması, hesaplama karmaşıklığının artmasına sebep olur. ESA eğitiminde genellikle 3x3 veya 5x5 gibi küçük çekirdek boyutları kullanılır. Ancak son yayınlarda, ağdaki boyutun azaltılması için bazı durumlarda 1x1 filtrelerin yararlı olabileceği belirtilmektedir. Çekirdek sayısı, odaklanacak farklı özelliklerin sayısını belirlediğinden çok önemli bir tasarım parametresidir. Çekirdek sayısı azsa, ağ verilerdeki bazı desenleri kaçırabilir.

Bunun yanı sıra, çekirdek sayısı yinelenen filtrelere neden olacak kadar büyük olmamalıdır. Örneğin; çekirdek boyutu 3x3 ise 64 çekirdeğin kullanılması yinelenen filtreler oluşturur. Çünkü 3x3 boyutun 64 nitelikli farklı filtre oluşturması mümkün değildir. Yinelenen filtrelere ek olarak; her bir kıvrık görüntü bilgisayarın belleğinde yer kapladığı için çok fazla filtre, bellek sorunları doğuracaktır. Her çekirdek giriş görüntüsünün üzerine kaydırıldığında, bir özellik haritası oluşur. Bu çıktı görüntüleri, tüm çekirdekler çıktılarını ürettikten sonra birleştirilir. Giriş görüntüsü 2 boyutlu ise, çıktıları 3 boyutlu tensor olacaktır.

Giriş görüntüsü 3 boyutlu hacimsel veri ise çıktıları 4 boyutlu tensor olacaktır. Bu ekstra boyut, birçok filtre kullanımından dolayı ortaya çıkar. Tensörün derinliği ve çekirdeğin derinliği aynı olmalıdır. Örneğin; 30x30 boyutunda bir giriş tensorü ve 3x3 boyutunda bir çekirdekten yola çıkılırsa, ortaya çıkan kıvrım boyutu 28x28'dir. Çizelge 3. 1'da evrişim katmanı parametreleri ve fonksiyonları gösterilmektedir.


**Çizelge 3.7:** Evrişim katmanı parametreleri ve fonksiyonları

<b>Parametre</b>	<b>Fonksiyonu</b>	<b>Veri türü</b>
Filtre	Evrişim işleminde kullanılan çıktı filtrelerinin sayısını ayarlar.	tamsayı
Kernel boyutu	Evrişimli pencerenin boyutunu belirtir.	tamsayı
Adım kaydırma	Adım kaydırma parametresi, evrişim penceresinin kaydırma boyutunu belirtir.	tamsayı
Dolgu	Dolgu parametresinin üç değeri vardır: Geçerli, nedensel ve benzer. Geçerli, girdinin sıfır dolgusu yoktur ve çıktısı, orijinal görüntünün boyutlarından daha küçüktür.	dizi
Aktivasyon	Aktivasyon parametresi, evrişimi gerçekleştirdikten sonra uygulamak istediğiniz aktivasyon fonksiyonunun adını belirtir.	aktivasyon fonksiyonu
Kutuplama	Kutuplama parametresi, evrişimli katmana bir önyargı vektörünün eklenip eklenmeyeceğini kontrol eder.	boole
Kernel başlatıcı	Çekirdek ağırlıkları matrisine uygulanan bir işlev. Eğitimden önce tüm değerleri başlatmak için kullanılır	anahtar argümanı
Kutuplama başlatıcı	Eğitim başlamadan önce sapma vektörünün nasıl başlatıldığını kontrol eder.	anahtar argümanı
Kernel düzenleyici	Bu parametreler, düzenleştirmenin türünü ve miktarını kontrol eder. Düzenli hale getirme, aşırı uydurmayı önlemeye yardımcı olan ve modelinizin eğitim örneklerinden gerçek bir popülasyona genelleme yeteneğini geliştiren bir yöntemdir.	düzenleyici fonksiyon

**Kaynak:** (C. Li et al., 2019)

Çizelge 3.6'da gösterildiği gibi çıkış tensorünün boyutu  $K \times 28 \times 28$  olur. Bir sonraki evrişim işleminde ise çekirdek boyutu  $K \times N \times M$  olarak hesaplanır. ESA modeli gösterimlerinde bu boyut genellikle  $K @ N \times M$  olarak temsil edilir. Dolgu (padding) ise burada çok önemli bir rol oynar. Genel olarak çekirdeğin giriş görüntüsü bir kerede 1 düğüm adımı boyutunda kayar. Yine de çıkış tensorü boyutunu kontrol etmek için kaydırma adım sayısını değiştirilebilir. Adım sayısı "2" olarak değiştirilirse, çekirdek 2 düğümü kaydırarak bir sonraki kısma geçer.

Örneğin;  $64 \times 64$  boyutunda bir görüntü ve  $3 \times 3$  boyutunda bir çekirdeği ele alırsak, adım 1 ise çıktı görüntüsü  $62 \times 62$  olacaktır. Adım 2 ise çıktı görüntüsü  $31 \times 31$  olacaktır. Evrişim işleminde, çıkış tensorünün boyutunu giriş hacmiyle aynı tutmak için giriş tensorüne dolgu eklenebilir. Dolgu boyutu genellikle çekirdeğin boyutuna göre belirlenir. Örneğin, çekirdek boyutu  $3 \times 3$  ise görüntünün çevresinde 1 piksel olması yeterlidir. Çekirdek boyutu  $5 \times 5$  ise görüntünün etrafında 2 piksel kullanılabilir (Bkz. Şekil 3.21). Dolgu değerleri genellikle sıfır veya kenar piksellerle aynı değer olarak seçilir.



**Şekil 3.21:** Dolgu değerleri ve sıfır ile doldurulmuş filtre.


$5 \times 5$  çekirdeğin boyutu için, görüntü boyutunu aynı tutmak amacıyla iki piksel sıfır dolgusu kullanılabilir. Herhangi bir evrişimsel katmanın çıktı büyüklüğünü hesaplamak için denklem şöyledir.

$$O = \frac{(w-K+2P)}{s} + 1 \quad (3.35)$$

Denklem 3.35'te "O" çıkış yüksekliği / uzunluğu, "W" giriş yüksekliği / uzunluğu, "K" filtre boyutu, "P" dolgu ve "S" ise adımdır.

### 3.3.3 Havuzlama Katmanı

Çıktının boyutunu düşürmek amacıyla havuzlama işlemlerinde bazı yöntemler uygulanır. Mesela alt bölgelerin özetlenmesi için maksimum ya da ortalama değer alma gibi bazı fonksiyonların kullanılması buna örnektir. Havuzlama işleminde, belirlenen alan içerisindeki değerlerin ortalaması alınır yahut maksimumu hesaplanır ve buna göre bir değer çıkarılır. Havuzlama işlemi girdide kayan pencere yöntemi kullanılarak uygulanmaktadır. Kayan pencere her defasında havuzlama yöntemine göre denk gelen girdi alanının içerisinde bir değer ortaya çıkarır bu değeri çıktı katmanına ilave eder. Bahsi geçen girdinin küçük parçaları, ESA'daki havuzlama katmanları sayesinde, tercih edilmiş olan yöntem uygun olarak sabit bir değere indirgenir. Buradan yola çıkılarak havuzlama katmanı hesaplamalarının evrişim katmanı hesaplamalarına göre daha az maliyetli olduğu söylenebilir. Havuzlama türlerinin en yaygın kullanılanı, girdinin parçalara ayrıldığı ve her bir parçadaki en yüksek değer alındığı maksimum havuzlama tekniğinden yararlanılmıştır. Şekil 3.22'de, 3x3'lük maksimum havuzlama işleminin üzerinde 1x1'lik adım sayısı ile hesaplanması gösterilmiştir.



Şekil 3.22: Maksimum ve ortalama havuzlama katmanı

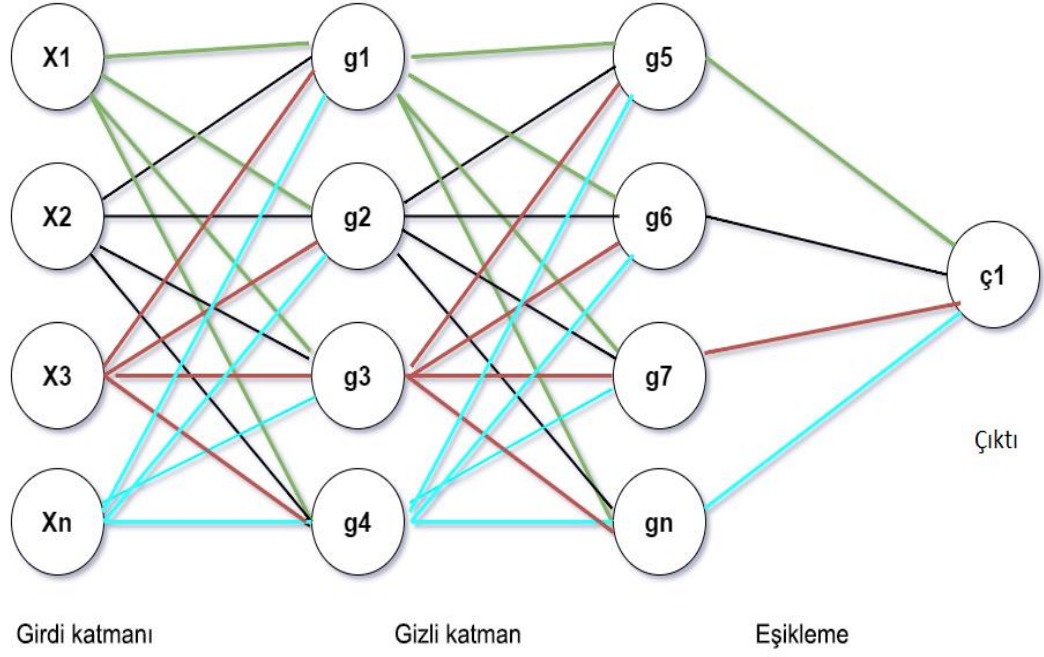
Aşağı örnekleme katmanı olarak da adlandırılan havuzlama katmanı, ağıdaki parametre sayısını ve hesaplamayı azaltmak amacıyla, evrişim katmanı çıktısının uzamsal boyutunu azaltır. Havuzlama katmanı ayrıca aşırı gecikmeyi kontrol etmek için de kullanılmaktadır. Havuzlama katmanı genellikle iki kıvrım katmanı veya kıvrım ile TBK'ler arasına yerleştirilir. Maksimum havuzlama ve ortalama havuzlama, en çok kullanılan havuzlama yöntemlerindedir. Belirli bir pencere bazında düşünüldüğünde ortalama

havuzlamanın o penceredeki deęerlerin ortalama deęerini aldıęı, maksimum havuzlamanın ise o penceredeki maksimum deęeri aldıęı grlr. Havuzlama iřlemi iin pencere boyutu ve adım deęeri olan iki nemli hiper parametre vardır. Pencere boyutu, odaklanacak alanın geniřlięini ve te yandan adım srgl pencerenin adım boyutunu belirler. Havuzlama katmanı, grnt matrisini st ste gelmeyen ve 4 dikdrtgen kısımdan oluřan gruplara ayırır. 2 havuzlama sınıfı, maksimum ve ortalama maksimum deęerdeki greli matris blgesinde, maksimum havuzlama ile retilir. Ortalama havuzlama, greli matris blgesindeki ortalama deęeri saęlar. Havuz katmanı bilgisayarın performansını arttırır ve fazla gecikme olasılıęını azaltır.

### **3.3.4 Tam Baęlı Katman**

Bir sinir aęında, bir katmandaki btn girdilerin kendinden sonra gelen katmandaki her bir etkinleřtirme birimine baęlandıęı katmanlara TBK denir. TBK'ler, popler MO modellerinde, son ıktıyı meydana getirmek iin nceki katmanlar tarafından ıkarılan verileri derleyen son birkaç katman olarak tanımlanabilir. Konvolsyon katmanının ardından en ok zaman aldıęı bilinen ikinci katmandır. Bařka bir deyiřle, evriřim ve havuzlama tabakası dikdrtgen Őekilli ıktılar retilir. Bu ıktılar vektr matrisine dnřtrlerek aęırlık matrisi ile arpılabilir. rneęin; her biri  $5 \times 5 \times 3$  voksel ieren 64 zellik eřleme katmanı varsa, TKD'de bu hacimler  $4800 \times 1$  vektrne ( $5 \times 5 \times 3 \times 64 = 4800$ ) dnřtrlr. Őekil 3. 23'te Tam baęlı katman gsterilmektedir.





**Şekil 3.23:** Tam Bağlı Katman

Tamamen bağlanmış katmandan önceki katman, üst düzey özellikleri temsil eder (Bkz. Şekil 3.23). Tamamen bağlı bir katmanın yardımıyla, bu üst düzey özellikler gizli katmanların ağırlıkları ile çarpılabilir. Sistemin geri kalanı ÇKP gibi çalışır. Bu katman YSA gibi çalışmaktadır. Havuzlama ve evrişim işlemlerinden sonra ortaya çıkan değerler bu katman tarafından girdi olarak alınır, işleme sokulur ve çıkış katmanında sınıf sayısı kadar sonuç üretilir.

### 3.3.5 Hiper Parametreler

Hiperparametreler, MÖ modeller yapısını belirleyen değişkenlerdir (Örn: gizli katman sayısı) ve modelin nasıl eğitildiğini belirleyen değişkenlerdir (Örn: öğrenme hızı). Hiperparametreler eğitimden önce yani ağırlıkları ve sapmayı optimize etmeden önce ayarlanır. Kısacası bir MÖ modeli oluştururken, modelin mimarisini nasıl tanımlanacağına dair tasarım seçenekleri sunulur. Çoğu zaman, belirli bir model için en uygun model mimarisinin ne olması gerektiğine hemen karar verilemez zira bir dizi olasılığın hesaplanması gerekmektedir. Model mimarisini tanımlayan parametrelere hiperparametreler denir ve bu nedenle ideal model mimarisini arama sürecine hiperparametre ayarı adı verilir.

Havuzlama katmanı, ESA'ya ait evrişim katmanı ve tam bağımlı katman özellikleri hakkında bir önceki bölümde bilgiler verilmiştir. Evrişimli ağlarının

en iyi sonucu vermesi için, temel sinir ağlarında olduğu gibi, hiper parametrelerin ideal bir şekilde ayarlanması gerekmektedir. Hiper parametrelere ait her bir detay, sonraki bölümde tartışılacaktır.

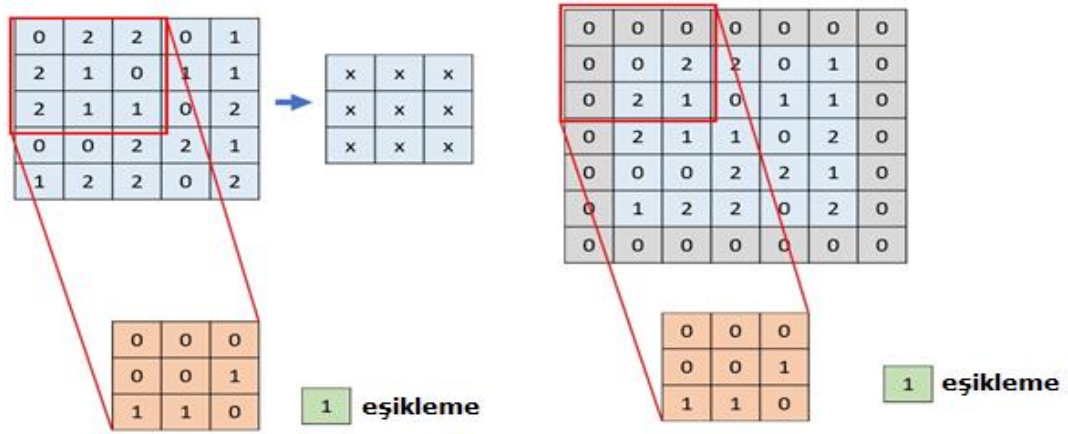
Kullanılacak olan filtre sayısına "derinlik" denir. Her bir filtre, girdiye ait farklı özellikleri arar. Mesela evrişim katmanına bir resim girdi olarak alındığında, bu girdideki köşeler ve farklı renkler sebebiyle her filtredeki farklı nöronlar aktif hale gelecektir. Farklı özellikleri arayan ancak girdinin belli bir yerine bakmakta olan nöronların tümüne "derinlik kolonu" ismi verilmektedir. Girdi üzerinde filtrenin kaç piksel kaydırılması gerektiğini belirleyen hiper parametreye "kaydırma adımı" denir. Örneğin filtrenin evrişim işleminin ardından 1 piksel kayması isteniyorsa adım sayısı 1 olarak seçilmelidir. Adım sayısının 2 olması durumunda filtre 2 piksel kayar. Eğer adım sayısı 2 ya da 2'den büyük bir değere sahip olursa çıktı boyutu girdi boyutundan daha düşük olur (Bkz. Şekil 3.24). Filtre, girdide en soldan başlayarak en sağa varana dek birer adım ilerlediği zaman çıktı genişliğinin "ilerleme sayısı + 1" olması gerekmektedir. Yükseklik için de bu yöntemin uygulanması mümkündür. Matematiksel bazda açıklamak gerekirse, herhangi bir filtre boyutu ( $k$ ) ve girdi boyutu ( $i$ ) için dolgu değeri "0" ve adım sayısı da "1" olacak şekilde sonuç ( $o$ ) olacaktır. Denklemi (3.36) şu şekildedir:

$$o = (i - k) + 1 \quad (3.36)$$

Ayrıca Denklem 3.36'da görüldüğü gibi girdinin çevresinin sıfırlar vasıtasıyla doldurulması işlemine "dolgu" denir. Dolgunun kullanılma nedeni, evrişim işleminin ardından çıktı boyutunun kontrol edilmesi isteğidir.

$$o = (i - k) + 2p + 1 \quad (3.37)$$

Denklemi 3.37'de dolgunun çıktının boyutuna olan etkisinin hesaplanması gerekirse; filtre boyutu ( $k$ ), girdi boyutu ( $i$ ), adım sayısı 1 ve herhangi bir dolgu ( $p$ ) değeri için sonuç olarak hesaplanmaktadır. Şekil 3. 24'te Dolgusu olan ve olmayan ESA katmanları gösterilmektedir.



Şekil 3.24: Dolgusu olan ve olmayan ESA


**Kaynak:** (Klang, 2018)

Şekil 3. 24'te olduğu gibi eğer evrişimin sonucunda girdi ve çıktı boyutlarının aynı değerde olması isteniyorsa dolgu değerinin 1 olması gerekmektedir. Buna yarım dolgu (Half-Padding) denmektedir

### 3.3.6 Paket Normalizasyonu

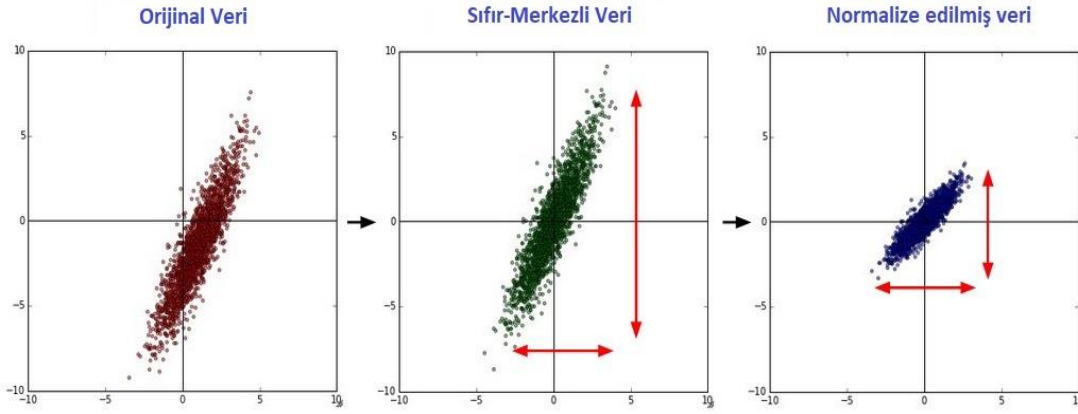
Düzenleştirme bölümü içerisinde bahsedilmiş olan düzenleştirme yöntemlerinin her biri varsayım olarak eğitim veri setine ait bütün örneklerin aynı dağılımdan üretildiği üzerinde durmaktadır. Bu tarz bir varsayım ile veri setini eğitmek ve değişken hiper parametreler doğrultusunda yorumda bulunmak, net sonuçlara ulaşma olanağı sağlamaz. Eğitim evresi esnasında, DSA'ya ait girdilerin temizlemesi halinde daha hızlı birleşme sağlandığı bilinmektedir. Şekil 3.25'te görüldüğü üzere; sol tarafta 2 boyutlu orijinal giriş verilerinin, orta kısımda her bir boyutta bulunan ortalamadan çıkarılması ile sıfır merkezli duruma getirilmekte ve sağ tarafta her boyut standart sapmasıyla ek olarak ölçeklendirilmektedir. Sağ tarafta eşit uzunlukta bulunan ve verilerin kapsamını gösteren çizgiler, ortada eşit uzunlukta değildirler.

Normalleştirme, veri boyutlarının yaklaşık olarak aynı ölçekte olacak şekilde normalleştirilmesini ifade eder. Bu normalleşmeyi sağlamanın iki yaygın yolu vardır. Birincisi, her boyutu sıfır merkezli olduktan sonra standart sapmasına bölmektir. Şekil 3.25'te gösterildiği gibi öncelikle kutuplama değeri ve gürültü seviyesi belirlenir daha sonra bu iki değer birleştirilerek paket normalizasyonu yapılır.



**Şekil 3.25:** Paket normalizasyonu gösterimi

Bu ön işlemin başka bir biçimi, her boyutu normalleştirir. Böylece boyut boyunca minimum ve maksimum sırasıyla -1 ve 1'dir. Bu ön işlemi uygulamak, yalnızca farklı girdi özelliklerine sahip olduğunda mümkündür. Şekil 3. 2'da Normalize edilmiş veri gösterilmektedir.




**Şekil 3.26:** Normalize edilmiş veri

**Kaynak:** (F. Li et al., 2019)

Ön işlemin değişik bir biçimi de verilerin beyazlaşmasıdır. Bu işlem esnasında, Şekil 3.26'da gösterildiği gibi, veriler ilk önce ortalanırlar. Sonrasında, kovaryans matrisi hesaplanır. Bu matris, verilerdeki korelasyon yapısı ile ilgili bilgi vermektedir. Veriler arasındaki temel korelasyon, bu ön işleme vasıtasıyla ortadan kaldırılır. Bu durumda temizlenmiş veriyle önceki veri arasındaki fark, temizlenmiş verinin özdeş kovaryans matrisine ve sıfır ortalamaya sahip olmasıdır.

Sinir ağının gizli katmanları, bu katmanların dağılımının farklılığına bağlı olarak yeni dağılımın uyarlanması için sürekli çaba göstermek zorundadır. Gizli katman girdileri daha istikrarlı olursa eniyileycinin uygun rejimde sıkışması, yani optimize edilmesi ve ulaşılacak maksimum seviyeye ulaşılması,

daha kolay olur. İç katman girişlerinin dağılımlarını düzenlemek için normalleştirme uygulanır. Her bir aktivasyon bağımsız şekilde paket normalizasyonu kullanır ve böylece normalleştirme işlemi gerçekleştirir. Paket normalizasyonunda girdi olarak kabul edilen parametrelerin eğitilebilir ya da eğitilemez konumda olması, paket normalizasyon işlemi esnasında kullanılmış olan ortalama ve varyans vektörüne bağlıdır. Şekil 3.27’de, bir ESA’ daki paket normalizasyonu işlemi gösterilmektedir.



**Şekil 3.27:** ESA mimarisinde detaylı paket normalizasyon işlemi

İç katmanlarda bulunan girdilerin dağılımları normalizasyon uygulanarak düzeltilebilir. Paket halindeki verilerin olduğundan daha küçük paketlere ayrılması yöntemiyle, normalizasyon işleminde ağ modellerine eğitim uygulanır.

Bunun haricinde, normalize edilmiş olan değerlerin değiştirilmesi ve ölçeklendirilmesine ihtiyaç vardır. Aksi takdirde normalleştirilen katman, temsil edebileceği parametreler bakımından sınırlanacaktır. Mesela girişlerin bir sigmoid fonksiyonuna normalleştirilmesi durumunda, çıkış yalnızca doğrusal bölgeye bağlanabilir. Bu demektir ki, çıkışta elde edilen veri, kullanılan normalleştirme yönteminden direkt etkilenmektedir. Böylelikle  $x_k$  (normalleştirilmiş giriş),  $y_k$  (çıkış) ifadesine dönüştürülür.

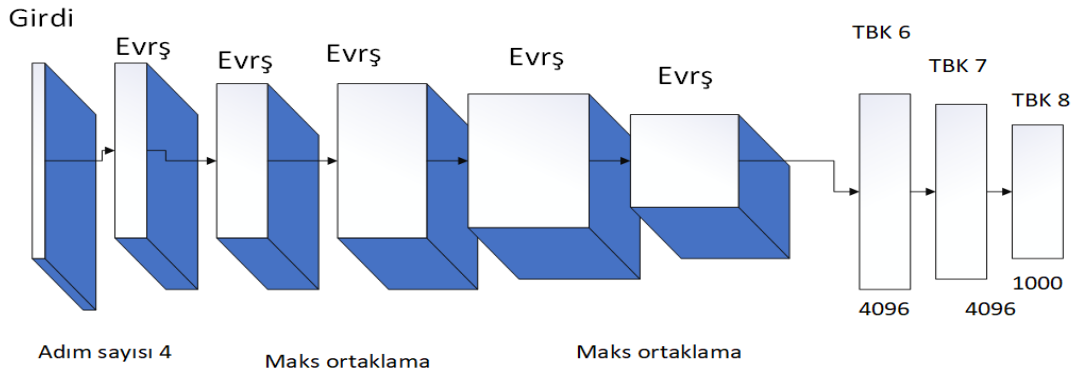
### 3.3.7 Paket Normalizasyon İşleminin Avantajları

Gizli katmanlara gelen verilerin kovaryans kaymasının azaltılması, paket normalizasyon işlemi sayesinde gerçekleşir. Birden çok boyutun birbiriyle ilişkisinin olup olmadığını anlamak için kovaryans değişimi kullanılabilir. Böylece eğitimlerin parametre ölçeğine ya da başlangıç değerlerine bağımlılığı azalır. Ayrıca model düzenli hale gelir. Modelin seyreltme, lokal cevap normalizasyonu ve diğer düzenleme tekniklerine duyduğu ihtiyaç azalmış olur. Yoğunlaştırılmış, doğrusal olmayan, yüksek öğrenme oranlarının kullanılması mümkün olur.

### 3.4 Geleneksel Evrişimli Sinir Ağları

#### 3.4.1 AlexNet Ağı

AlexNet, toplamda 8 katmandan meydana gelmektedir. Bu katmanlardan ilk 5'i evrişim katmanından, son 3'ü ise TBK'den oluşmaktadır. En sondaki katman, 1000 sınıf arasında bir dağılım sağlayan softmax fonksiyonuna bağlıdır.



Şekil 3.28: AlexNet ağı mimari yapısı

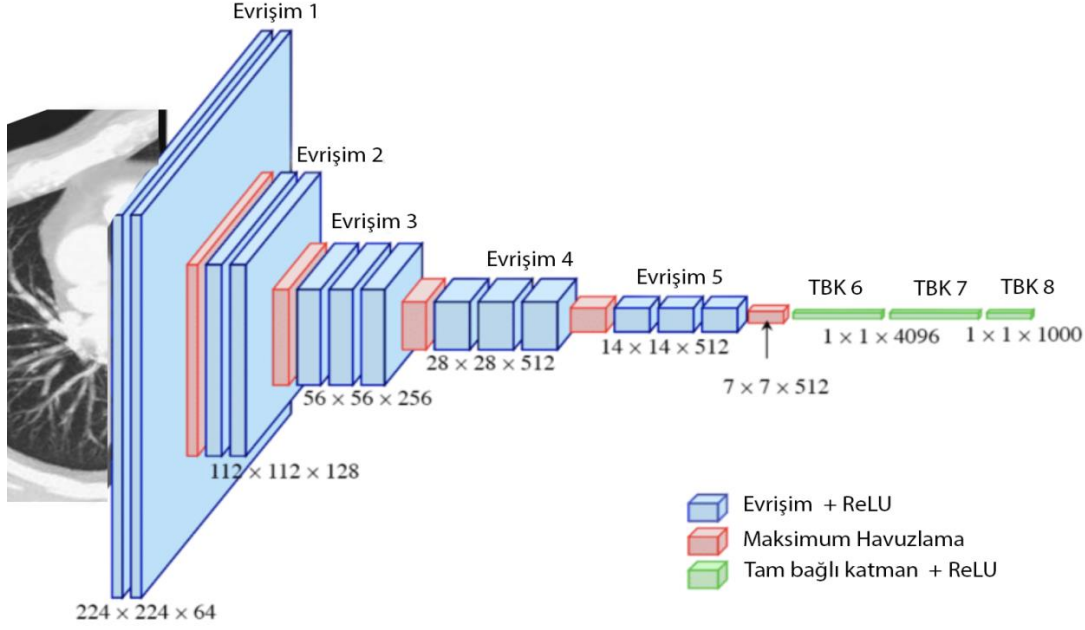
**Kaynak:** (C. Li et al., 2019)

Temel olarak bakıldığında bu ağ, aynı girdiye uygulanan havuzlama işlemleri ile birden çok evrişim işlemi uygulamasını baz alır. Girdiye aynı anda maksimum havuzlama işlemi ve 1x1, 3x3 ve 5x5 boyutlarındaki filtreler ile evrişim işlemi uygulanır. Uygulanan tüm bu işlemlerin sonuçları birleştirilir ve en sonda tek bir sonuç çıkarılır. Ağ, aynı anda hem spesifik hem de genel özellikleri çıkartabilmesini bu özelliğine borçludur. Şekil 3.28'de anlatılan bu ağ ile ilgili en çok göze çarpan problem, hesaplama açısından maliyeti

arttırmasıdır. Sebebi de 5x5 evrişimde sayısı az olsa bile çok sayıda filtreli bir evrişim tabakasının üzerinde bulunmasıdır. Havuzlama katmanları da eklendiğinde bu problem daha belirgin hale gelmektedir. Tüm aşamalarda havuzlama katmanının çıktısı ile bu evrişim katmanının çıktısını birleştirmek, çıktı boyutlarında kaçınılmaz bir büyümeyi beraberinde getirmektedir. Her işlemden önce boyut azaltma işlemi yapılırsa ağıın hesaplama maliyetini düşürmek mümkün olmaktadır. Şekil 3.28’de bahsedildiği üzere, 5x5 ve 3x3 boyutlarındaki filtreler uygulanmadan önce 1x1 boyutlarında filtre uygulanarak boyut küçültülmüştür. Şekil 3.28 de 2, 4 ve 5. katmanlarda bulunan filtre yalnızca aynı GPU'nun ve kendinden önceki katmanın filtrelerine bağlıdır. 3. Katman, 2. katmandaki bütün filtrelere bağlıdır. Her katmanın ardından ReLU uygulanmaktadır. İlk evrişim katmandaki parametreler, girdi boyutu 224x224x3 ve filtre boyutu 11x11x3 olan 96 filtre ve adım sayısı 4 pikselden meydana gelmektedir. İkinci katmanda, ilk katmanda normalize edilen ve havuzlama uygulanan çıktılarına 5x5x48 boyutlarında 256 adet filtre uygulanır. Üçüncü katmanda 3x3x256 boyutlarındaki 384 adet filtre, ikinci katmanın normalize edilen ve havuzlama uygulanmış olan çıktılarına uygulanır. Dördüncü katman 3x3x192 boyutlarında 384 adet, beşinci katman ise 3x3x192 boyutlarında 256 adet filtre uygular. TBK'de bulunan her bir katman 4096 nörona sahiptir.

### 3.4.2 VGG16 Ağı

VGG16 Ağı, temelde AlexNet ile aynı prensipler baz alınarak üretilmiştir. Ağıın girdisi RGB renk formatında, 224x224 boyutlarında bir resimdir. Ağa verilmeden evvel resimdeki her pikselden, eğitim setindeki resimlerle hesaplanan, ortalama resme ait olan piksel değerleri çıkartılır. Ağda kullanılabilen evrişimler 3x3 boyutlarındadır; derinliklerine de farklı değerler atanmıştır. Ek olarak bir konfigürasyonda 1x1'lik evrişim uygulanmıştır. Şekil 3. 29’da VGG16 ağı mimari yapısı gösterilmektedir.



**Şekil 3.29:** VGG16 ağı mimari yapısı

**Kaynak:** (Ding et al., 2017)

Ayrıca filtrenin adım sayısı 1 piksele sabitlenmiştir. Çıktının boyutlarının değişmeyeceği şekilde dolgu değerleri ayarlanmıştır. Bazı evrişim katmanlarının ardından toplam 5 defa,  $2 \times 2$  boyutlarında ve adım sayısı 2 olan maksimum havuzlama işlemi uygulanmıştır. Evrişim katmanlarından sonra her birinde 4096 adet filtre bulunan TBK'ler kullanılmıştır, son katmanda ise 1000 adet nöron kullanılmıştır. Son katman softmax katmanıdır.

Şekil 3. 29'da eğitim sırasında, VGG16 girdisi sabit boyutlu  $224 \times 224$  RGB görüntüden meydana gelmektedir. Görüntü ön işleminden sonra, eğitim setinde hesaplanan ortalama RGB değerini her pikselden çıkarmaktır. Görüntü, çok küçük bir alıcı alana sahip filtreler kullanıldığından bir evrişimli katman yığımından geçirilir. Bu  $3 \times 3$  bir filtre olarak düşünülebilir. VGG16 modelinde giriş kanallarının doğrusal bir dönüşümü olarak görülebilen  $1 \times 1$  evrişim filtrelerinden yararlanılmaktadır. Evrişim adımı 1 piksele sabitlenmiştir; modelde dolgu çözünürlüğün evrişimden sonra korunacağı şekilde ayarlanmıştır. Yani dolgu,  $3 \times 3$  dönüşüm için 1 pikseldir. Havuzlama için beş maksimum havuzlama katmanından yararlanılmaktadır.

Maksimum havuzlama, adım 2 ile  $2 \times 2$  piksellik bir pencere üzerinde gerçekleştirilir. Şekil 3. 29'da gösterildiği gibi evrişim katmanını 3 adet TBK




katmanı izlemektedir. İlk ikisinde 4096 kanal bulunur. Üçüncüsünde ise 1000 kanal mevcuttur. Son katman softmax katmanıdır. TBK konfigürasyonu tüm ağlarda aynıdır.

### 3.4.3 Inception v3 Ağı

Inception v3 mimarisi modüllerden meydana gelmektedir. Her bir modül, farklı boyutlu evrişim ve maksimum havuzlamalardan oluşur. Böylece her bir modüle 'inception' ismi verilmektedir. Tam olarak 9 Inception bloğundan meydana gelen modele GoogLeNet adı da verilmektedir. Kısacası Inception v3 bir tür evrişimli sinir ağı modelidir. Birçok evrişim ve maksimum havuzlama adımından meydana gelir. En son katman ise tam bağlı bir sinir ağı içermektedir. 2012 yılında evrişimli sinir ağı modellerini ve derin öğrenmeyi yeniden popüler hale getiren ilk çalışmadır. Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton gibi araştırmacılarca geliştirilmiştir (Dean, 2020). Temel olarak, birbirini takip eden evrişim ve havuzlama katmanları olduğundan LeNet modeline çok benzer. ReLU aktivasyon fonksiyonu olarak kullanılır ve havuzlama katmanlarında maksimum havuzlama kullanılır. Şekil 3. 30'da bahsedildiği üzere, 5x5 ve 3x3 boyutlarındaki filtreler uygulanmadan önce 1x1 boyutlarında filtre uygulanarak boyut küçültülmüştür. 2014 yılında düzenlenen ILSVRC14 yarışmasında birinciliği kazanan bu ağ, gereken maliyeti arttırmadan hesaplama için daha geniş ve daha derin bir yapı sunmaktadır. 22 tane katmanın meydana getirdiği ağa Inception adı verilmiştir. Bu isim Lin ve arkadaşlarının yaptıkları bir çalışma esnasında kullandıkları "Daha derine gitmeliyiz" konulu internet söyleminden türetilmiştir (Ding et al., 2017).

Temel olarak bakıldığında bu ağ, aynı girdiye uygulanan havuzlama işlemleri ile birden çok evrişim işlemi uygulamasını baz alır. Girdiye aynı anda maksimum havuzlama işlemi ve 1x1, 3x3 ve 5x5 boyutlarındaki filtreler ile evrişim işlemi uygulanır. Uygulanan tüm bu işlemlerin sonuçları birleştirilir ve çıktı olarak elde edilir. Ağ, aynı anda hem spesifik hem de genel özellikleri çıkartabilmesini bu özelliğine borçludur.



**Şekil 3.30:** Inception v3 mimari yapısı

**Kaynak:** (Wang et al., 2020)


Inception v3 ağından farklı olarak bu ağı, içeriğinde paket normalizasyonunu da bulundurmaktadır. Kısaca söylemek gerekirse, her bir katmanın çıktısında ortalama ve standart sapmanın hesaplanması ve bu değerlerle çıktıların normleştirilmesi işlemine "paket normalizasyonu" denmektedir. Bu işlem tüm sinir ağının sıfır ortalama ile aynı aralıkta sonuç vermesini sağlamaktadır. Inception v3 ağına farklı paket normalizasyon değerleri ile karşılaştırılması Şekil 3. 30'da gösterilmiştir. Inception v3 ağı 2015 yılında duyurulmuştur. Ağına derinlik ve genişliği eniyelenmiş, böylece ağıdan maksimum bilgi akışı almak hedeflenmiştir. Derinlik artınca sistematik olarak ağına genişliği de artmaktadır. Bu ağıda 5x5 ve 7x7'lik filtreler değil, onları karşılayacak 2 veya 3 adet 3x3 boyutlu filtre kullanılmaktadır. Şekil 3. 30'da Inception v3 ağı gösterilmiştir (Wang et al., 2020).

### 3.4.4 ResNet50 Ağı

Derin öğrenme mimarisinde ağına gerçek anlamda derinleşmeye başladığı mimari türdür. Bu yönüyle kendinden önceki modellerden farklıdır. ResNet50; kalıntı değerlerin (residual value) sonraki katmanları besleyen blokların (residual block) modele eklenmesiyle meydana gelmektedir (Alakwaa et al.,

2017). Bu özellik ResNet50 mimarisini klasik bir model olmaktan çıkarmaktadır.

Kısaca ResNet50 "residual network" isminden türetilmiştir. Şekil 3. 31'de Kalıntı (Residual) öğrenme blokları yapısı gösterilmektedir.



**Şekil 3.31:** Kalıntı (Residual) öğrenme blokları yapısı

Microsoft araştırma ekibince çok fazla derin ağlarda gradyan'ın 0'a yakınsaması problemini ortadan kaldırmak için geliştirilmiştir. ResNet50 (Choi et al., 2018) mimarisinin mantığı oldukça basittir, birkaç katman önde yer alan aktivasyon fonksiyonunu şu anki aktivasyon fonksiyonunun girdisiyle toplayıp aktive eder. Böylelikle üzerinde işlem yapılan katmanın lineer transform'unun sonucu 0 olsa bile bir çıktı meydana gelir. ResNet50 sayesinde "kaybolan gradyanlar" problemi meydana gelmeden öğrenme çok daha derin ağlarla gerçekleşir.

Şekil 3. 31'de gösterilen klasik ağa bazı kısa yollar eklenerek oluşturulan Microsoft ResNet50 Ağı, kalıntı bloklardan meydana gelmektedir. Kalıntı blokta  $x$  değeri girdi olarak alınır, evrişim – aktivasyon – evrişim serisinden geçirilir ve bir  $f(x)$  fonksiyonu elde edilir. Daha sonra  $f(x)$  fonksiyonuna orijinal girdi olan  $x$  değeri eklenerek  $h(x) = f(x) + x$  üretilir. Klasik evrişim işleminde  $h(x)$  fonksiyonu  $f(x)$  fonksiyonuna eşittir. Fakat bu ağda, girdiye evrişim işlemi uygulandıktan sonra orijinal veri de eklenmektedir (Ding et al.,

2017). Şekil 3. 31’de ağı oluşturan blok diyagramı gösterilmiştir. ResNet50 ağı, geleneksel ağlardan farklı bir yapıya sahiptir. Bu ağ 2015 yılında birinci olmuş, daha sonra eğitim hızını arttırmak amacıyla Inception yapısıyla kalıntı ağ bağlantıları birleştirilmiş ve böylece Inception v3 ağı geliştirilmiştir. Teoride, ResNet50 modele ne kadar katman eklenirse başarının o kadar artacağına inanılırdı fakat pratikte bu teorinin çalışmadığı deneyimlenmiştir.

### 3.5 Performans Metrikleri

Akciğer nodüllerini tespit etmek ve sınıflandırmak için geliştirilen DÖ algoritmalarının performansını analiz etmek için farklı ölçütler kullanılır. Çizelge 3.7’de görüldüğü gibi Matthews Correlation Coefficient (MCC), özgüllük, doğruluk, F2 skoru, F1-skoru, ROC eğrisi, FROC ve ROC eğrisinin altındaki alan olan (AUC) değerinden yararlanır. Hata Matrisi: MÖ’de kullanılan sınıflandırma modellerinin performansını değerlendirmek için hedef niteliğe ait tahmin değerleri ve gerçek değerlerin karşılaştırıldığı özel bir tablo düzenidir. Matrisin her satırı, tahmin edilen bir sınıftaki örnekleri temsil ederken, her sütun gerçek bir sınıftaki örnekleri temsil eder.

#### Çizelge 3.8: Derin öğrenme akciğer kanseri tespitinde kullanılan metrikler

---

• DP: BT görüntüsünde akciğer nodülü bulunur ve nodül ile BT görüntüsü olarak sınıflandırılır (Nardelli et al., 2018).
• YP: BT görüntüsünde akciğer nodülü yoktur ve nodül ile BT görüntüsü olarak sınıflandırılır (Nardelli et al., 2018).
• DN: BT görüntüsünde akciğer nodülü yoktur ve nodül olmadan BT görüntüsü olarak sınıflandırılır (Da Nóbrega et al., 2018).
• YN: BT görüntüsünde akciğer nodülü bulunur ve nodül olmayan BT görüntüsü olarak sınıflandırılır (Da Nóbrega et al., 2018).

---

Çizelge 3.7’de de gösterilen 4 değerlendirmeden en az birine sahip olmalıdır. Sistemin iki sınıfı karıştırıp karıştırmadığını görmeyi kolaylaştırmasından kaynaklanmaktadır. Hata matrisi Ayrıca Hata matrisi kullanılarak elde edilen ve her mimari için yararlanılan diğer değerler ise Doğruluk (Accuracy), Hassasiyet (Sensitivity), Özgüllük (Specificity), F2 skoru, MCC ve F1 skorudur (Bkz. Çizelge 3.8).

**Matthews Correlation Coefficient:** Doğruluk, hassasiyet gibi ölçütler, dengesiz dağılan veri kümeleri için çok da başarılı sonuçlar üretmez. Bu

nedenle, sonuçları sağlamak için Matthews Correlation Coefficient (MCC) kullanılmıştır. Temelde gerçek veriler ile tahmin edilen veriler arasındaki korelasyon (phi-coefficient) ilişkisine bakarak değerlendiren MCC kriteri, aşağıdaki formülde gösterildiği gibi hata matrisindeki tüm parametreleri kullanır.

**Çizelge 3.9:** Performans ölçümü parametreleri

<b>Metrik</b>	<b>Açıklaması</b>	<b>Notlar</b>
Hassasiyet	$SE = TP/(TP + FN)$	<b>(3.38)</b>
Özgüllük	$SP = TN/(TN + FP)$	<b>(3.39)</b>
Doğruluk	$ACC = (TP + TN)/(TP + TN + FP + FN)$	<b>(3.40)</b>
F2 skoru	$(5 * TP / (TP+FP) * TP / (TP+FN)) / (4 * TP / (TP+FP) + TP / (TP+FN))$	<b>(3.41)</b>
F1-Skoru	$F1 = 2TP/(2TP + FP + FN)$	<b>(3.42)</b>
ROC	Özgüllük ve ROC değeri arasındaki ilişkiyi gösteren eğri (Y eksenini gerçek pozitif orandır ve X eksenini yanlış pozitif orandır) (işlem karakteristiği eğrisi)	<b>(3.43)</b>
F- ROC	ROC eğrisine benzer, yalnızca X ekseninde farklılık gösterir. X eksenini, görüntü başına yanlış pozitif orandır	<b>(3.44)</b>
MCC	$DP * DN - YP * YN / \sqrt{(DP + YP) * (DP + YN) * (DN + YP) * (DN + YN)}$	<b>(3.44)</b>
AUC	ROC eğrisinin altındaki toplam alan $Gini = 2xAUC - 1$	<b>(3.45)</b>

**Kaynak:** (Nardelli et al., 2018)

Doğruluk, bir sınıflandırıcının başarısını göstermek için kullanılan en yaygın ölçüdür. Doğru tahminlerin toplam örnekleme oranıdır. Hassasiyet, doğru pozitif orandır. Doğru pozitif örneklerin sınıflandırıcı tarafından bulunan tüm pozitif örneklere oranı olarak kabul edilir. Öte yandan, özgüllük doğru negatif oranı olarak kabul görür. Doğru negatif örneklerin sınıflandırıcı tarafından bulunan tüm negatif örneklere oranıdır. ROC eğrisi, tanı testinin doğruluğunu tanımlaması ve testler arasında güvenilir bir karşılaştırma yapması açısından sık kullanılan bir yöntemdir. Son olarak, F2 skoru, sınıflandırıcı tarafından bulunan doğru pozitiflerin sayısının, pozitif olarak sınıflandırılan örneklerin toplamına oranıdır.

- **Karakteristik Eğrisi (ROC) ve Eğri Altında Kalan Alan (AUC)**

TBA uygulandıktan sonra, "n" boyutlu uzay daha az bir boyuta indirgenmiş olmaktadır. Bu yeni boyutlara Temel Bileşenler adı verilmektedir.

**Sınıflandırma Modellerinde Başarı Kriterleri:** Performans ölçümü, MÖ'de önemli bir yer tutmaktadır. Bu nedenle bir sınıflandırma probleminin performansını değerlendirmek için Karakteristik Eğrisi (ROC) ve Eğri Altında Kalan Alan (AUC) eğrisinden yararlanılmaktadır. Bu yaklaşım, herhangi bir sınıflandırma modelinin performansını kontrol edebilmek açısından en önemli değerlendirme kriterlerinden biri olarak görülmektedir. Sınıflandırma algoritmalarını kullanarak yapılan çalışmalarda en büyük yanılgılardan biri, başarı kriteri olarak yalnızca doğruluk oranına bakmaktır. Özellikle dengesiz veri setlerinde (imbalanced data sets) doğruluk oranı doğru bilgilere ulaşılmasını güçleştirmektedir. Çünkü dengesiz veri seti, sınıflar arasındaki dağılımın yakın olmadığı veri setlerini tanımlarken kullanılmaktadır.

Eşik değeri değiştirilerek “doğru pozitif oranı- yanlış pozitif oranı” grafiğine sahip olması sağlanan İşlem Karakteristik Eğrisi'nin (Receiver Operating Characteristic Curve, ROC) altında kalan alan (Eğri Altında Kalan Alan, AUC) global performans ölçeği olarak çokça başvurulan bir yöntemdir. AUC değeri, genellikle 0 ile 1 arasında değişmektedir.

Rastgele tahminlerle kararlar veren bir algoritmanın ROC eğrisi diyagonal bir çizgi oluşturuyorsa, AUC değeri 0,5'tir. AUC değeri ile doğru karar verilme olasılığı arttırılmaktadır. İki ROC eğrisinin AUC'si ne kadar yüksekse bir bütün olarak eğri o kadar iyidir. Ancak, geçerli bir karşılaştırma için belirli hususların dikkate alınması gerekmektedir. Örneğin; ROC eğrileri farklı veri kümeleri kullanılarak oluşturulursa veri kümelerinin zorluk seviyeleri aynı kabul edilmektedir. Bilgisayarda medikal görüntü analizi algoritmasıyla oluşturulan bir ROC eğrisi genellikle 10 veya 100 değerinde meydana gelmektedir. İşlem için  $(DP_i, YP_i)$ ,  $i=1, \dots, k$  ve  $i$  değerinin artışıyla TP değerlerinin azalmadığı varsayılmakta, yamuk kuralı uygulanmakta ve AUC değeri, Denklem 5.1'de görüldüğü şekilde hesaplanmaktadır.

$$AUC = \sum_{i=1}^{k-1} (FP_{i+1} - FP_i)(TP_i + TP_{i+1})/2 \quad (5.1)$$

Denklem 5.1'de görüldüğü gibi; hata matrisi, tahminin (1 veya 0) gerçek değer (1 veya 0) ile birleşimidir. Tahmin değeri ve doğru değerler, sınıflandırılmış ya da sınıflandırılmamış olma durumlarına göre 4 bölüme ayrılmaktadır. Bunlar, performans ölçümü bölümünde detaylı bir şekilde açıklanmaktadır.

AUC genel bir performans ölçümü olduğu için bazı önemli ayrıntılar gözden kaçabilir. Bu durumda ROC eğrisinin altında belirli bir DP aralığı, YP aralığı veya her ikisi için kısmi bir bölge hesaplamak daha uygun olabilir. Genel olarak, aynı DP veya YP aralığındaki kısmi AUC'leri karşılaştırmak uygundur. Herhangi bir nedenle farklı DP aralıkları için hesaplanan AUC'leri karşılaştırmak gerekirse farklı DP aralıklarında, en az sayıda farklı değer üzerinden normalleştirme yapılmalıdır. Kısmi AUC için en küçük değer, çapraz çizgiden belirlenebilir. Fakat bu şekilde normalleştirilse bile, farklı DP aralıklarındaki AUC'leri karşılaştırmak anlamlı olmayacaktır.

**Free Response ROC eğrisi:** Amaç, BT görüntülerindeki tüm anormal oluşumları tanımlamak olduğunda FROC gibi bir performans ölçüğü seçilmelidir. Standart ROC eğrisinde, görüntü ile ilgili algoritmanın bir senaryo olduğu varsayılarak, görüntü için "anormallik yok" veya "anormallik var" şeklinde bir karara varılmaktadır. Eğer "anormallik var" kararı hatalıysa görüntünün tamamı YP olmaktadır. Görüntü başına yalnızca bir adet YP olabilir. Bu nedenle, bir görüntü setinde bulunabilecek YP'lerin sayısı, görüntülerin sayısına eşittir. Daha genel bir senaryoda ise algoritma, görüntüdeki herhangi bir anormal bölgeyi tanımlamaktadır. Bu senaryoda, bir görüntü için birden fazla YP olabilir. FROC eğrisinde tespit algoritması, görüntü içinde herhangi bir yere özel sonuç üretebilir. Mümkün olan maksimum YP sayısı algoritma tarafından belirlenmektedir.

FROC eğrisinde, algılama algoritması görüntünün herhangi bir yerinde belirli sonuçlar üretebilir. X eksenini, mümkün olan maksimum YP sayısı sabit olmadığından, 0 ile 1 arasındaki değerleri içermemektedir. Bunun yerine, her bir görüntü için alınan ortalama YP sayısı dahil edilmektedir. FROC eğrisinde, TP ve FP seviyelerinde 0 değer elde etmek mümkündür. FROC eğrisi, algoritmanın genelleştirilmiş özgüllüğü ve F2 skoru arasındaki değişim alanını temsil etmektedir. X ekseninde sabit bir maksimum değer olmadığından, DP değeri en yüksek sayıya ulaştığında veya görüntünün uygulama için çok büyük olduğu durumlarda, bazı YP değerleri kırılmaktadır. Eğrinin altındaki alanlar kullanılarak iki FROC eğrisi karşılaştırılabilir. Genel olarak, eğrinin altındaki alan yamuk kuralı uygulanarak tahmin edilebilir. Aynı DP ve YP aralığındaki iki FROC eğrisini karşılaştırmak daha anlamlı olmaktadır.






## 4. MODEL ÇALIŞMALARINA YÖNELİK GÖRÜNTÜ İŞLEM SÜRECİ

### 4.1 Dalgacık Dönüşümü

BT görüntüleri ile nodül belirleme tekniğinde, birden fazla iç içe geçmiş parametrik değişken incelenmelidir. Bu çalışmada kullanılacak Dalgacık Dönüşümü (DD), ilk kez 1909 yılında Alfred Haar tarafından doktora tezinde "dalgacık" terimi olarak kullanılmıştır (Kozłowski, 2005). Zaman içinde Daubechies, Coifman ve Wickherhouser gibi birçok önemli araştırmacı bu konuda önemli bir ivme kazanmıştır. Dalgacık analizi ile daha önce geliştirilmiş olan Fourier analizinde eksik zaman bilgisi elde edilir. Diğer bir deyişle dalgacık analizi, zamanla değişen bir sinyalin zaman ölçeğindeki perspektifine bakmamızı sağlayan bir tür dönüşümdür. DD pek çok alanda kullanıldığı gibi tıp alanında da görüntü işleme alanlarında da geniş bir yelpazeye sahiptir (AYDIN, F., & Aslan, Z. 2017). Gerek sinyal işleme gerek görüntü işleme olsun DD MÖ'sü yanında yer almaya başlamıştır. DD dinamik sinyalleri işleme olanağı sağlamaktadır. Ayrıca DD durağan ve durağan olmayan sinyallerin analizinde geniş bir uygulamaya sahiptir. Bu uygulamalar, sinyallerden elektriksel gürültünün giderilmesini, ani süreksizliklerin saptanmasını ve büyük miktardaki verilerin sıkıştırılmasını içerir. Şekil 4.1'de Ayrık Fourier dönüşümü ve Kısa süreli Fourier dönüşümü ile Ayrık Dalgacık Dönüşümü için zaman-frekansı gösterilmektedir.



**Şekil 4.1:** (a) Ayrık Fourier dönüşümü, (b) Kısa süreli Fourier dönüşümü ve (c) Ayrık Dalgacık Dönüşümü için zaman-frekansı

**Kaynak:** (Daubechies, 1988)

Şekil 4.1'de görüldüğü gibi DD, birçok farklı türde görüntülerin analiz, iletim ve sıkıştırılması işlemlerinde önemli kolaylıklar sağlamaktadır. DD ile, bir sinyali, bir

sinyalin temsilinin sinüs ile olduğu Fourier dönüşümü gibi, her biri iyi tanımlanmış, baskın bir frekansa sahip dalgacıklar olarak bilinen bir grup oluşturucu sinyale ayırtmak mümkündür. DD'de, dalgacıklar kısa sürenin geçici fonksiyonlarıdır, yani belirli bir zaman etrafında ortalanmış sınırlı süredir. Fourier dönüşümünün problemi, zaman alanından frekans alanına geçerken zaman içinde olanların bilgisinin kaybolmasıdır. Fourier dönüşümü kullanılarak elde edilen frekans spektrumunu gözlemlemek, analiz edilen sinyalin frekans içeriğini ayırt etmek kolaydır, ancak frekans spektrumu sinyalinin bileşenlerinin ne zaman görüldüğünü veya kaybolduğunu bulmak mümkün değildir. Fourier dönüşümünden farklı olarak DD, zaman içinde ve frekans alanlarında bir sinyalin zaman içindeki frekans içeriğinin evrimi hakkında bilgi veren bir analize izin verir. DD kullanarak sinyallerden elektriksel gürültüyü gidermeye yönelik öncü çalışma, sinyallerde Gauss beyaz elektrik gürültüsünün giderilmesi için bir eşik kullanılmasını öneren Donoho ve Johnstone çalışmalarında işlemektedir (Ramos et al., 2017). ADD, elektrik gürültüsünün azaltılması prosedürlerini, sadece hızlı Fourier dönüşümü sistemlerinin düşük geçişli filtrelerinin kullanımı ile değiştiren yeni bir alternatif olarak elektrik gürültüsünün ortadan kaldırılması için uygun bir araç olarak kabul edilir. Elektriksel gürültünün çok küçük bir bant örtüşmesine sahip olduğu veya filtreleme yöntemini kullanabilmek için sinyal ve gürültüden tamamen farklı olduğu durumlarda kullanılır.

Fourier dönüşümünün örneğinde olduğu gibi, DD ayrıklaştırılmıştır ve ADD olarak bilinir ve geleneksel Fourier dönüşümü yöntemlerine göre önemli bir avantaj sağlar. DD, bir sinyali farklı frekans bantlarını temsil eden çeşitli ölçeklere ayırır ve her ölçekte DD'nin konumu, elektrik gürültüsünün tanımlanabileceği ve etkili bir şekilde çıkarılabildiği önemli zaman özelliğinde belirlenebilir. Kısa süreli dalgacıklar, bilginin yüksek frekanslı bileşenlerden çıkarılmasını sağlar. Bu, elektriksel gürültünün ortadan kaldırılması için önemli bir bilgidir, çünkü elektriksel gürültünün yüksek frekanslı dalgalanmalar gösterme olasılığı daha yüksektir. Uzun süreli dalgacıklar, düşük frekanslardan bilgi almanızı sağlar. Yüksek ve düşük frekansların bilgisiyle, elektrik gürültüsünün istenmeyen eşiklerinin altındaki bir eşik ve sıfır değerlerini tanımlayabiliriz.

Bu çalışma dinamik olmayan Fourier dönüşümüne ADD üzerine odaklanmıştır; çünkü sinyaller zamanın fonksiyonu olarak görüldüğünden dinamiklerdir. Bu


matematiksel dönüşümler elde edilemeyen bilgilere ulaşılma imkânı sağlamaktadır. Bu durum sinyal işleme açısından çok önemlidir. Başlıca dalgacık türleri Çizelge 4.1'de verilmiştir.

**Çizelge 4.1:** Başlıca dalgacık türleri

I.	Symlet Dalgacık
II.	Biortogonal dalgacık
III.	Daubechies dalgacık
IV.	Gaussian dalgacık
V.	Haar dalgacık
VI.	Coiflet dalgacık

**Kaynak:** (Nason & Silverman, 1994)

DD,  $\Psi(t)$  örnek fonksiyonunun ölçeklendirilmesi ve çevrilmesiyle oluşturulan temel fonksiyona sahip bir işaretin analizi olarak ifade edilir. Bu temel işlevlerin sonlu süresi ve titreşimli dalga özellikleri vardır ve bu dalgalara dalgacık adı verilir. Dalgacıklar ilk kez, 1900'lerin başlarında Haar kullanılmıştır. Şekil 4.2'de DD'de kullanılan pencere ve çözünürlük hücreleri gösterilmektedir.



**Şekil 4.2:** Dalgacık Dönüşümünde kullanılan pencere ve çözünürlük hücreleri

Şekil 4.2'de gösterildiği gibi Fourier dönüşümü, işaretin tamamı üzerinde bir dönüşüm yaparak işaret hakkında bilgi verir. Sabit aralıklı zaman penceresi sinyallerine uygulanan Fourier dönüşümü ile belirli bir frekansın zaman bilgisi elde edilemez. Bu anlamda, sadece geçerli zaman aralığındaki frekans bileşenleri hesaplanabilir. Fourier dönüşümündeki bu eksiklikler, 1946'da Gabor tarafından pencere fonksiyonu olarak tanımlanan sabit bir fonksiyonun dönüştürülmesi ile taranan herhangi bir sinyalin ortadan kaldırılmasına ve bölgesel frekans analizine izin verilmiştir.

Gabor dönüşümü adı verilen bu dönüşüm, oluşturulan yeni algoritma ile farklı pencere fonksiyonları kullanılarak "Kısa Süreli Fourier Dönüşümü, Kısa Süreli Fourier Analizi" olarak yenilendi. Ayrıca yüksek frekans bileşenleri zaman serisindeki ayrıntılar hakkında da bilgi sağlanmaktadır. Alçak ve yüksek frekanslı bileşenlerin bir zaman serisi üzerindeki etkisi, BT görüntüsü zaman serileri sayesinde çok daha iyi anlaşılabilir. Bir aşamalı filtreleme sayesinde ayrık dalgacık dönüşümü ile zaman serileri alçak ve yüksek frekans bileşenlerine ayrıştırılır. Bu bileşenler yaklaşım (approximations) ve detay (coefficients) bileşenleri olarak adlandırılır. Burada yaklaşım bileşeni yüksek ölçek değerlerine sahip olmasına rağmen, zaman serilerindeki düşük frekans değerlerini temsil etmektedir. Detay bileşenleri, zaman serilerinin yüksek frekans değerlerini düşük ölçek değerleri ile temsil etmektedir. Yaklaşım bileşeni A harfi ile ve detay bileşenleri D harfi ile belirtilmiştir. Bu filtreler Alçak Geçiren Filtre (AGF) ve Yüksek Geçiren Filtre (YGF)'dir. AGF alçak frekans değerlerine sahip yaklaşım bileşenini oluştururken, diğer taraftan YGF yüksek frekans değerlerine sahip detay bileşenini oluşturur. Kısa Süreli Fourier Analizlerde kullanılan pencerelerin sabit boyutu nedeniyle, zaman frekansı alanında elde edilen bilgiler sınırlı bir hassasiyetle elde edilebilir. Her görüntü, kullanılarak 2 seviyede ayrıştırılır. Bunlar AA, YA, AY ve YY gibi gruplara ayrılır. DD, dinamik ve anlık değişikliklerle sinyallerin analizinde kullanılan bir tekniktir. Bu da farklı ölçeklerde DD'nin yeniden çözülme özelliğinden kaynaklanmaktadır. Çizelge 4.2'de DD'nin başlıca uygulama alanları gösterilmektedir.

**Çizelge 4.2:** Dalgacık Dönümünün başlıca uygulama alanları

I.	Veri sıkıştırma
II.	Görüntü süzme
III.	Biyomedikal mühendisliği uygulamaları
IV.	Kısmi diferansiyel denklemlerin sayısal çözümü
V.	Uzay çalışmaları
VI.	YSA olarak sayılabilir

Çizelge 4.2'de gösterildiği üzere DD işaret üzerindeki düşük frekansları yakalamak için geniş pencere işlevlerini ve Kısa Süreli Fourier Analizdeki sınırlamayı ortadan kaldırmak için sabit genişlikli pencereler yerine yüksek frekansları yakalamak için dar pencere işlevlerini kullanan bir pencereleme tekniğidir (Shankar, 2004). Dalgacık belirli bir zaman aralığında salınan bir dalga gösterir. Bu nedenle hem zaman hem de frekans bakımından sınırlı bir yapıya sahiptir. DD, ses ve görüntü

sıkıştırılmada görüntü analizindeki avantajlar, çok çözünürlüklü sinyal işleme ve iki boyutlu sinyal işlemede önemli bir kullanım alanı bulmuştur. Son yıllarda DD'nin başlıca uygulama alanları Çizelge 4.2'de gösterilmiştir.

#### 4.1.1 Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümünde (SDD) sinyal, kısa süreli fourier dönüşümündeki pencere işlevine benzer olan dalgacık işlevi ile çarpılır ve dönüşüm, zaman alanındaki farklı zaman aralıkları için hesaplanır. Başka bir deyişle, DD, bir işaretin veya sinyalin fonksiyon (x) örnek fonksiyonunun ölçeklendirilmesi ve çevrilmesi ile oluşturulan temel fonksiyonlarla analizine dayanır. Herhangi bir f (x) fonksiyonunun SDD;

$$w_f(a, b) = \langle f, \Psi_{a,b} \rangle = \int_{-\infty}^{\infty} f(x) \Psi_{a,b}(x) dx \quad (4.1)$$

Denklem 4.1'de,

f(x): DD alınacak işaret/sinyali,

$\Psi_{a, b}(x)$ : Dalgacık taban fonksiyonu

$W_f(a, b)$ : f (x)'in DD'yi göstermektedir. Sürekli DD'deki taban fonksiyonu  $\Psi_{a, b}(x)$ ,  $\Psi(x)$  ana fonksiyonun ölçekleme ve öteleme terimleri dikkate alındığında aşağıdaki gibi tanımlanır:

$$\Psi_{a, b}(x) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right) \quad (4.2)$$

Denklem 4.2'de "a", ölçek parametrelerini ve b, çeviri parametrelerini gösterir. Fourier dönüşümü  $\Psi(s)$  olan ana dalgacık fonksiyonunun  $\Psi(x)$  gerçek değerde olması için, aşağıdaki kabul edilebilirlik gerekliliğini karşılaması gerekir:

$$C\Psi = \int_{-\infty}^{\infty} \frac{|\Psi(s)|^2}{s} ds \quad (4.3)$$

Denklem 4.3'te:

$C_\Psi < \infty$  şartını sağlar ve bu durum kazancın sıfır olması anlamına gelmektedir.

$$\Psi(0) = \int_{-\infty}^{\infty} \Psi(x) dx = 0 \quad (4.4)$$

Denklem 4.4'te  $\Psi(0) = 0$  ise,  $\Psi(\infty) = 0$  olduğu manasına gelmektedir. Bu, dalgacığın genlik tepkisinin bir bant geçiren filtrenin aktarım fonksiyonuna benzediğini gösterir.  $\Psi(x)$  'in ana dalgacık fonksiyonu, sıfır dürtü yanıtı olan

herhangi bir bant geçiren filtre gibi artan frekanslarla yeterince hızlı bir şekilde sıfıra indirmeyi mümkün kılar (Kozłowski, 2005). Belirli bir  $W_f(a, b)$  DD'den ters SDD kullanılarak,  $f(x)$  işareti fonksiyonu yeniden kazanılabilir. Ters SDD, Denklem 4.5'te

$$f(x) = \frac{1}{c_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} w_f(a, b) \frac{\Psi_{a,b}(x)}{a^2} db da \quad (4.5)$$

şeklinde ifade edilmektedir.


#### 4.1.2 İki Boyutlu Sürekli Dalgacık Dönüşümü

İki boyutlu  $f(x, y)$  fonksiyonunun SDD,

$$W_f(a, b_x, b_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \frac{\Psi_{a,b_x,b_y}(x,y)}{a^3} db_x db_y da \quad (4.6)$$

şeklinde ifade edilmektedir. Denklem 4.6'da bulunan  $\Psi_{a, b_x, b_y}(x,y)$  dalgacık taban fonksiyonu aşağıdaki şekilde tanımlanmaktadır.

Tek boyutlu ADD, görüntüler gibi iki boyutlu işlevler için kolayca ifade edilebilir. İki boyutlu ayrık dalgacık işlevi, iki boyutlu ölçekleme işlevi  $\Phi(x, y)$  ve  $\psi^H(x, y)$ ,  $\psi^V(x,y)$  ve  $\psi^D(x,y)$  gibi yatay, dikey ve köşegen iki boyutlu dalgacık fonksiyonlarını kullanarak iki boyutlu ayrık dalgacık fonksiyonunu ifade edebilir (Kozłowski, 2005). Bu çalışmada  $\Psi^H(x, y)$  çizgi boyunca çizgiyi değiştirir;  $\Psi^V(x, y)$  sütun boyunca görüntüde değişir;  $\Psi^D(x, y)$  görüntünün diyagonalinde meydana gelen değişiklikleri gösterir. Şekil 4.3'te gösterildiği üzere ADD'de ayrıştırma ve birleştirme süreçleri gösterilmektedir.



**Şekil 4.3:** ADD'de ayrıştırma ve birleştirme süreçleri gösterimi

**Kaynak:** (Kozłowski, 2005).

Şekil 4.3'te gösterildiği gibi iki boyutlu ölçekleme ve iki boyutlu yönlü dalgacık fonksiyonları genel olarak gibi ifade edilebilir. Bu algoritmanın şematik bir temsili Şekil 4.3'te verilmektedir. Dijital filtreler ve altörnekleme işlemleri iki boyutlu

ayrık dalgacık dönüşümlerinde de kullanılabilir. Burada, her seviyede, önce yatay olarak, sonra dikey olarak alttan kesme ve üst geçiş filtreleme gösterilmektedir

Ayrışma işlemi sonucunda elde edilen yüksek frekanslı ve düşük frekanslı alt görüntüler kullanılarak, orijinal görüntü tekrar elde edilebilir. Bu sürece sentez denir. Basitçe, birleştirme işleminde, ayırma işleminde gerçekleştirilen işlemlerin bir simetrisi takip edilir.

S: Sinyal, g: Alçak geçiren filtre, h: Yüksek geçiren filtredir. Her seviyede yüksek geçiren filtre detay (Y) bilgiyi oluştururken, alçak geçiren filtre yaklaşık (A) bilgiyi oluşturmaktadır.

### 4.1.3 Ayrık Dalgacık Dönüşümü

Sürekli dalgacık dönüşümündeki işlem ve veri kapasitesi çok büyük olduğu için işlem verimliliğini arttırmak amacıyla konum ve ölçeklerin ikili kuvvetleri alınır ve bu işleme ADD denir. Sürekli dalgacık dönüşümünün her  $\tau$  öteleme değeri ve her a ölçek değeri için hesaplama gerektirdiği göz önünde bulundurulursa, gereksiz işlem den kaçınmak amacıyla  $\tau$  ve a değerleri ayrıştırılarak sürekli dalgacık dönüşümünden ayrık dalgacık dönüşümüne geçiş sağlanmaktadır (Saravanan & Ramachandran, 2010). Fakat SDD'de, tüm dalgacık katsayılarını ölçeklendirerek hesaplayarak çok sayıda katsayı elde edilir. Bu çok fazla veri ve işlemsel yük oluşturur. Bu dezavantajı ortadan kaldırmak için ADD geliştirilmiştir.

ADD, dalga boyu katsayıları ölçek değerlerini ikili olarak seçerek hesaplanır, böylece işlem sayısında ciddi bir azalma sağlanır. Bu  $\psi \in L_2(R)$  fonksiyon bir dalgacıktır, eğer fonksiyonlar ailesi tarafından tanımlıysa


$$\psi_{j,k}(t) = 2^j \psi(2^j t - k) \quad (4.7)$$

$$\Psi_{j,k}[x] = \frac{1}{2^j} \psi(2^j x - k)$$

Denklem 4.7'de j ve k tamsayılar, bir  $\psi_{j,k}(t)$  ortonormal temeli çerçevedir (Zahra et al., 2012). Çeviri ve ölçekleme parametreleri olarak seçilen yeni ölçek değerleri kesikli değerlerdir ve kesikli DD şeklindedir. Ayrıca zaman serileri için, düşük frekans bileşeni, serinin en önemli parçasıdır. Bu bölüm sadece zaman serisinin ana karakterini göstermekle kalmaz, aynı zamanda dizinin genel davranışları hakkında da bilgi verir.

$$W[a, b] = \sum_x f[x] \Psi_{a,b}[x] \quad (4.8)$$

Denklem 4.8’da “a ve b” ayrık değerler  $a=2^j$  ve  $b=2^k$  ( $j, k \in \mathbb{Z}$ ) olmak üzere, dalgacık taban fonksiyonu, olacak şekilde yeniden yazılabilir. Şekil 4.4’te DD’de işaretin altbandlara ayrışımı gösterilmektedir.



**Şekil 4.4:** Dalgacık Dönüşümünde işaretin altbandlara ayrışımı

**Kaynak:** (NİZAM & Korürek, 2011)

Şekil 4.4’te görüldüğü üzere dalgacık katsayılarının sadece seçilen ölçek ve zaman aralığında hesaplanması önemli bir avantaj sağlayacaktır.

Dalgacık katsayılarının ölçek değerlerinde hesaplanması çok miktarda katsayının oluşmasına ve işlem yüküne neden olduğundan dolayı, katsayıların yalnızca seçilen ölçekler ve zaman dilimleri için hesaplanması birçok avantaj sağlar. En çok kullanılan ölçek adımı ikilik ölçek ve zaman adımıdır.



Seçilmiş yeni ölçek değerleri ile yeniden ifade edilen ve ayrık dalgacık dönüşümü için kullanılan dalgacık fonksiyonudur. Kullanılan DD ağacı Şekil 4.4'te gösterilmektedir. Burada görülen  $h(n)$  ve  $g(n)$  filtreleri için DD ailesinden Daubechies filtresidir. Ayrık değerli  $x[n]$  işareti, DD, yaklaşık A ve detay D'de alt bantlara bölünür. Bu şekilde, orijinal işaret düşük geçişli  $h[n]$  ve yüksek geçişli  $g[n]$  yaklaşık alt bantta belirli sayıda skalaya bölünür. Çoklu çözünürlük olarak da bilinen bu işlem, Şekil 4.4'te ayrıntılı olarak gösterilmiştir.

ADD, orijinal sinyalin analizi ve sentezi için yeterli bilgi sağlar ve hesaplama yükünü azaltır. Ayrık dalgacık dönüşümündeki ana fikir, SDD'deki mantığın aynısıdır. Dijital sinyalin zaman ölçekli temsili, dijital filtreleme teknikleri kullanılarak elde edilir. SDD, dalgacık ve işaret arasındaki farklı ölçeklerdeki ilişkiyi gösterir. Burada benzerlik kriteri ölçek veya frekanstır. İşaretteki yüksek frekanslı varyasyonlarını analiz etmek için bir dizi yüksek geçiren filtrelerden ve düşük frekans varyasyonlarını analiz etmek için bir dizi düşük geçiren filtrelerden yararlanır. Yaklaşıklık katsayıları olarak isimlendirilen işaret alçak geçiren filtre çıkışındaki işaretin alt-örneklenmesi ile elde edilirken; Ayrıntı yüksek geçiren filtre çıkışındaki işaretin alt-örneklenmesi ile elde edilen işarettir. ADD iki fonksiyon kümesinden yararlanır. Bunlar alçak geçiren ve yüksek geçiren fonksiyon kümeleridir. İşareti farklı frekans bantlarına ayrılması, zaman-uzay sinyalinin tekrar tekrar yüksek ve alçak geçiren filtrelerden geçirilmesiyle elde edilir. Orijinal  $x(n)$  işareti önce bir yarım bant yüksek geçişli  $g(n)$  filtresinden ve bir düşük geçişli  $h(n)$  filtresinden geçirilir. Filtreleme sonrası işarettaki en yüksek frekans  $\pi$  yerine  $\pi/2$  olduğundan, işarettaki örneklerin yarısı elimine edilebilir. Bu nedenle, işaret 2 ile alt örneklenmiştir. Aynı ayrıştırma seviyesinde iki filtre çıkışı üst-örneklenip birleştirme filtrelerinden sonra eklenirse, orijinal  $x(n)$  işareti elde edilir.

#### **4.1.4 Haar Dalgacı**

Sinyal işleme, sinyalde bulunan bilgilerin elde edilmesi için kullanılan teknikleri içerir. Sinyal işleme ile bir sinyalin özellikleri zaman ve frekans uzaylarında eşzamanlı olarak incelenir.

Bir sinyalin özellikleri zamanla değişmiyorsa bunlara "durağan sinyal" denir. Durağan bir sinyalde de beklenmeyen olaylar görülebilir fakat bu olayların olasılığı istatistiksel olarak tahmin edilebilir. Durağan sinyalleri incelemek için Fourier

Dönüşümü kullanılır. Fourier Dönüşümü ile bu sinyaller, sinüs ve kosinüs dalgalarının lineer birleşime ayrışır. Herhangi bir  $f(t)$  fonksiyonunun Fourier Dönüşümü (FD),

$$F(f) = \int_{-\infty}^{\infty} f(t)e^{-i2\pi ft} dt \quad (4.9)$$

Denklem 4.9'da  $F(f)$  ile verilir. Böyle bir fonksiyonun Ters Fourier Dönüşümü (TFD) ise onu izleyen bağıntı ile tarif edilebilir.

$$f(t) = \int_{-\infty}^{+\infty} F(f)e^{i2\pi ft} dt \quad (4.10)$$

Denklem 4.9 ve 4.10 bağıntıları, periyodik olmayan fonksiyonlar için düzenlenmiştir ve bu fonksiyonların zaman / frekans ortamında tanımlarını vermektedir.

Simgesel olarak Fourier Dönüşümünü (Fourier Transform (FD)) ve TFD aşağıdaki gibi gösterilebilir.

$$\begin{aligned} f(t) &\xrightarrow{\text{FD}} F(f) \\ F(f) &\xrightarrow{\text{TFD}} f(t) \end{aligned} \quad (4.11)$$

eğer  $F(f)$  karmaşık bir fonksiyon ise;

$$F(f) = R(f) + iI(f) = A(f)e^{i\Phi(f)}$$

Denklem 4.11'de  $R(f)$ ,  $F(f)$  fonksiyonunun gerçel (real) kısmını;  $I(f)$ ,  $F(f)$  fonksiyonunun sanal (imaginer) kısmını göstermektedir.

Denklem 4.12 ve 4.13 genlik ve faz bağıntıları gösterilmektedir.


$$A(f) = \sqrt{R(f)^2 + I(f)^2} \quad (4.12)$$

ve

$$\Phi(f) = \arctan\left(\frac{I(f)}{R(f)}\right) \quad (4.13)$$

şeklinde yazılabilir.

Şekil 4.5 a'da sayısal olarak türetilen 2 sinüzoidalın toplamı, Şekil 4.5 b'de ise genlik spektrumu verilmektedir.




**Şekil 4.5:** Haar Dalgacığı ile üretilmiş iki farklı görüntü

Aynı yıllarda Paul Levy, Haar Temel Fonksiyonu olarak adlandırılan değişken ölçekli temel fonksiyonu kullanarak rastgele bir sinyal tipi olan Brownian Hareketi'ni araştırmıştır. Bu çalışmada Brownian Hareketi'nin küçük ve karmaşık detaylarının incelenmesinde Haar Temel Fonksiyonlarının Fourier Temel Fonksiyonlarına göre çok daha üstün olduğu sonucu çıkmıştır. Burada kullanılan başka bir dalgacık ise Haar dalgacığıdır ve diğer dalgacıklar Haar dalgacığın türetilmesi yoluyla elde edilirler.

Dalgacıkların ilk bahsi A. Haar'ın (1909) tezinde bulunan bir ekte geçmiştir. Haar dalgacıkları bazı sınırlı uygulamalar için geçerli olup, bilinen en basit ve en eski dalgacık fonksiyonudur. Haar dalgacığının bir özelliği, tam dayanağa sahip olmasıdır. Yani Haar dalgacığı sonlu bir aralık dışında sıfır olur. Ne yazık ki Haar dalgacıklarının türevi sürekli değildir ve bu özellik de onların uygulamalarını biraz sınırlar. 1930'lu yıllarda değişken ölçekli taban fonksiyonlar üzerine yapılan çalışmalarda, Littlewood ve Paley (1937) ölçeği değişirken enerjisini koruyan fonksiyonlar elde etmişlerdir.

Baz Fonksiyonları ve Ölçeği Değişen Baz Fonksiyonları kavramlarını anlama, dalgacıkları anlamının temelini oluşturmaktadır. 1950–1960 yılları arasında Littlewood-Paley teorisi, kısmi diferansiyel denklemler ve integral denklemlerine uygulandı. 1960-1980 yıllarında matematikçiler Guido Weiss ve Ronald R. Coifman, "atoms" adı verilen bir fonksiyon uzayının en küçük elemanı üzerinde çalıştı. Amaç, sıradan bir fonksiyon için bu atomları bulmak ve bu atomları kullanarak fonksiyon uzayının tüm elemanlarını tekrar meydana getirecek

birleştirme kuralını ortaya koymaktı (ALIFAX & SCOTtA, 1997). Şekil 4. 6'da Haar Dalgacıđı yapısı gösterilmektedir.



Şekil 4.6: Haar Dalgacıđı yapısı

**Kaynak:** (Stanković & Falkowski, 2003)

1977'de Esteban ve Galand, yeni bir süzgeç kavramını ortaya attı ancak bu yöntemde, ana sinyalin yeniden elde edilmesi ile ilgili hata oranı çok yüksekti. Yukarıda tanımlanan  $\Psi(x)$ , 1909 yılında bu dalgacıđı bulan Macar matematikçi Alfred Haar onuruna Haar dalgacıđı olarak bilinmektedir. Haar dalgacıđı,  $X = 0, \frac{1}{2}, 1$  noktalarında süreksizdir (Stanković & Falkowski, 2003).

## 4.2 Görüntü Ön İşleme

Bu tez çalışmasında gerçekleştirilen tüm deneyler aşağıda belirtilen özellikteki bir bilgisayar üzerinde gerçekleştirildi. Yapılan çalışmada hız ve modülerlik göz önünde bulundurularak 13 TB veri yerine sadece 124.8 GB veri ile çalışılmıştır. Veri setinin %80 eğitim ve %10 test ve %10 doğrulama için denenmiştir. Bilgisayar konfigürasyonu MSI GT75 Titan 4K-071 GTX 1080 8G, 32GB 4TB SSD Windows 10 üzerinde işlem yapılarak eğitilmiştir. Programlama olarak da Python programlama dili hem görüntü işleme hem de MÖ uygulamaları için kitaplıklar açısından zengindir. Araştırmada Python dili için Anaconda'daki Jupyter notebook geliştirme ortamı ile gerçekleştirilmiştir. Doğrulama için 10 katlı çapraz doğrulama yaklaşımı kullanılmıştır.

- **Ön işlem:**


KAM veri seti birçok BT görüntüsünü içerdiğinden, DÖ algoritmaları için uygundur. Ayrıca veri seti, DÖ algoritmalarına uygun olarak çalışılmasını sağlamak için kendi içinde etiket barındırmaktadır. Bununla birlikte, veri setinde bazı hasta bilgilerine de (yaş, tarihçe, cinsiyet vb.) yer verilmiştir. ESA mimarisinde BT görüntü veri setini işlemek için ayar gerektiren birçok parametre bulunmaktadır. En önemli parametrelerden biri ise giriş tensor boyutudur. Parametrelerin birbiriyle uyumlu olması gerektiğinden, girdi boyutu modeldeki diğer tüm parametreleri değiştirir. Akciğer BT taramalarında nodülün boyutları 1 mm – 30 mm arasında değişiklik gösterir ve bu da giriş boyutu kararını daha fazla zorlaştırır. Bunun haricinde, performansın artması için karar füzyonunda farklı sonuçların kullanılıp kullanılmayacağını gösterilmesi gerekmektedir. Bu etkilerin doğru şekilde gözlemlenmesi için tüm giriş boyutlarına uygun olacak şekilde ince ayarlanmış bir ESA mimarisi tasarlanması oldukça önemlidir. Bu bölümde verilerin ön işlemden geçirilmesi, işlenmesi ve ESA modelinin parametreleri ile hiper parametrelerinin belirlenmesi konuları ayrıntılı olarak açıklanmaktadır. ESA model mimarisi oluşturulduktan sonra bu model üzerinde farklı giriş boyutları test edilir ve sonuçlar sunulur. BT görüntülerinde genellikle gürültü ve yapay (makine kaynaklı gerçekte var olmayan bölgeler) gibi etkenlerden dolayı cisim yoğunlukları değildir. Bundan dolayı görüntüye ön işlem yapılmıştır.

- **Veri ön işleme:**

Ağ mimarisi oluşturulmadan önce veri kümesindeki örnekler dikkatle incelenmiştir. ESA kullanılması planlandığından, örneklerin vokseller arasındaki mesafeleri vb. parametreler oldukça önemlidir. Eğitim kısmına bakıldığında ise sinir ağı sistemi girişinin boyutunun tüm BT görüntüleri için aynı olması gerektiği görülmektedir. Ancak giriş boyutları piksel cinsindeyken gerçek dünya boyutları mm cinsindedir. Aynı giriş boyutları farklı gerçek dünya boyutlarına karşılık geliyorsa, farklı hacimsel boyutlarda eğitilen mimarinin anlamlı sonuçlar vermesi beklenmemelidir. Örneğin, 20x20x20 piksel bir tarama için 24x24x16 mm'ye karşılık gelirken başka bir tarama için 18x18x20 mm'ye karşılık gelebilir. Bu durumu ele almak için tüm taramalarda vksel boşlukları incelenmiştir.

- **Histogram:**


Yoğunluğa ya da parlaklığa göre eşikleme (tresholding), katı nesnelere içeren görüntüler için basit bir tekniktir. Her piksel eşik değeri ile karşılaştırılır, eğer değer yüksek çıkarsa piksel ön plan olarak değerlendirilir ve rengi beyaz yapılır. Eğer düşük veya eşit çıkarsa piksel arka fon olarak değerlendirilir ve rengi siyah yapılır. Eşiklemenin başarısı eşik değerinin seçimine bağlıdır. Şekil 4. 7'de Histogram filtresi kullanımı gösterilmektedir.



**Şekil 4.7:** Histogram filtresi kullanımı

Şekil 4. 7'de ideal durumda gri seviyeli histogram, ön plan nesnelere ile arka fonu temsil eden ve çakışmayan iki farklı dağılımı gösterilmektedir. Eşik değeri, bu iki dağılım arasında kalan bölgeden seçilir. Eşik değeri genellikle görüntüye özel şekilde ve deneyimle seçilmektedir. Verinin normalize edilmesi ve normalize adımı, görüntünün gürültüden temizlenmesi için filtreden geçirilmesini içermektedir. Histogram, dijital bir görüntüde her bir renk değerinden kaç tane olduğunu gösteren bir grafikdir. Bu grafiğe bakarak görüntünün parlaklığı veya tonları hakkında bilgi alınabilir.

Şekil 4. 8'de her bir BT taramasına ayrı ayrı uygulanmış veri ön işleme adımları gösterilmektedir. Bu adımlar başlıca Histogram filtresi, Kenar belirleme ve Bulanıklaştırma olarak sıralanabilir.




**Şekil 4.8:** Her bir BT taramasına ayrı ayrı uygulanmış veri ön işleme adımı

Eşikleme değerinin seçimini zorlaştıran bazı durumlar bulunmaktadır. Örneğin, düşük görüntü kontrastlığı ön ve arka planın ayrıştırılmasını zorlaştırır. Arka planın değişik yoğunluklarda olması ise bütün görüntü için kullanılacak tek bir eşik seçimini imkansızlaştırabilir. Düşük uzamsal çözünürlük ve değişik parlaklık seviyelerindeki nesnelere de ayrı bir zorluk nedenidir.

- **Optimal eşikleme:**

Yoğunluk/parlaklığa göre eşikleme, katı nesnelere içeren görüntüler için basit bir tekniktir. Her piksel eşik değeri ile karşılaştırılır, eğer değeri yüksek ise piksel ön plan olarak değerlendirilir ve rengi beyaz yapılır. Eğer düşük veya eşit ise piksel arka fon olarak değerlendirilir ve rengi siyah yapılır. Eşiklemenin başarısı eşik değerinin seçimine bağlıdır. İdeal durumda, gri seviyeli histogram, ön plan nesnelere ve arka fonu temsil eden ve çakışmayan iki farklı dağılım içerir. Eşik değeri bu iki dağılımın arasındaki vadiden seçilir. Eşikleme değerinin seçimini

zorlaştıran bazı durumlar vardır. Düşük görüntü karışıklığı ön ve arka planın ayrıştırılmasını zorlaştırır. Arka planın değişik yoğunluklarda olması bütün görüntü için kullanılacak tek bir eşik seçimini imkansızlaştırabilir. Düşük uzamsal çözünürlük, değişik parlaklık seviyelerindeki nesnelere için ayrı bir zorluk nedenidir. Arka planı gürültülü olan BT görüntülerini düzeltmek için kullanılan basit bir uygulamadır. Gri seviyeli histogramda tepe noktaları arasında kalan alanın tabanı optimal eşik değildir. Optimal eşikleme görüntüsünün histogramı, iki veya daha fazla olasılık yoğunluğunun ağırlıklı toplamı olarak ele alınır. Şekil 4. 9'da Optimal Eşikleme görüntüsü gösterilmektedir.



**Şekil 4.9:** Optimal Eşikleme görüntüsü

Bu şekilde sınıflandırılmamış en düşük sayıda pikselden alınan gri seviye, eşik değeri olarak atanır. Bu seviye, iki normal dağılımın kesişim noktasına karşılık gelir. Şekil 4. 9 (a)'da iki normal dağılımın kesişiminin optimal eşiği, Şekil 4. 9 (b)'de ise optimal ve geleneksel histogramın sonuçları yer almaktadır. Gürültü piksellerin yanlış sınıflandırılması ihtimaline karşılık, eşikleme öncesi ortalama veya median filtreleme yapılır. Optimal eşikleme için kullanılacak birçok yöntem vardır. Genel yaklaşımda pikseller arka fon pikselleri ve ön plan pikselleri olarak iki sınıfa veya kümeye ait olarak düşünülür. Amaç, bir eşik değeri seçerek eşik değerinin her iki tarafındaki piksellerin kendi taraflarındaki piksel ortalama değerlerine yakın olmasını sağlamaktır. Şekil 4. 9'da Optimum eşikleme görüntüsünün histogramı, iki veya daha fazla olasılık yoğunluğunun ağırlıklı toplamı olarak ele alınır. Bu şekilde sınıflandırılmayan en düşük piksel sayısından



alınan gri seviyesi, eşik değeri olarak atanır. Bu seviye, iki normal dağılımın kesişimine karşılık gelir.

**Otsu yöntemi:** Görüntüye ait gri seviyeli histogramı, olasılık dağılımı olarak ele alır.

**Maksimum entropi eşikleme:** Sınıflar arasındaki entropi (belirsizlik ölçüsü) yüksek tutularak Otsu yöntemine benzer bir yöntem kullanılır.


**Yinelemeli veri analizi tekniği algoritması (Iterative self-organizing data analysis technique algorithm):** Kmeans kümeleme algoritmasına benzer bir yöntem, iki küme için uygulanır. Yinelemeli veri analizi tekniği algoritması (ISODATA) her iki tepe noktasına ait piksel ortalaması ile görüntü eşiklenir. Eşiğin altı ve üstü için alınan ortalama ile yeni bir eşik belirlenir ve aynı işleme devam edilir.

**Eşikleme:** Görüntü sınıflamanın eski, basit ve popüler tekniklerinden biridir. Şekil 4.10'da ise histogram analizi ile ilişkili, ESA'ya dayalı bir görüntü eşikleme yaklaşımı sunulmaktadır.



**Şekil 4.10:** Normal (sağlıklı) eşikleme sonrası

Gerçek görüntüler üzerindeki deneysel sonuçlar, önerilen yaklaşımın nesnelere arka plandaki diğer yöntemlere göre daha iyi bir görsel kalite sunarak etkili bir şekilde çıkarabileceğini göstermektedir. Şekil 4. 11'de Kanserli görüntü eşikleme sonrası gösterilmektedir.




**Şekil 4.11:** Kanserli görüntü eşikleme sonrası

Çoklu Eşikleme ve Sınıflama: Birden çok sınıfın olduğu ve birden çok eşik değerinin istendiği, genellikle aynı sahneye ait birden çok görüntünün bulunduğu durumlarda kullanılır. Parlaklık, desen ve gradyan gibi çoklu özelliklerin kullanımına açıktır. Ortaya çıkan sınıflar, renklerle ayrıştırılabilir. Gelişmiş Otsu Yöntemi burada uygulanabilir.

- **Kenar belirleme ve bağlantı kurmak:**

Görüntü içindeki kenarlar, Sobel Operatörü gibi gradyan operatörler kullanılarak ve görüntünün gradyan değerleri eşiklenerek belirlenir. Belirgin olan kenarlar kesintisiz görünürken zayıf olanlar kırık çizgiler halinde görünür. Gürültülü görüntüler, Şekil 4.12 (a)'da görüldüğü gibi, aslında olmayan kenarların ortaya çıkmasına neden olmaktadır. Gürültülü görüntüler yumuşatılarak yanlış kenarlar azaltılır ancak bu durumda da Şekil 4.12 (b)'de görüldüğü gibi zayıf kenarlar tamamen ortadan kaybolur ve diğer kenarlar genişler. Gürültülü damar görüntüsü Butterworth filtresi kullanılarak düzleştirilirse, Şekil 4.12 (b)'de yer alan görüntüye ulaşılır.




**Şekil 4.12:** Normal (sağlıklı) kenarlar görüntüsü

Kenar bulma, bir görüntüdeki kenarların büyüklüğünü ve yönünü ölçmek amacıyla, bir görüntü gradyanının hesaplanmasını içeren temel bir görüntü işleme tekniğidir. Görüntü gradyanları; çizgi algılama, özellik algılama ve görüntü sınıflandırma gibi, bilgisayarla görmedeki çeşitli aşağı akış görevlerinde kullanılır. Önerilen ESA tekniği, momentum özelliklerinin çıkarılmasından yararlanan kenar algılama görevini gerçekleştirmek için kullanılır. Kenar bulma sayesinde modelimiz görüntüyü daha net algılar bu da nodülün daha kolay anlaşılmasını sağlar. Hata oranını en aza indirir. Model ne kadar farklı görüntü veya görüntünün farklı varyasyonlarını tanırsa öğrenme o denli başarılı olur. Şekil 4. 13'te Kanserli BT Görüntü kenarları gösterilmektedir.



**Şekil 4.13:** Kanserli BT Görüntü kenarları gösterimi

Herhangi bir boyuttaki herhangi bir BT girdi görüntüsünü daha fazla eğitim gerektirmeden işleyebilir. 4.13'te görüntüler üzerindeki kenar algılamanın görüntü işleme için çok önemli olduğu görülmektedir. Kenar tespiti yapıp kenarlar arasında bağlantı kurularak sınırların ortaya çıkarılması gerekmektedir. Bitişik kenarlara ait piksellerinin benzer nitelikleri varsa, bunlar birbirine bağlanmalıdır. Sınırlar, bağlantı kurulduktan sonra ortaya çıkar.



**Şekil 4.14:** BT görüntüsünde kenar belirleme

Kenarlar arası bağlantı işleminin devamında, içleri sonradan doldurulacak olan küçük boşluklarla arası açılan piksel kümelerinin bulunması işlemi yapılır. Seçilen


nokta, İA'dır. Her görüntü bu noktayı alır ve piksel değeri yüksek olan kenarlık tarafını bu pikselin düşük değerine çevirir. Öznitelik çıkarma tekniğindeki asıl amaç, görüntüyü kompakt ve benzersiz tek bir değere veya matris vektörü biçimine sokmaktır. Öznitelik çıkarma; sınıflandırma için hangi görüntünün kullanılabilmesine bağlı olarak, görüntü işlemedeki boyutsal küçülmeyi hesaplar. Giriş verilerinin temsili özelliklerinin azaltılmasını içerir. Öznitelik çıkarım işlemi ADD yöntemi ile gerçekleştirilir.

**Gri seviyeli görüntü:** Gri seviyeli görüntü türünde yalnızca farklı gri seviyeli görüntü değerleri bulunmaktadır. Gri renk değer aralıkları  $G = (Gaber et al., 2017..... 255)$  şeklinde ifade edilir. Bilgisayarda en düşük veri depolaması "byte" olarak yapılır ve 1 byte 8 bite eşittir. Şekil 4. 15'te Sağlıklı greyskale görüntü gösterilmektedir.



**Şekil 4.15:** Sağlıklı greyskale görüntü gösterimi

Yani bir karakter 8 bit olarak temsil edilir. Bir gri seviyeli görüntüde 256 adet farklı gri renk tonu bulunabilir. Bu şekildeki bir gösterimde 0 gri değeri kural olarak siyah renge, 255 gri değeri ise beyaz renge karşılık gelir. 0-255 değerleri arasındaki renkler ise gri renk seviyeleri oluşmaktadır. Bununla birlikte, solunum döngüsü sırasında alınan ve solunan hava bakımından BT yoğunluğundaki değişiklik dikkate alındığında, farklı şişirme seviyelerinde elde edilen iki BT görüntüsündeki gri tonlama aralığının akciğer bölgesi içinde farklılık gösterdiği görülmektedir.




**Şekil 4.16:** Kanserli greyskale görüntü gösterimi

Bu gri tonlama aralığı farkını dengelemek için yoğunluk normalizasyonu yapılmalıdır. Gri tonlamalı görüntüde her bir piksel değeri, yalnızca yoğunluğu taşıyan tek bir dereceye dönüşür. Gürültüsüz gri tonlamalı görüntü, pikselleri 0'lar (beyaz) ve 1'ler (gri tonlamalı) içeren bir görüntüye dönüştürür (Bkz. Şekil 4.16).

**Negatif görüntü:** BT görüntüleri gri skala değerindeki görüntülerdir. Gri tonlamalı görüntü, her pikselin yalnızca tek bir temsili ışık miktarının olduğu ve her pikselin 8 bit (0-255) olduğu bir görüntüdür. Herhangi bir zamanda gri görüntülerde görüntülenebilecek maksimum renk sayısı 256'dır. Akciğer BT görüntüleri karakteristik olarak net değildir; bu nedenle görüntü işlemede daha iyi performans elde edebilmek için gri tonlamalı görüntüyü negatif görüntüye çevirmek gerekir.


$$\text{PixelDeger}[x,y] = 255 - \text{PixelDeger}[x,y] \quad (4.13)$$

Denklem 4.13'te "x" sütun sayısını, "y" ise satır sayısını temsil eder. Şekil 4.17'de gösterilen, BT gri skala görüntüsünün negatifi.



**Şekil 4.17:** a) BT hastalıklı görüntüsünün negatifi b) Sağlıklı görüntüsünün negatifi

**Gauss Bulanıklığı:** BT görüntülerinde ortaya çıkan zayıflıkları ve kör bölgeleri düzeltmek için Gauss filtreleri kullanılır. Diğer bir deyişle, BT görüntülerinin tüm gürültüsünü azaltmak için her BT görüntüsünde Gauss bulanıklığı uygulanmalıdır (Bkz. Şekil 4.18). Bu işlem yapıldıktan sonra BT görüntüleri aynı özelliğe sahip olur. BT görüntüleri bulanıklaştırma tekniğinden etkilendiği zaman, görüntüdeki küçük bileşenlerin görselleştirilmesi ve görünürlüğü azalır. Gauss Bulanıklığı, tüm kısımları bulanıklaştırmak yerine sadece belli bölgeleri bulanıklaştırdığından, tercih edilen bir filtre türüdür.



**Şekil 4.18:** BT görüntülerine Gauss bulanıklığı uygulaması

Özellikle standart sapma yüksek olduğunda iyi sonuçlar doğurur. Bununla birlikte, yüksek standart sapma uygulamak sınıflama için her zaman iyi değildir çünkü bu durum yüksek bulanıklık etkisini de bulanıklaştırabilir ve İA bölgesi olan tümörü uzaklaştırarak düşük doğruluk seviyesine sahip bir sistemin ortaya çıkmasına yol açabilir. Bu nedenle, görüntünün bozulmamış biçimini bozulmuş sürümünden geri kazanmak ve görüntüye keskinlik vermek için Gauss bulanıklığı elzemdir.

$$G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (4.14)$$

$$\text{Sigma}(\sigma) = 0.3x((\text{kernelsize} - 1)x0.5 - 1) + 0.8$$

Denklem 4.14'te "x" sütun sayısını, "y" ise çekirdekdeki satır sayısını temsil eder.

**Ortalama filtresi:** Ortalama Filtresi, görüntüleri yumuşatmak için kullanılan basit ve uygulaması kolay bir yöntemdir. Bu sayede, bir piksel ile diğerleri arasındaki değişim miktarını azaltır. Diğer bir deyişle, bu filtre görüntülerdeki gürültüyü azaltmanın bir yoludur. Bir görüntünün her bir piksel değerini komşularının ve




kendisinin de dahil olduğu bir ortalama değer ile değiştirmektedir. Bu durum, çevresindekileri temsil etmeyen piksel değerlerinin ortadan kalkmasını sağlar. Ortalama Filtresi aynı zamanda bir evrişim filtresidir; çekirdek şablon (kernel) temeline dayanır. Büyük şablonun tek bir taramadaki etkisine benzer türde bir etkinin, küçük şablonun birden fazla geçişi ile sağlanması mümkündür. Görüntü ve sinyal işleme adımlarında gürültü temizlemek için kullanılan Ortalama Filtresinin amacı, belirli bir pencere aralığındaki sayıların ortancasını (median) almak ve bu sayede aşırı büyük atlamaları ortadan kaldırmaktır. Yani, filtre uygulandıktan sonra resimde bulunan ve konumlarından belirgin şekilde ayrılmış olan piksellerin tespit edilerek temizlenmesi sağlanır. Aynı zamanda Ortanca Filtre olarak da bilinen Ortalama Filtre ile bir grup sayı dizisinden veya bir matris içerisinde ortalama değerler seçilir ve diğerleri elenir. Böylelikle büyük farklılıklar temizlenmiş olur. Hareketli Ortalama filtresinin aksine bu filtre lineer değildir. Genellikle görüntü işlemek için kullanılır.

Ortanca Filtresi, bir maske içindeki tüm vektörlerin büyüklüğü alınarak ve büyüklüklerine göre sıralanarak gerçekleştirilir. Bir pencereyi bir görüntü üzerinde hareket ettirmeye ve giriş penceresindeki parlaklığın medyan değeri olarak çıktı pikselini hesaplamaya dayanır. Basit Medyan Filtresi, bir görüntünün ortalaması yerine verilerin medyanı alındığından, Ortalama filtresine göre bir avantaja sahiptir. Medyan büyüklüğe sahip piksel daha sonra incelenen pikselin yerini almak için kullanılır. Bir setin medyanı, gürültünün varlığına göre daha sağlamdır. Ortanca Filtresi Denklem 4.15'te görüldüğü gibidir.


$$\text{Filtre}(X_1 \dots \dots X_n) = \text{Median}(|X_1|^2 \dots \dots \dots |X_n|^2) \quad (4.15)$$

Denklem 4.15'te, ön işlem aşamasındaki BT görüntüleri için çok önemli bir adım olan ortalama filtrelerin performansı karşılaştırılmış ve uyarlanabilir medyan filtresinin BT görüntüleri için en uygun filtre olduğu kanıtlanmıştır. Eşikleme tabanlı yöntemler vasıtasıyla görüntü zayıflama değerlerine dayalı ikili bölümler oluşturulup görüntü bölümlere ayrılabilir. Şekil 4.19'da BT görüntüsünden akciğer çıkarımı gösterilmektedir.



**Şekil 4.19:** BT görüntüsünden akciğer çıkarımı (maske uygulaması)

Akciğer maskesi çıkarımı prosedürü Şekil 4.19'da gösterilmektedir. Akciğer BT görüntüsünden İA çıkarmak için öncelikle eşikleme yöntemi kullanılarak vücut kısmı görüntüden çıkarılır. Daha sonra BT görüntüsünün vücut maskesi verilir ve akciğer maskesi üretilir. Ayrıca gürültüye karşı hassastır. Bununla birlikte, benzer kısımlarda da patolojik bölgelerin zayıflama değerleri bulunabilir. Ortaya çıkan bölütlemeyi düzeltmek için ek morfolojik operasyonlar benimsenir. Akciğerden düşük yoğunluklu gürültülü bölgelerin filtrelenmesi için bağlı bileşen etiketleme uygulanır. Akciğer bölümündeki gürültülü noktaların giderilmesi için dilatasyon yöntemine başvurulur. Daha sonra dilatasyonun sebep olduğu sınır yanlışlığının ayarlanması için erozyon yöntemi uygulanır. Şekil 4.20'de morfolojik operasyonların bir hali gösterilmektedir.



**Şekil 4.20:** Watershed uygulaması

BT taramaları, farklı ayarlara sahip olan makineler tarafından alınır. Görüntü farklı şekilde kalibre edilir. Taramalar, ESA için sorun yaratabilecek düzeyde farklı voksel aralıklarına sahiptir. Tüm BT taramaları enterpolasyon yoluyla bir izotropik çözünürlüğe yeniden ölçeklendirilir; böylece her vokselin boyutu 1 mm x 1mm x 1 mm hacmi temsil eder. Tüm modeller için eğitim ve test örnekleri yeniden ölçeklendirilmiş olan BT taramalarından üretilir.



Watershed algoritması, otomatik bir bölütleme yöntemidir. Daha az örtüşen düz dışbükey nesnelere daha iyi çalışır. Üst üste çakışmanın az olduğu, düz dışbükey nesnelere daha iyi sonuç verir. Gri tonlamalı görüntü, son ikili görüntüde dokunmayan nesnelere yaratmaya yetecek kadar yüksek bir değerle eşleştirilir. Mesafe dönüşümü, yüksekliği temsil eden gri seviyeyi içeren üç boyutlu bir görüntü olarak düşünülebilir. Eşiklenme, topografik yüzeyde orijinal nesnelere belirli bir seviyede ayıran ve uzaklık dönüşümünde zirvelere haline getiren bir taşkın olarak düşünülebilir. Gri tonlamalı görüntü, piksel değerlerinin yükseklik olarak kabul edildiği topografik yüzey olarak düşünülebilir. Birbirine yakın nesnelere ayırmak için havza algoritması doğrudan bu görüntüye uygulanabilir. Tepeleri bir vadiye çevirmek için önce topografik yüzey tamamlanır. Yüzeyin bölgesel minimumlarla delindiği ve alanın su ile dolu olduğu varsayılmıştır. Su havzaları doldurmaya başlar ve bitişik havzalardaki suların karışmaması için setler yapılır. Yüzey tamamen su ile dolduğunda, setler iki nehir havzası arasında setler oluşturarak sınırları çizer ve görüntüyü istenen bölgelere böler. Şekil 4.20'de görüldüğü gibi, üst üste binen nesnelere içeren ikili bir görüntüye uygulanan havza dönüşümünden sonra, bölgeleri ayıran havza çizgileri ortaya çıkmaktadır. Çizelge 4. 3'te Watershed uygulanırken uyulması gereken kurallar gösterilmektedir.

**Çizelge 4.3:** Watershed yapılırken uyulması gereken kurallar

- 
- Merkez voksel akciğere yerleşir.
  - Merkez vokselin Hounsfield ünitesi 100'ün üzerindedir.
  - Merkez vokselin etrafında 5 x 5 x 5 boyutunda bir kutunun minimum Hounsfield ünitesi 0'ın üzerindedir.
- 

Bazı durumlarda ön işlem yapılmadıysa BT görüntü eğitim seti oldukça dengesiz olabilmektedir. Veri kümesi, alt örnek olan negatif örnekler ile dengelenir ve pozitif örnekler çoğaltılır. Büyütme, 3B kaydırma ile 3B dönüşüm birleşimidir. Büyütme işleminde yakınlaştırma ve uzaklaştırma yapılmaz çünkü nodüllerin boyutları önemli bilgiler içerir. Benzer şekilde, 3D dönüşlerin açıları sınırlandırılır çünkü hava yollarına ve damarlara oranla yüksek zayıflamaların göreceli konumları, bunun bir nodül olup olmadığını gösterir.

Otsu Eşiği: Otsu yöntemi, genel bir eşikleme tekniğidir ve eşik arama işlemi için görüntünün histogramını kullanır. Bu çalışmada belirli bir eşik değeri altında olan kısımlar 0, üstünde kalanlar 1 olacak şekilde ikili eşik (binary thresholding) yöntemi kullanılmıştır fakat sürekli değişen durumlar göz önüne alındığında DICOM

görüntülerinde manuel olan bu sistem yeterince iyi sonuç vermediği için yerine Otsu Eşiği yöntemi tercih edilmiştir. Otsu yöntemi, gri seviye görüntüler üzerinde uygulanabilen bir eşik tespit yöntemidir. Eğer görüntüler RGB formatlı ise, bu görüntüler gri seviyeye dönüştürülür. Bu yöntem denenirken, görüntünün arka plan ve ön plan olacak şekilde iki renk sınıfından oluştuğu varsayılır. Daha sonra tüm eşik değerleri için bu iki renk sınıfına ait sınıf içi varyans değeri hesaplanır. Bu değer en küçük olmasını sağlayan eşik değeri, optimum eşik değeridir. Otsu eşiği algoritması, bu ilişki vasıtasıyla ağırlıklı sınıf için varyansı en aza indiren bir eşik değeri (t) bulur.


$$a_{\omega}^2(t) = q_1(t)a_1^2(t) + q_2(t)a_2^2(t) \quad (4.16)$$

Burada:

$$q_1(t) = \sum_{i=1}^t p(i)$$

$$q_2(t) = \sum_{i=t+1}^I p(i)$$


Denklem 4.16'da gösterildiği eşikleme, mevcut görüntüleri bir görüntünün daha basit formuna dönüştürür ve böylece akciğer nodülü algılanır (Bkz. Şekil 4.21).



**Şekil 4.21:** a) Otsu eşiği uygulaması (b) Tamamlanmış BT görüntüsü

Görüntü Bölütleme: Bölütleme, görüntüyü oluşturan bölge ve nesnelere alt bölümlere ayırmaya yarar. Gerçekleştirilen alt bölümler için detay seviyesinin çözülecek probleme bağımlı olduğu bilinmektedir. Yani, uygulamaya bağlı olarak görüntüde İA bölgeleri ya da nesnelere algılandığında bölütleme sonlandırılabilir. Örneğin; görüntü içerisinde benzer parlaklıklar mevcut olabilir ve bu parlaklıklar,

İlgili görüntünün farklı bölgelerinde bulunan nesnelere temsil edebilir. Karmaşıklık içeren bir görüntünün bölütlenmesi, görüntü işlemedeki en zor işlemlerden biridir. Bölütleme işlemi ne kadar doğru biçimde çalışırsa, modelin başarı oranı da o kadar yükselmektedir. Bu sebeple, bölütleme işlemlerindeki doğruluk oranlarını olabildiğince yüksek tutmak gerekmektedir. Şekil 4. 22’de Görüntünün bölünmesi gösterimi yapılmaktadır.




**Şekil 4.22:** Görüntünün bölünmesi gösterimi

Burada bilinmesi gereken en önemli husus, tüm görüntülere uygulanabilecek genel (üniversal) bir bölütleme yönteminin bulunmadığı ve hiçbir bölütleme yönteminin mükemmel olmadığıdır. Başka bir ifadeyle; görüntü iyileştirme ve onarma problemlerinde olduğu gibi, görüntü bölütleme için tasarlanan yöntemler ve bu yöntemlerin başarıları görüntüye ve uygulamaya bağlı olarak değişiklik gösterebilir. Bölütleme algoritması, görüntüdeki gri seviye değerinin iki ana özelliğini temel alır: Benzerlik ve süreksizlik. Süreksizlik, görüntü içerisinde kendini gri seviye değerinde normal olmayan (Ör.: nesne kenarı vb.) değişiklik şeklinde gösterir. Benzerliğin temelinde ise görüntü içerisindeki gri seviye değerlerinin birbirine benzeyen kısımlarını bölgelere ayırma mantığı yatar. Eşikleme, bölge büyütme, bölge bölme, istatistiksel sınıflandırma, kenar algılama, bölge algılama ve watershed bu kategoriye örnek metotlardır (Al-Tarawneh, 2012). Tez çalışmasında, bu metotlar arasından bölge büyütme ve istatistiksel bölge birleştirme yöntemleri ayrı ayrı ve birlikte kullanılarak bölütleme işlemi yapılmıştır. Modele aynı BT veri setinden farklı görüntüler öğretmek başarı oranını yükseltir.

**Görüntünün Çevrilmesi:** BT görüntüleri, bölündükten sonra görüntü daha iyi anlaşılabilir diye, sağ ve sol olmak üzere çevrilir. Bu işlem için gereken denklem aşağıdaki gibidir:

$$\text{PixelDeger}[x, y] = \text{PixelDeger}[x, \text{sütun} - y - 1] \quad (4.17)$$

Denklem 4.17’de piksel deęerlerin hesaplanması gsterilmektedir. Satır ve stunların hesaplanmasıyla piksel deęerleri bulunmaktadı. (Bkz: Őekil 4.23)



**Őekil 4.23:** Grntnn evrilmesi

Őekil 4.23’te grndđ gibi grnt evrilmesindeki ama modelin grntnn her halini grp tanınması ve bu Őekilde đrenmenin gerekleŐmesini sađlamaktır. Model ne kadar farklı varyasyon đrenirse o kadar baŐarılı olur.

## 5. UYGULAMA VE ANALİZ

Bir YSA eğitilirken; katman sayısı, gizli birim sayısı, öğrenme oranı ve aktivasyon fonksiyonu gibi parametreler hususunda karar verilmesi gerekmektedir. Bu parametrelerde kullanılacak olan farklı değerlerin sağlayacağı başarımları önceden tahmin etmek oldukça güçtür. Bu sebeple de MÖ uygulaması yinelemeli bir süreçten ibarettir. Söz konusu süreç genellikle hedef problemi çözebilmek için gerekli katman sayısı, gizli birim sayısı ve üzerinde çalışılacak olan veri setleri gibi hususlarda bir fikir oluşturulması ile başlamaktadır. Oluşturulan fikir daha sonra kodlanarak denenmektedir. Kodun çalıştırılması ile belirlenen ağ ve konfigürasyonların başarımları gözlemlenmektedir. Bu gözlem neticesinde performansın değerlendirilmesi ile fikir gözden geçirilmekte, yeni konfigürasyon değerleri ve eniyileme parametrelerinin oluşturulmasıyla da süreç tekrarlanmaktadır.

Bu çalışma kapsamında, sınıflandırma yaklaşımları için dört adet geleneksel ve bir adet de yenilikçi DÖ tekniği kullanılmıştır. Ayrıca her teknik kendi içerisinde farklı konfigürasyon ve parametreler ile kurgulanmış ve bunlara ilişkin yapılar kurularak eğitilmiştir.

Temel bileşen analizi (TBA); örüntü tanıma, bilgisayarla görme ve sinyal işleme alanlarında yaygın olarak kullanılan özellik çıkarma ve veri gösterimi tekniği için klasik bir boyut azaltma yöntemi olarak tanımlanmaktadır. TBA sonucunda ortaya çıkan özdeğer ve özvektör bileşenleri, ana eksenlere olan varyanslarına göre sıralanmakta ve içlerinden en az biri, en çok katkı sağlayanlar arasında yer almaktadır. Çok boyutlu veri setleri, kurulan bir sistemi girdi olarak beslemek için genelde fazlasıyla karmaşık olmaları sebebiyle yük getirici özellikte olabilirler. Bu veri setlerinin boyutları, TBA kullanılarak etkinliğinden önemli bir kayıp vermeden ikiye indirgenebilmektedir. Dolayısıyla TBA; geniş bir değişken kümesini, bu kümedeki bilginin çoğunu kapsayan daha küçük bir küme haline getirmede kullanılan bir boyut indirgeme yöntemidir. TBA ile orijinal sayıdaki

değişkenin varyans yapısını, değişkenlerin doğrusal bileşenleri olan daha az sayıdaki yeni değişkenlerle ifade etmek hedeflenmektedir.

Değişken sayısı  $p > 1$  olarak kabul edildiğinde,  $\mathbf{X}' = [X_1 X_2 \dots X_p]$  şeklinde değişkenler vektörü verilmektedir.  $E(\mathbf{X}) = \boldsymbol{\mu}$  ve  $Cov(\mathbf{X}) = \boldsymbol{\Sigma}$  olduğu kabul edilmektedir.  $\boldsymbol{\mu}$  ve  $\boldsymbol{\Sigma}$ ,  $\mathbf{X}$ ; değişkenler vektörünün temsil ettiği kitlenin parametreleri olmaları sebebiyle çoğunlukla bilinmemektedirler. Böyle bir durumda, mümkün olan en fazla olabilirlik tahmin yönteminin kullanılmasıyla örneklemden tahmin yürütülmeye çalışılmaktadır. Bu sebeple;  $n$  birimlik rastgele bir örnek, ilgili kitleden çekilmektedir. Örnek birimleri  $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$  gözlem vektörleri olmak üzere;  $\boldsymbol{\mu}$  parametresinin en çok olabilirlik tahmin edicisi  $\mathbf{X} = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_i$  örnek ortalama vektörü iken  $\boldsymbol{\Sigma}$  parametresinin en çok olabilirlik tahmin edicisi  $\mathbf{S} = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{X}_i - \mathbf{X})(\mathbf{X}_i - \mathbf{X})'$  örnek varyans-kovaryans matrisidir. Burada  $i$ -nci gözlem vektörü  $\mathbf{X}_i' = [X_{1i} X_{2i} \dots X_{pi}]$ ,  $i = 1, n$  olup,  $p$ -boyutlu uzayda bir nokta vasıtasıyla temsil edilmesi mümkündür. Eğer bütün gözlemler  $p$  boyutlu uzayda noktalar yoluyla temsil edilirse ortaya bir küme (bulut) çıkacaktır. Çizelge 5.1'de, özellikle çok boyutlu verilerin veri boyutunu indirebilmek amacıyla başvurulan bir yöntem olması sebebiyle popülerliğini korumakta olan TBA'nın temel amaçları listelenmiştir.

#### **Çizelge 5.1:** Temel Bileşen Analizi temel amaçları

- 
- Verilerin boyutunu azaltmak
  - Tahminleme yapmak
  - Veri setini bazı analizler için görüntülemek
- 

Genel olarak bakıldığında TBA; çok değişkenli istatistiksel analiz teknikleri, tane değişkenleri ya da bu değişkenlerin üzerinde ölçülen tane birimi (bireysel veya nesne) ile ilgilenmektedir. Dolayısıyla bu teknik, ölçümlerden elde edilmiş olan veri yapılarını incelemektedir.

### **5.1 Geleneksel Derin Öğrenme Algoritmalarının Uygulanması**

ESA, BT görüntülerine bir dizi öğrenilebilir filtre uygulamaktadır. ESA'da evrişim katmanı, filtre boyutu, uygulanan filtre sayısı ve evreler ile tanımlanabilmektedir. Evrişimli bir katmanın girişi ve çıkışı, BT görüntüleri ile başlayan üç boyutlu (genişlik, yükseklik, derinlik) bir yapıya sahiptir. Evrişim

katmanları derlenirken çıkışın genişliği ve yüksekliği maksimum havuzlama işlemine dayalı olarak yapılmaktadır. Derinlik ise daha fazla veya daha az filtre kullanılarak elde edilmektedir.


İlk bölümde geleneksel metotlar arasında yer alan ve hazır kütüphaneler olarak kullanılan ResNet50, Inception v3, AlexNet ve VGG16 yöntemlerinden yararlanılmıştır.

### **5.1.1 ResNet50 Ağı**

ResNet50'de, yenilikçi bir mimariden ziyade çok çeşitli sınıflandırma görevlerini kullanarak mükemmel sonuçlar gösterebilen, halihazırda var olan ESA mimarisinden yararlanılmıştır. ResNet50 adı verilen yapıda toplam 50 katmana sahip bir artık sinir ağı varyantı kullanılmaktadır. Artık ağların, iyi bir performans ve parametre sayısı kombinasyonu sağlamaları sebebiyle model daha hızlı eğitilmektedir. Artık ağ mimarisi ayrıca eğitildikleri boyuttan farklı boyutlara sahip olan görüntüleri de besleyebilme yeteneğine sahiptir. ResNet50 ağı için önerilen sistem, aynı BT taramalarına sahip vakaların oluşturduğu bir veri üzerinden oluşturulmuştur.

Resnet50 model eğitimi iki aşamadan oluşmaktadır. Birinci aşamada; BT görüntüleri KAM veri kümesinde  $224 \times 224 \times 3$  olarak boyutlandırılarak, daha sonra  $128 \times 128 \times 3$ ,  $224 \times 224 \times 3$  ve  $299 \times 299 \times 3$  olarak yeniden ölçeklendirilmektedir. Farklı eğitim aşamalarında farklı boyutlar kullanılmaktadır. Bir BT veri seti için ImageNet ağırlıkları 5 Epok boyunca öğrenme hızı  $1e-3$  olacak şekilde ayarlanmaktadır. İkinci aşamada; tüm ağ daha önce olduğu gibi, ayırt edici bir öğrenme oranıyla 5 Epok için daha da ince ayarlamalara tabi tutulmaktadır. Daha sonra, tüm ağ 40 Epok için  $229 \times 229 \times 3$  boyutunda girdi görüntüleriyle daha da ince hale getirilmektedir. Bu durumda, ilk katmanın  $1e-6$  öğrenme oranıyla son katmanınsa  $1e-4$  öğrenme oranıyla eğitildiği öğrenme oranları kullanılmaktadır.

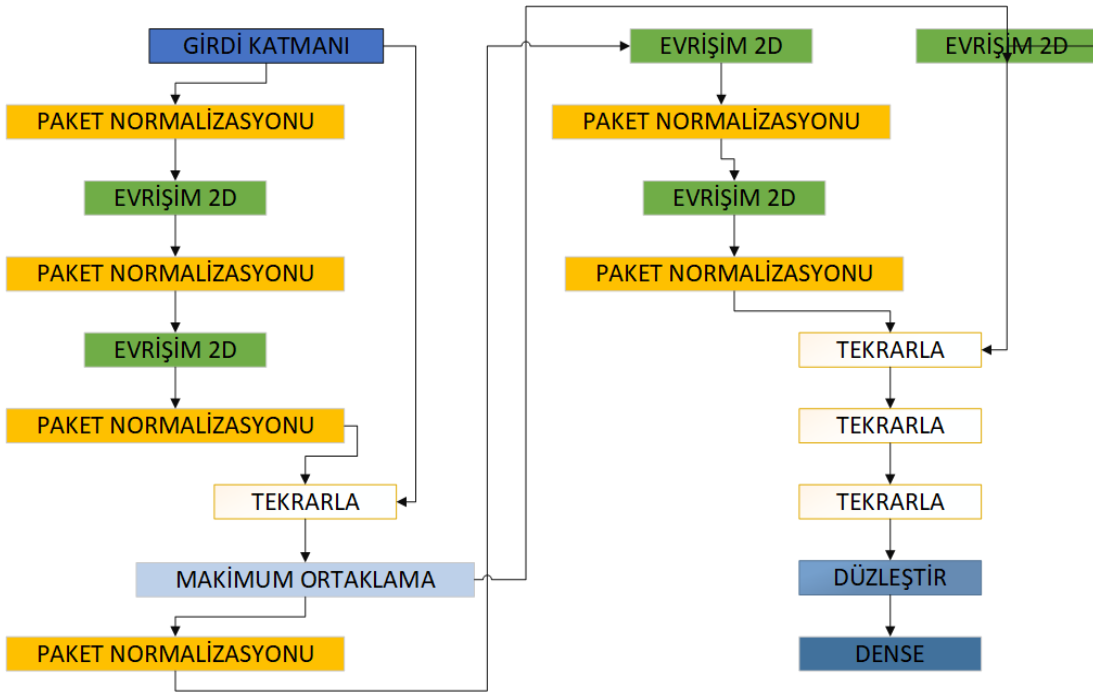
Şekil 5.1'de, ResNet50 kullanılarak bulunan en iyi dört ağ mimarisi sonucu gösterilmektedir.



**Şekil 5.1:** ResNet50 ile elde edilmiş en iyi sonuçlar

Özetle ResNet50 modelinde 50 Epok, 0.001 öğrenme katsayısı ve Adam optimizasyonu kullanılmıştır. ResNet50'de kullanılan ağırlıklar ImageNet veri seti ile önceden eğitilmiştir; bu sayede modelin tekrar eğitilmesi gerekmemiş ve zaman kaybı önlenmiştir.

Şekil 5.1'de de görüldüğü üzere; BT görüntüleri üzerindeki kırmızı ile işaretlenmiş yerler malignite, mavi ile işaretlenmiş yerler benign ve işaret olmayan yerler ise sağlıklı akciğer anlamına gelmektedir. Aşağıda verilen Şekil 5.2'de uygulanan ResNet50 mimarisi gösterilmektedir.



**Şekil 5.2:** Uygulanan ResNet50 mimarisi

Şekil 5.2'de de görüldüğü üzere; ÖA için eğitilen modelin bazı parametreleri (maksimum havuzlama, paket normalizasyonu) değiştirilip model KAM veri setine uyarlanarak; öncelikle BT veri setinin, paket normalizasyonuna tabi tutulmuş, daha sonra evrişim 2D katmanı ve bu adımların tekrarından oluşan bir seriden geçirilmiş, son olarak da düzleştirme uygulanmıştır. Böylece 34



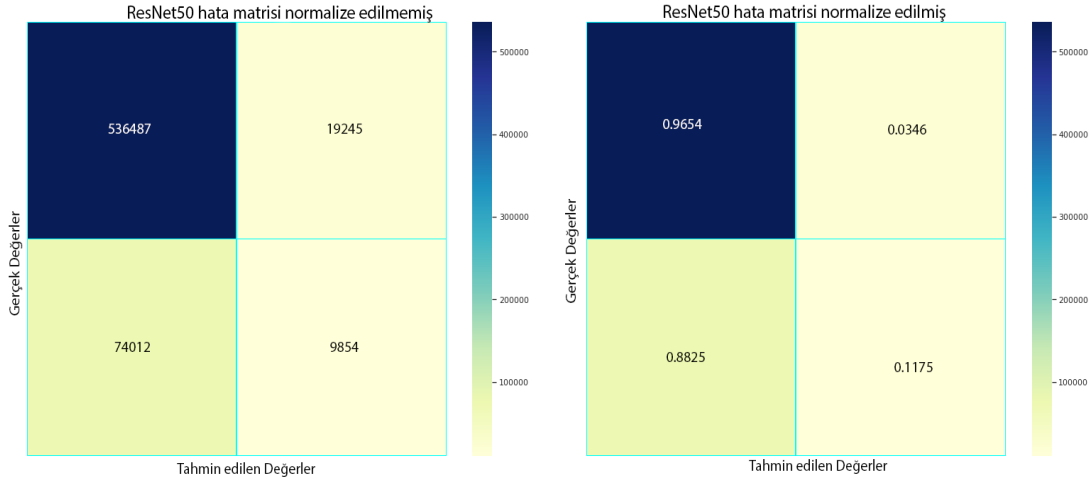
katmanlı ağdaki her 2 katmanlı bloğu 3 katmanlı “bottleneck” bloğu ile değiştirerek 50 katmanlı bir ResNet elde edilmiştir. Boyutları arttırmak için tekrarlar seçeneği kullanılmıştır. Ayrıca, 0.1'lik başlangıç öğrenme oranı ile başlamak için biraz fazla büyük bir değer olarak görülebileceği için eğitim hatası %95'in altına düşene kadar (yaklaşık 500 epok) farklı öğrenme oranları denenerek özellikle 0,01, 0.001 ve 0.0001 şeklinde denemeler yapılmıştır. Aşamalı yeniden boyutlandırma kullanan ResNet50 modeli, farklı girdi görüntüsü boyutlarıyla birden çok eğitim aşamasında daha iyi bir sınıflandırma yapma eğilimi göstermektedir. Bu, aynı zamanda bir girdi görüntü boyutundan diğerine aktarım yapmayı öğrenmenin bir yoludur. Dikkat edilmesi gereken husus, eğitimin sonraki aşamalarına geçerken öğrenme oranlarında düşüş sağlanmış olmasıdır. Bu durum, ağırlıkların bir aşamadan sonraki aşamaya kadar çok fazla değiştirilmediğini göstermektedir.

Çizelge 5.2’de ResNet50 ağının toplam doğrulama sayısı ve modelin doğruluğu gösterilmektedir.

**Çizelge 5.2:** ResNet50 model Sonuçları


Doğrulama	MCC	F2 skoru	Doğruluk	Özgüllük	Hassasiyet	F1
Kat 1	0.901	0.814	0.887	0.795	0.911	0.904
Kat 2	0.845	0.752	0.885	0.874	0.899	0.816
Kat 3	0.889	0.759	0.883	0.853	0.887	0.728
Kat 4	0.733	0.728	0.881	0.832	0.875	0.864
Kat 5	0.821	0.704	0.877	0.891	0.851	0.812
Kat 6	<b>0.943</b>	<b>0.794</b>	<b>0.965</b>	<b>0.799</b>	<b>0.982</b>	<b>0.974</b>
Kat 7	0.809	0.828	0.873	0.848	0.827	0.888
Kat 8	0.897	0.756	0.869	0.806	0.803	0.712
Kat 9	0.865	0.884	0.853	0.998	0.813	0.884
Kat 10	0.941	0.812	0.737	0.849	0.767	0.824

ResNet50 ağı performansının sonuçları ve kullanılan nicel ölçümlerin sunulduğu Çizelge 5.2’de de görüldüğü üzere MCC 0.943, F2 skoru 0.894, doğruluk 0.965, özgüllük 0.894, hassasiyet 0.982, ve F1 skoru 0.974 olarak bulunmuştur. Model doğruluğu için 10 katlı çapraz doğrulama kullanılmış ve doğruluk oranı yüzde 96,5 gibi bir değerle başarıya ulaşmıştır. Bu durumun ispatı niteliğinde olan ResNet50 ağı hata matrisinin normalize edilmiş ve normalize edilmemiş iki farklı şekli aşağıda verilen Şekil 5.3’te gösterilmektedir.




**Şekil 5.3:** ResNet50 hata matrisi gösterimi

Resnet modelinde daha hızlı eğitim yapabilmek için darboğaz (bottleneck) blokları kullanılmaktadır. Şekil 5.4'te ResNet50 Modeli için eğitim, test seti içinse ROC eğrisi gösterilmektedir.



**Şekil 5.4:** ResNet50 ağı ROC eğrisi sonuçları

Şekil 5.4'te ResNet50 modelinin performansı için gösterilen ROC eğrisinde, AUC 0,97 olarak ölçülmüştür. Bu da aslında ResNet50 mimarisinin başarılı olduğu anlamına gelmektedir. Tek sıkıntı ise yapılan deneylerde doğrulama sonucunun istenilen düzeyde olmamasıdır. Bu durumu gösteren ResNet50 doğruluk ve kayıp oranları aşağıda verilen Şekil 5.5'te yer almaktadır.



**Şekil 5.5:** ResNet50 doğruluk ve kayıp oranları

Şekil 5.5'te de görüldüğü üzere ResNet50 mimarisi için kayıp oranı düşmekte, doğruluk oranı ise artmaktadır.

### 5.1.2 Inception v3


Medikal görüntü işlemede, Inception v3 etkili bir DSA mimarisidir. Inception algoritması, yerleşik veya mobil bilgi işlem aygıtları açısından çok daha iyi performans göstermektedir. ESA, özellikle görüntü tanıma problemleri için tasarlanmış bir sinir ağıdır. Görüntülerin insan tarafından tanınmasının çok katmanlı sürecini taklit etmektedir. Inception v3 modülü, tipik olarak üç farklı boyutta evrişim ve bir maksimum havuzlama içermektedir. Önceki katmanın ağ çıkışına ulaşmak amacıyla kanal, evrişim işlemi sonrasında toplanmakta ve ardından da doğrusal olmayan füzyon gerçekleştirilmektedir. Böylece ağın ifade edilmesi ve farklı ölçeklere uyarlanabilirliği geliştirilerek aşırı uyum önlenmektedir. Inception v3, Image Net'te önceden eğitilmiş ve Keras tarafından geliştirilmiş bir ağ yapısıdır. Varsayılan görüntü giriş boyutu, üç kanallı  $299 \times 299$ 'dur. Derin ESA'da doğruluğu arttırmanın yolu, her bir düzeydeki ortalama boyutlarda çalışma düzeyi ve birim sayısını arttırmaktır. Bu nedenle başlangıçta  $1 \times 1$ ,  $3 \times 3$ ,  $5 \times 5$  evrişim filtresi ve  $3 \times 3$  maksimum havuzlama filtresi kullanılmaktadır. Evrişim katmanında maksimum havuzlama işlemi çok etkilidir. Inception, optimum seyrek mimari ve diğer mimariden 3 ~

10 × daha hızlıdır. Aşağıda verilen Çizelge 5.3'te; Inception v3 ağı'nın toplam doğrulama adımı ve modelin doğruluğu gösterilmektedir

**Çizelge 5.3:** Inception v3 model sonuçları

Doğrulama	MCC	F2 skoru	Doğruluk	Özgüllük	Hassasiyet	F1
Kat 1	0.797	0.756	0.869	0.596	0.803	0.712
Kat 2	0.976	0.833	0.849	0.814	0.865	0.917
Kat 3	<b>0.976</b>	<b>0.733</b>	<b>0.849</b>	<b>0.737</b>	<b>0.865</b>	<b>0.917</b>
Kat 4	0.789	0.714	0.869	0.747	0.759	0.944
Kat 5	0.813	0.876	0.789	0.897	0.873	0.748
Kat 6	0.787	0.774	0.752	0.747	0.987	0.564
Kat 7	0.789	0.714	0.869	0.847	0.759	0.944
Kat 8	0.733	0.876	0.789	0.897	0.873	0.348
Kat 9	0.885	0.738	0.774	0.847	0.987	0.788
Kat 10	0.789	0.714	0.869	0.813	0.759	0.944


Inception v3 ağı performansının sonuçları ve kullanılan nicel ölçümlerin sunulduğu Çizelge 5.3'te de görüldüğü üzere MCC 0.976, F2 skoru 0.733, doğruluk 0.849, özgüllük 0.714, hassasiyet 0.865, ve F1 skoru 0.917 olarak bulunmuştur. Bu durumun ispatı niteliğinde olan Inception v3 hata matrisi gösterimi aşağıda verilen Şekil 5.6'da gösterilmektedir.



**Şekil 5.6:** Inception v3 hata matrisi gösterimi

Son teknoloji ürünü olan ESA ağı, sınıflandırma için son derece uygundur. 48 katman derinliğindedir ve 1 × 1, 3 × 3 ve 5 × 5 gibi evrişimlerle birleştirilmiş bir katman içeren Inception modüllerini kullanmaktadır. Bunu yaparak parametre sayısı azaltılabilmekte, eğitim hızı artırılabilir. Bu, aynı zamanda GoogLeNet Mimarisi olarak da anılmaktadır. Çizelge 5.3 ve 5.4, Inception V3 modeli için eğitim ve test setindeki f1 skorunu göstermektedir.

Aşağıda verilen Şekil 5.7'de, art arda dönemlerde azalma yaşandığı için Inception Ağı modeline ait eğitim kaybı gösterilmektedir.



**Şekil 5.7:** Inception v3 ROC performansı gösterimi

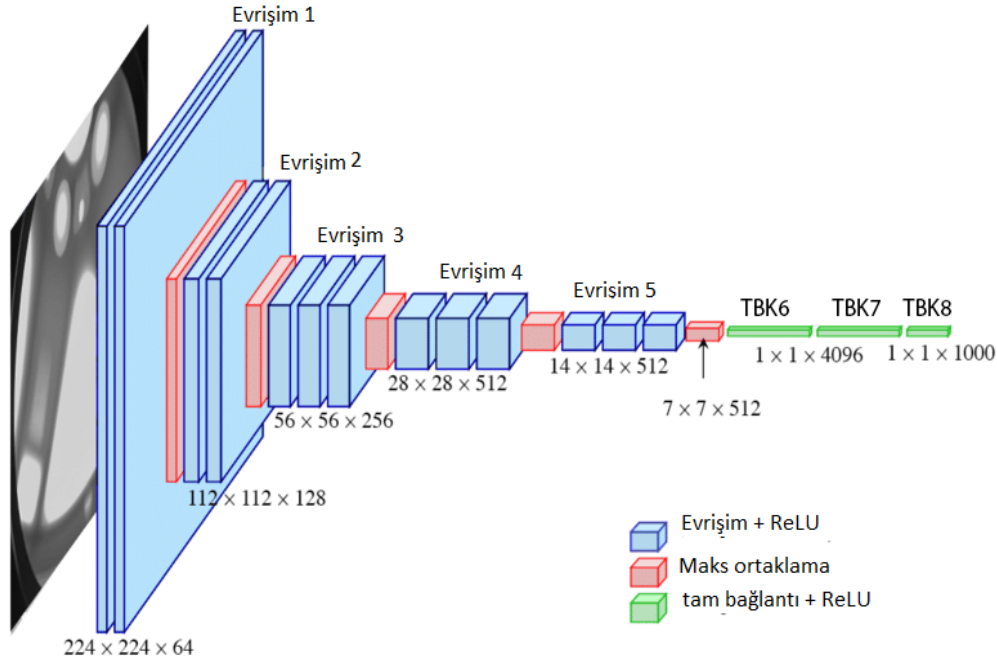
Şekil 5.7'de görüldüğü üzere; Inception v3 modelinin performans için gösterilen ROC eğrisinde AUC'si 0,790 olarak ölçülmüştür. Bu durum da yapılan deneylerde Inception v3 mimarisinin başarılı olmadığı anlamına gelmektedir.

### 5.1.3 VGG16 Ağı

Bu modelde ise veri eğitimi için VGG16 kullanılmıştır. BT görüntüleri eğitim ve test için iki sete ayrılmıştır. VGG16 bir ESA mimarisidir. VGG16'nın 16 katmanı bulunmaktadır. Katmanlar, evrişimli katmanlar, maksimum havuzlama katmanları, aktivasyon katmanları ve TBK'lerden oluşmaktadır. 13 evrişimli, 5 maksimum havuzlama ve 3 yoğun katman olmak üzere toplam 21 katmandan oluşmasına rağmen sadece 16 ağırlık katmanı bulunmaktadır. Evrişim 1'de 64 filtre bulunurken Evrişim 2'de 128, Evrişim 3'te 256, Evrişim 4 ve 5'te 512 filtre bulunmaktadır.

VGG16 basit bir ağ modelidir ve önceki modellerden en önemli farkı evrişim katmalarının 2'li ya da 3'lü kullanılmasıdır. Tam bağlı katmanında  $7 \times 7 \times 512 = 4096$  nöronlu bir öznitelik vektörüne dönüştürülmüştür. İki TBK katmanının çıkışında 1000 sınıflı softmax performansı hesaplanmıştır. Yaklaşık 138 milyon parametre bulunmaktadır. Diğer modellerde olduğu gibi girişten çıkışa kadar matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri (derinlik) artmaktadır. Önerilen yöntemde VGG16 mimarisinin TBK8

katmanına sahip olması bu modellerin diğer modellerle kullanımında etkili olmuştur. VGG16 modelinin TBK8 katmanı 1000 özelliğe sahiptir. Aşağıda verilen Şekil 5.8’de VGG16 ağı performansının sonuçları ve kullanılan nicel ölçümler gösterilmektedir.



**Şekil 5.8:** VGG16 Şeması gösterimi

**Kaynak:** (Teramoto et al., 2019)


Şekil 5.8’de de görüldüğü üzere; EVRŞ1 katmanının girdisi sabit boyutta  $224 \times 224 \times 64$  RGB görüntüdür. Görüntü, filtrelerin çok küçük bir alıcı alanla kullanıldığı  $3 \times 3$  (sol / sağ, yukarı / aşağı) şeklinde bir evrişim katman yığınınından geçirilmektedir. Yapılandırmalardan birinde, giriş kanallarının doğrusal bir dönüşümü olarak görülebilen  $1 \times 1$  evrişim filtreleri de kullanılmaktadır. Evrişim adımı 1 piksele sabitlenmiştir; yani uzamsal çözünürlüğün evrişimden sonra korunabileceği dolgu,  $3 \times 3$  dönüşüm için 1 piksel şeklindedir. Bazı evrişim katmanlarından sonra gelen maksimum havuzlama, 2 adım ile bir pencere üzerinde gerçekleştirilmektedir. 3. adımda TBK bir evrişimli katman yığınınını takip ederek,  $1 \times 1 \times 4096$  kanala sahip olmaktadır. En son kaman ise çıktı katmanıdır.

Aşağıda verilen Çizelge 5.4’te VGG16 ağının toplam Epok sayısı ve modelin doğruluğu gösterilmektedir.

**Çizelge 5.4:** VGG16 model Sonuçları


Doğrulama	MCC	F2 skoru	Doğruluk	Özgüllük	Hassasiyet	F1
Kat 1	0.725	0.614	0.715	0.705	0.869	0.903
Kat 2	0.785	0.714	0.744	0.847	0.759	0.744
Kat 3	0.737	0.899	0.812	0.802	0.870	0.871
Kat 4	0.827	0.744	0.721	0.714	0.759	0.904
Kat 5	0.817	0.889	0.819	0.809	0.869	0.698
Kat 6	0.907	0.734	0.717	0.818	0.841	0.788
Kat 7	0.914	0.779	0.815	0.877	0.801	0.845
Kat 8	<b>0.941</b>	<b>0.801</b>	<b>0.826</b>	<b>0.795</b>	<b>0.869</b>	<b>0.903</b>
Kat 9	0.901	0.714	0.913	0.781	0.759	0.905
Kat 10	0.861	0.701	0.901	0.761	0.869	0.907

VGG16 ağı performansının sonuçları ve kullanılan nicel ölçümlerin sunulduğu Çizelge 5.4'te de görüldüğü üzere MCC 0.941, F2 skoru 0.724, doğruluk 0.826, özgüllük 0.825, hassasiyet 0.869 ve F1 skoru 0.903 olarak bulunmuştur. Bu durumun ispatı niteliğinde olan VGG16 hata matrisi gösterimi aşağıda verilen Şekil 5.9'da gösterilmektedir.



**Şekil 5.9:** VGG16 hata matrisi gösterimi

Şekil 5.9'da da görüldüğü üzere VGG16 hata matrisi gösteriminde gerçek ve tahmin edilen değerler tartışılarak, hata matrisi normalize edilmiş ve normalize edilmemiş olmak üzere iki yönden incelenmiştir. DP 519538 iken YP 3302'de kalmıştır. Öte yandan YN 78083 değerinde kalırken DN 8975 olmuştur. Aşağıda verilen Şekil 5.10'te VGG16 ROC sonuçları gösterilmektedir.




Şekil 5.10: VGG16 ROC sonuçları gösterimi

Şekil 5.10'da da görüldüğü üzere, en iyi AUC değeri 0,87 olarak hesaplanmıştır. VGG16 performansında ise yanlış teşhis oranı düşük olmakla birlikte YPO ve YNO yüksek görülmektedir.

#### 5.1.4 AlexNet

AlexNet, ESA mimarilerinin en ünlülerinden biridir. Yapı olarak çok katmanlıdır. TBK ve üç maksimum havuzlama katmanının yanı sıra beş kıvrımlı katmandan oluşmaktadır. Aşağıda verilen Şekil 5.11'de AlexNet Modelinin yönetim akış şeması gösterilmektedir.



Şekil 5.11: AlexNet Modeli yönteminin akış şeması

Şekil 5.11'de de görüldüğü üzere, AlexNet modelinde ilk adımda eğitilmiş ağın birinci kısmı dışa aktarılmıştır. İkinci adımda elde edilen öznetelik kısmı yeni tasarlanmış bir ikinci yarı kısma bağlanarak önerilen ağın temel mimarisi oluşturulmuştur. Öğrenme ünitelerinin rastgele deaktif hale gelmesi için tam bağlantılı katmanlarda %50 çıkarma uygulanmıştır. Böylece Softmax ile her eğitim yinelemesinin sonunda ağırlıklar değiştirilerek genelleme performansının artışı sağlanmıştır. Buna ek olarak, aşırı uymanın önüne

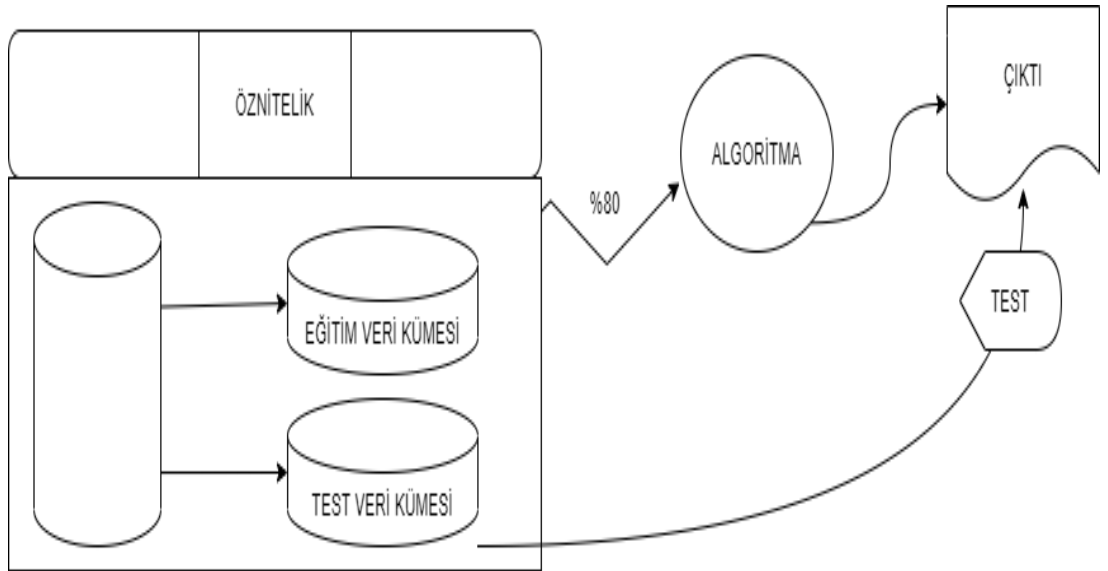


geçmek ve genelleme performansını iyileştirmek için L2-norm düzenlenilmesi benimsenmiştir. Üçüncü adımda, 3 bileşen görüntüsünün dalgacık katsayıları yeni inşa edilmiş ağı üç girdi kanalına verilerek yeniden eğitim için geri yayılım gerçekleştirilmiştir.

Ağı eğitmek için 0,9 ivme ile OED yöntemi kullanılmıştır. Epok sayısını belirlemek için hatasızlık doğrulaması her yinelemenin sonunda gerçekleştirilmiştir. 5 yinelemeden sonra hatasızlığın azami değere ulaşmaması halinde öğrenme süreci durmaktadır. Çapraz entropi, kayıp fonksiyonu olarak kullanılmıştır. Kaybı azaltmak için sınıflayıcı olarak kullanıldığında oldukça iyi bir performans gösteren Softmax'ten yararlanılmıştır. Softmax'in en önemli özelliği ikiden fazla sınıflama gereken durumlarda kullanılmasıdır.

Önerilen ağı eğitim kaybı ve hatasızlık izleri Şekil 5.12'de gösterildiği gibidir. Çizelge 5.4'teki bulgulardan yola çıkarak öğrenmenin doğru bir şekilde uygulandığı varsayılabilir.

Son aşama olarak dışarda tutma (holdout) yönteminden yararlanılarak, aşağıdaki Şekil 5.12'de gösterilen çapraz doğrulama uygulanmıştır.




**Şekil 5.12:** Dışarda tutma yöntemi (holdout method)

Şekil 5.12'de görülmekte olan dışarda tutma metodundan; veri kümesini "eğitim" ve "test" kümesi olarak ayırırken yararlanılmaktadır. Aşağıda verilen Çizelge 5.5'te AlexNet ağına toplam doğrulama sayısı ve modelin doğruluğu gösterilmektedir.

**Çizelge 5.5:** AlexNet model Sonuçları


Doğrulama	MCC	F2 skoru	Doğruluk	Özgüllük	Hassasiyet	F1
Kat 1	0.861	0.837	0.801	0.717	0.828	0.847
Kat 2	<b>0.962</b>	<b>0.854</b>	<b>0.837</b>	<b>0.781</b>	<b>0.854</b>	<b>0.911</b>
Kat 3	0.806	0.834	0.864	0.872	0.864	0.815
Kat 4	0.794	0.731	0.812	0.753	0.816	0.715
Kat 5	0.785	0.728	0.726	0.875	0.858	0.756
Kat 6	0.774	0.829	0.809	0.776	0.789	0.749
Kat 7	0.787	0.829	0.832	0.849	0.846	0.712
Kat 8	0.702	0.789	0.597	0.875	0.821	0.816
Kat 9	0.768	0.854	0.835	0.854	0.854	0.719
Kat 10	0.817	0.849	0.862	0.849	0.832	0.712

AlexNet ağı performansının sonuçları ve kullanılan nicel ölçümlerin sunulduğu Çizelge 5.5'te de görüldüğü üzere MCC 0.962, F2 skoru 0.854, doğruluk 0.826, özgüllük 0.794, hassasiyet 0.854, ve F1 skoru 0.911 olarak bulunmuştur. Ayrıca hata matrisinde doğru pozitif oranı 542122 olarak hesaplanmıştır (Bkz. Şekil 5.13). Aşağıda verilen Şekil 5.13'te AlexNet mimarisinde bulunan son evrişim katmanının aktivasyon haritası gösterilmektedir.



**Şekil 5.13:** AlexNet hata matrisi gösterimi

Şekil 5.14'te görüldüğü üzere AUC sonucu 0.716 olarak ölçülmüştür. DP 524122 iken YP sadece 20791'de kalmıştır. Öte yandan YN 83285 değerinde kalırken DN 11400 olmuştur. Aşağıda verilen Şekil 5.14'te AlexNet modelinin ROC performans gösterimi yer almaktadır.



**Şekil 5.14:** AlexNet modelinin ROC performans gösterimi

Şekil 5.14'te de görüldüğü üzere ROC eğrisi üzerinden sunulan sonuçlar, tahmin oranının 0,716 AUC değeriyle oldukça doğru olduğunu kanıtlamaktadır.


## 5.2 Yenilikçi Derin Öğrenme Algoritmasının Uygulanması

Geleneksel mimaride kullanılan AlexNet, ResNet50 ESA mimarileri, VGG16 ve Inception v3; yaklaşık olarak 1000 sınıfa sahiptir ve derin mimariler için tasarlanmışlardır. Bu mimariler milyonlarca görüntü üzerinde eğitilmişlerdir ve bu nedenle çok derin modellerdir. Derin mimariler çalışma esnasında daha çok zaman harcayabilir. Dolayısıyla, bu derin mimarilerin düşük konfigürasyonlu makinelerde verimsiz olma ihtimalleri bulunmaktadır. Ayrıca, bu söz konusu derin modeller kullanıldığında tıbbi verilerin görselleştirilmesi anlamlı olmayabilir.

Buna dayanarak bu çalışma kapsamında, 4K-ESA olarak adlandırılan hem çok derin olmayan hem de tıbbi görüntü işleme için daha uygun olan bir ESA mimarisi geliştirilmiştir. Bu mimaride dört evrişimli katman bulunmaktadır. Ayrıca global bir ortalama havuzu (GOH), iki TBK katmanı ve Softmax ile çıktı katmanı vardır. GOH, klasik ESA'larda TBK değiştirmek için tasarlanmış bir havuzlama işlemidir. Buradaki fikir, son ÇKP katmanındaki sınıflandırma

görevine ait tüm ilgili kategoriler için bir özellik haritası oluşturmaktır. GOH, havuzlama amacıyla kullanılır ancak havuzlamadan daha etkilidir.

Her bir evrişimli katmanın iki ardışık 3 x 3 evrişimli bloğu, ReLU'ları, ReLU ile 1 x 1 Evrişimli bir bağlayıcı bloğu ve bir maksimum havuzlama bloğu vardır. İlk katmanda her bir evrişimli bloktaki filtre sayısı 16, ikinci katmanda 32, üçüncü katmanda 48 ve son katmanda 64'tür. Filtrelerdeki adım kaydırma oranı ise 1'dir. Aşağıda verilen Şekil 5.15'te 4K-ESA mimarisi gösterilmektedir.



Şekil 5.15: 4K-ESA MC mimari yapısı

Şekil 5.15'te de görüldüğü üzere konektör evrişimli bloğun çıkışı, maksimum havuzlamadan önce ikinci ESA bloğunun çıktısı ile toplanmaktadır. Maksimum havuzlama adımı 2'dir; böylece çözünürlük 4 faktör azalmaktadır. Her evrişimli bloktan önce boyutu korumak için sıfır dolgu uygulanmaktadır. Eğitimi hızlandırmak için her katmana mini toplu normalleştirme uygulanmaktadır. 4K-ESA'daki katman sayısı 4'tür, böylece reseptör penceresi tüm görüntüyü kaplamaktır. Model öncelikle 5 katmanla test edilmiştir ancak 4 katman daha iyi performans göstermiştir. Girdi görüntüsünün her pikseli, tüm veri tabanının piksellerinin ortalaması ve standart sapması ile normalleştirilmektedir. Mini parti boyutu dört örnektir ve maliyet fonksiyonu kategorik çapraz entropidir. Her mini partiden önce, öğrenmenin tamamen rastgele hale getirilmesini sağlamak için numuneler yönlendirilmiştir; bu aynı zamanda aşmanın üstesinden gelmeye de yardımcı olmuştur. İlk ağırlıklar


normalizasyon uygulanarak bulunmuş, ağırlıkları optimize etmek için Adam eniyilemesi kullanılmıştır. 4K-ESA'da kullanılan parametreler aşağıda verilen Denklem 5.2'de gösterilmektedir.

$$\beta_1 = 0.9, \beta_2 = 0.999, \varepsilon = 1 \times 10^{-9} \quad (5.2)$$

Önerilen 4K-ESA mimarisi, daha önceki geleneksel mimarinin bir varyasyonudur. Bu iki mimari arasındaki temel fark, katmanların sayısıdır. Önerilen mimarimi modelin hafif olmasını sağlayan, daha az sayıda katmana sahiptir. Önceki geleneksel mimarilerde İA çıkarılmamıştır. Bu mimaride ise İA'dan yararlanılmaktadır. Yeni 4K-ESA mimarisi, önceden temizlenmiş ve işlenmiş olan aynı verilere uygulanmıştır. Deneylede kullanılan örnekler sırasıyla şu şekilde seçilmiştir:

Eğitim veri kümesindeki dengesizlik, birçok MÖ algoritmasını etkileyebilir ve bazılarının azınlık sınıfını tamamen görmezden gelmesine yol açabilir. Bu, tahminlerin en önemli olduğu azınlık sınıfı olduğu için bir sorundur. Dengesiz veri setleri ile çalışılırken analiz sonuçlarının mükemmel yakın olarak ortaya çıkması modelin başarılı bir model olduğu anlamına gelmemekte aksine modelde aşırı öğrenme olabileceği anlamına gelmektedir. Sınıf dengesizliği sorununu ele almaya yönelik bir yaklaşım, eğitim veri setini rastgele yeniden örnekleme. Dengesiz bir veri kümesini rastgele yeniden örnekleme yönelik iki ana yaklaşım bulunmaktadır. Bunlar Rastgele Üst örnekleme ve Rastgele alt örneklemedir.

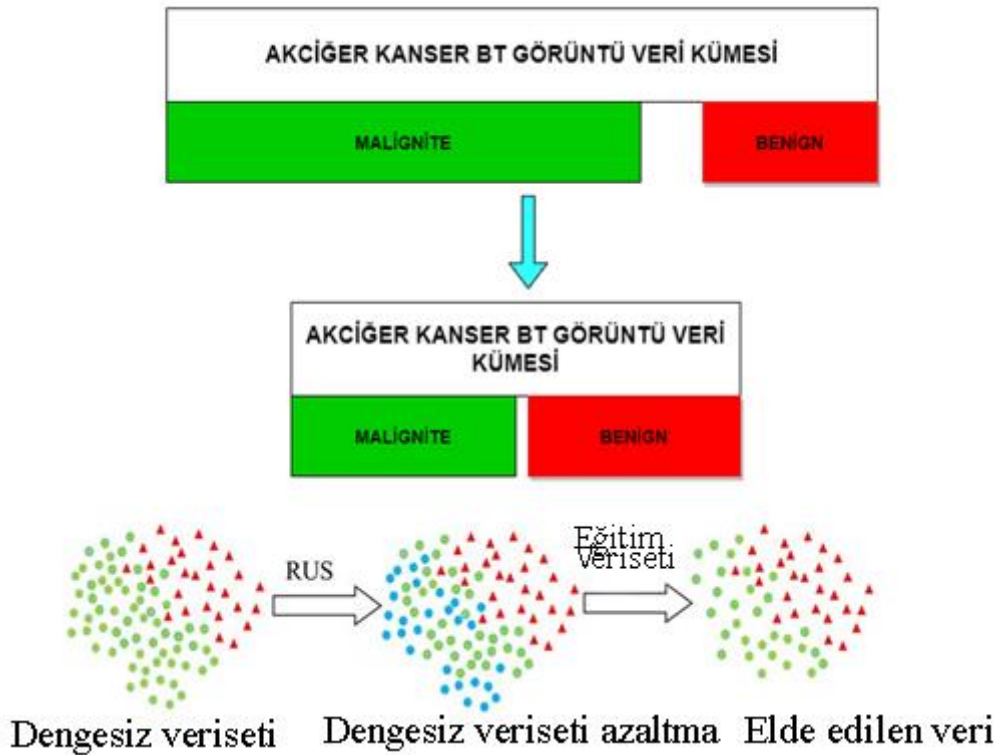
**Rastgele Üst Örnekleme:** Azınlık sınıfının örneklerini çoğaltarak sınıf dağılımını dengeleyen sezgisel olmayan bir yöntemdir. Aşağıda verilen Şekil 5.16'da rastgele üst örnekleme şeması gösterilmektedir.



Şekil 5.16: Rastgele Üst Örnekleme

Şekil 5.16'da de görüldüğü üzere; bir modeli ezbercilikten kurtarmaya yarayan rastgele üst örnekleme metodunda, öncelikle eğitim veri setinde bulunan azınlık sınıfındaki örnekler basitçe çoğaltılmaktadır. Bu çoğaltma işlemi, sınıf dağılımını dengeleyebilir ancak modele herhangi bir ek katkı sağlamamaktadır. Örneğin; veri kümesi %90'lık kanserli %10'luk sağlıklı BT görüntüsü gibi dengesiz bir dağılıma sahip verilerden oluşuyorsa %10'luk kısmı üst örnekleme metodu ile dengeli hale getirilmektedir.

Rastgele Alt Örnekleme: Dengeli bir sınıf dağılımı oluşturmak için çoğunluk sınıfının bir alt kümesinin seçildiği sezgisel olmayan bir yöntemdir. Rastgele alt örnekleme, verilerin boyutunu önemli ölçüde azaltabilecek olan bazı örneklerin ortadan kaldırılması ve özellikle büyük veri durumunda çalışma süresi maliyetini düşürebilecek olması açısından oldukça avantajlıdır. Aşağıda verilen Şekil 5.17'de rastgele alt örnekleme şeması gösterilmektedir.




**Şekil 5.17:** Rastgele Alt Örnekleme gösterilmektedir

Şekil 5.17'de de görüldüğü üzere; örneklerin çoğunluk sınıfından rastgele seçilmesi ve bunların eğitim veri setinden silinmesini içeren rastgele alt örnekleme metodunda, çoğunluk sınıf örnekleri daha dengeli bir dağılıma ulaşılan kadar rastgele atılmaktadır. Örneğin; veri kümesi %80'lik kanserli

%40'lık sağlıklı BT görüntüsü gibi bir dağılıma sahip verilerden oluşuyorsa %80'lik kısımdan verilerin %40'ı silinmektedir. Böylece veri seti %40'a %40 şeklinde dengelenmektedir.

Öncelikle 3 mm'nin altındaki kalınlığa sahip olan tüm nodül numuneleri kaldırılmıştır. Dolayısıyla anlaşılması daha kolay, 3 mm ve üzeri boyuttaki nodüller seçilmiştir. Nodüller "malignite", "benign" ve "nodül değil" olarak farklı evrelerde sınıflandırılmıştır. Genel olarak veri bölümünde açıklandığı gibi aynı veriler kullanılmıştır. Aşağıda verilen Şekil 5.18'da akciğer nodülü alanı İA'sının vurgulandığı bir BT görüntüsü örneğini gösterilmektedir.



**Şekil 5.18:** İA bölgesi belirlenmiş BT görüntüsü gösterimi

**Kaynak:** (Vaka 196'dan bir kesit)

Şekil 5.18'de de görüldüğü üzere sağ taraf, radyologlar tarafından nodül bölgesi olarak işaretlenmiştir. Nodül aday bölgeleri, KAM verisinden bölüm bölüm çıkarılmaktadır. Bir maske kullanımı ile aday nodüllerin piksellerinin orijinal değerleri korunmuş; bunun yerine sıfırı doldurularak  $52 \times 52$  boyutuna getirilmiştir. Sonunda, tüm örnekler  $256 \times 256$  olarak yeniden boyutlandırılmıştır. Sınıf başına örnek sayısı dengesizliğini gidermek için Rastgele Üst Örnekleme (RoS) ve Rastgele Alt Örnekleme (RuS) tekniklerinden yararlanılmıştır.

### 5.2.1 4K-ESA Uygulanan Monte Carlo Seyreltme

4K-ESA modelinde aşırı öğrenmeyi engellemek için seyreltmeden farklı bir teknik olan Gal ve Ghahramani (2016)'nin önerdiği Monte Carlo Seyreltme (MCS) kullanılmaktadır. DÖ'nün pek çok farklı ağı, mevcut tüm modellerin uzayında MCS'den yararlanabilir. MCS, modelin belirsizliğini göstermek için matematiksel bir zemin sağlamasına karşın, bu çalışmada MCS'den daha çok aşırı öğrenmeyi engellemek için yararlanılmıştır.

Normal seyreltme sadece eğitim esnasında uygulanarak tahmin esnasında durdurulmaktadır. MCS ise aşırı öğrenmeyi önlemek için bir düzenleme işlevi görmektedir. Test süresi boyunca seyreltme devam etmektedir. Normal seyreltme için test zamanında tahminin deterministik olarak kabul edilmesi esastır. Başka bir rastgelelik kaynağı olmadan bir test veri noktası verildiğinde, model her zaman aynı etiketi veya değeri tahmin edecektir. MCS ise hem eğitim hem de test esnasında uygulandığından test zamanında tahmin deterministik olmaktan çıkmaktadır. Bu nedenle, aynı veri noktası verildiğinde model her seferinde farklı değerleri tahmin etmektedir. Dolayısıyla MCS'nin birincil hedefi, rastgele tahminler oluşturmak ve bunları olasılık dağılımından örnekler olarak yorumlamaktır.

MCS'nin uygulanışına etkinleştirme fonksiyonu  $\sigma$  ve başlangıç parametreleri  $W_1, \dots, W_L, b_1, \dots, b_L$  ile düzenli bir ÇKP derinliği alarak başlanmaktadır. Yalnızca derinliği yüksek olan modelleri dikkate alındığında bu durumda bir skaler olacaktır. Normal ileri besleme mimarisi yerine, daha sonra  $Z_1 \dots Z_L$  seyreltme eklenmektedir. Aşağıda verilen Denklem 5.3'te DÖ katmanlarında meydana gelen etkileşimler sırasıyla anlatılmaktadır.

$$\hat{y}(\mathbf{x}) = \sqrt{\frac{1}{K_{L-1}}} \sigma \left( \dots \sqrt{\frac{1}{K_2}} \sigma \left( \sqrt{\frac{1}{K_1}} \sigma(xZ_1W_1 + b_1)Z_2W_2 + b_2 \right) \dots \right) Z_LW_L + b_L \quad (5.3)$$

Denklem 5.3'te görüldüğü üzere;  $W_L$  l'inci gizli katmandaki düğüm sayısını,  $Z_L$  tüm seyreltme katmanları için aynı olan Bernoulli olasılık  $P_D$  ögesini (0,1) ifade eden l'inci katmandan önceki seyreltme matrisidir.  $b_L$  ise eğitim süreci için ağırlık azaltma faktörünü ifade etmektedir. Denklem 5.3'te anlatıldığı gibi tüm parametrelerde aynı faktörleri kullanmak yerine, kayıp fonksiyonuyla sonuçlanan  $p_D$  olasılığına göre ağırlık matrisleri için ölçeklendirilmiştir. Ayrıca




eđitim adımları, gradyan iniş yöntemlerinden biri kullanılarak ve her öğrenme adımından önce seyreltme ölçütlerinin yeniden değerlendirilmesiyle düzenli bir şekilde gerçekleştirilir. Çizelge 5. 6'da 4K-ESA modelinin sonuçları gösterilmektedir.

**Çizelge 5.6:** 4K-ESA modelinin sonuçları

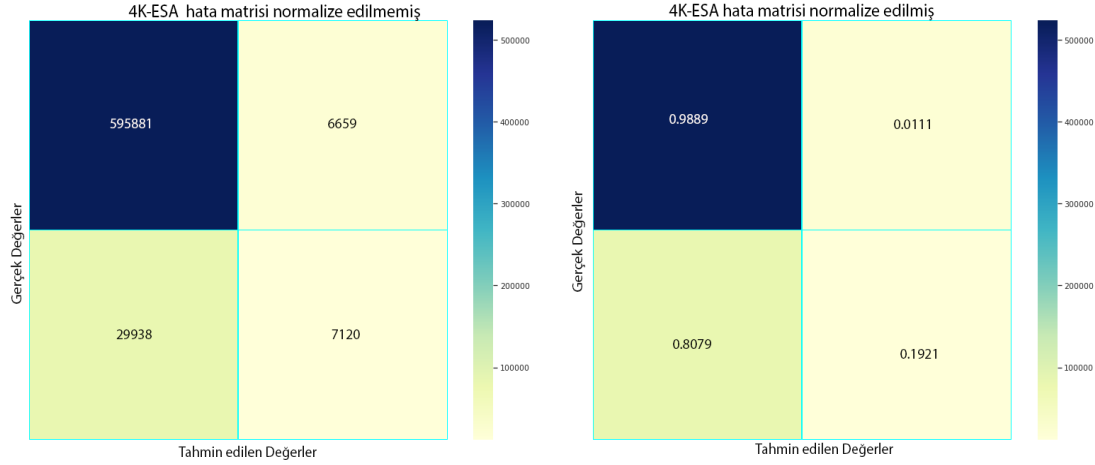
Dođrulama	MCC	F2 skoru	Dođruluk	Özgüllük	Hassasiyet	F1
Kat 1	0.861	0.837	0.801	0.801	0.728	0.809
Kat 2	0.885	0.836	0.889	0.824	0.805	0.835
Kat 3	0.794	0.835	0.947	0.803	0.882	0.844
Kat 4	0.846	0.821	0.862	0.876	0.894	0.807
Kat 5	0.798	0.807	0.899	0.941	0.706	0.865
Kat 6	0.951	0.793	0.851	0.863	0.718	0.826
Kat 7	0.919	0.794	0.891	0.824	0.885	0.834
Kat 8	0.971	0.758	0.878	0.785	0.847	0.915
Kat 9	0.952	0.875	0.914	0.858	0.845	0.903
Kat 10	<b>0.988</b>	<b>0.816</b>	<b>0.971</b>	<b>0.825</b>	<b>0.974</b>	<b>0.962</b>

4K-ESA ađı performansının sonuçları ve kullanılan nicel ölçümlerin sunulduđu Çizelge 5.6'da da görüldüđu üzere; MCC 0. 988, F2 skoru 0. 816, dođruluk 0. 971, özgüllük 0. 825, hassasiyet 0. 974 ve F1 skoru 0. 962 olarak hesaplanmıřtır. Ayrıca yapılan 10 kat çaprazlama deney sonucunda 4K-ESA mimarisi %97,15 dođruluk, %82,50 özgüllük ve %98,83 MCC, %97,74 hassasiyet ile %81,60 F2 skora sahip olduđu da Çizelge 5.6'da görülmektedir. Ařađıdaki verilen řekil 5.19'da 4K-ESA metodu performans sonuçları gösterilmektedir.



**řekil 5.19:** 4K-ESA metodu performans sonuçları


4K-ESA'dan elde edilen verilerle akciğer kanseri hususunda doğru tahminlerin yapılabilmesi açısından iyi sonuçlar elde edilmiştir. Şekil 5.19'da da görüldüğü üzere; yapılan testler sonucunda F1 ve Hassasiyet değerlerinin birbirine çok yakın olduğu anlaşılmaktadır. Aşağıda verilen Şekil 5.20'de 4K-ESA hata matrisi gösterimi yer almaktadır.



**Şekil 5.20:** 4K-ESA hata matrisi gösterimi


Şekil 5.20'de görüldüğü üzere; BT görüntüleri, 4K-ESA DÖ algoritmalarında yalnızca sınırlı sayıda katman için test edilmiştir. Buna karşın hem normalize edilmiş değerler hem de normalize edilmemiş değerlere bakıldığında, 4K-ESA akciğer kanseri hastalığının doğru teşhis edilebilmesi açısından başarılı sonuçlar göstermiştir.

Gizli katmanlar bazen makine konfigürasyonuna fazla gelmektedir. Bu nedenle katmanların sayısını arttırmak, tanı performansını her zaman iyileştirmeye yardımcı olamayabilir. Akciğer nodülü teşhisinde hata matrisinde görüldüğü gibi sonuç 595881 doğru pozitif oranına sahiptir. Aşağıda verilen Şekil 5.21'de 4K-ESA mimarisinde doğruluk ile kayıp oranlarının karşılaştırılması gösterilmektedir.



**Şekil 5.21:** 4K-ESA eğitim doğruluğu ve kayıp oranları


Şekil 5.21’de de görüldüğü üzere; epok sayısı düşükken doğruluk az, kayıp fazladır. Epok sayısı yüksek olduğunda da yine aynı sonuca maruz kalmaktadır. Dolayısıyla dengeli epok sayısı doğruluğu arttırırken kayıp oranını en aza indirmektedir. Aşağıda verilen Şekil 5.22’de 4-K ESA ROC eğrisi sonuçları gösterilmektedir.



**Şekil 5.22:** 4-K ESA ROC eğrisi sonuçları

Şekil 5.22’de de görüldüğü üzere; 4K-ESA mimarisi için ROC ve AUC değerleri hesaplanmıştır. En iyi AUC değeri 0.903 olarak test edilmiştir. Gösterilen sonuçlar açısından sınırlı sayıda da olsa YN ve YP değerlerinin

varlığından bahsetmek mümkündür. 4K-ESA modelindeki amaç, YN ve YP hastalarda çok büyük sıkıntılara neden olmaları sebebiyle bu değerleri minimize etmektir. Modelin doğruluğu ve değer kaybı açısından öğrenme eğrileri iyi derecede temsil edilmiştir. Aşağıda verilen Şekil 5.23'te 4K-ESA modeline ilişkin olarak ortaya çıkan sonuçlar gösterilmektedir.



**Şekil 5.23:** 4K-ESA modeline ilişkin olarak ortaya çıkan sonuçlar

Şekil 5.23'te de görüldüğü üzere; 4K-ESA'ya girdi olarak verilen BT görüntüleri, modelin çalışmasından sonra gizli katmanlarda yapılan işlemler neticesinde en son katman olan çıktı katmanına ulaşmaktadır. Burada hatalı değerler geri döndürülürken doğru değerler Şekil 5.23'te görüldüğü gibi malignite veya benign olarak işaretlenmektedir.

### 5.2.2 4K-ESA Modelinde Belirsizlik (Uncertainty of 4K-CNN Model)

Çıktıları iyi tanımlayan, ayrıca yeni girdiler için sonuçları makul biçimde tahmin edebilen bir model tasarlanmıştır. Ancak bu modelin ne kadar öğrendiği

veya öğrenemediği oldukça önemlidir. Burada sezgisel olarak, akla bazı sorular gelmektedir: Çıktıların ne kadar güvenilir olduğu belirlenebilir mi? Belirli bir BT görüntüsü girdi olarak verildiğinde elde edilen çıktı doğru mu yoksa yanlış mı tahmin edilir; Yanlış ise ne kadarı yanlıştır?

Bilinmeyen sonuçları tahmin ederken gerçek süreç bilinse bile, gerçek sonucun potansiyel gürültüden etkilenebileceğinin farkında olmak gerekmektedir. Öte yandan, sahip olunan modelin gerçek veri üreten model olup olmadığı konusunda bilinmesi gerekmektedir. Gerçek değerli girdiler ve çıktılar dikkate alındığında ve tüm çıktıların gürültüsüz olduğu varsayıldığında, doğrusal bir model kesinlikle iki gözlemle belirlenmektedir. Bununla birlikte, gürültü ortaya konsa dahi, sonuçtan kesin olarak emin olmak mümkün değildir. Ne kadar çok veri toplanırsa güvenilirlik de o kadar artmaktadır. Aşağıda verilen Denklem 5.5'te söz konusu duruma ilişkin formül açıkça gösterilmektedir.

$$f : [0, 2\pi] \times [0, \pi] \times \mathbb{R} \rightarrow \mathbb{R}^2 \quad (5.5)$$

Akciğer kanseri tespitinin anlamlı olabilmesi, toleransın tipik olarak çok daha sıkı olmasına bağlıdır. Girdi BT görüntüsüne bağlı olarak bir ağ, öngörücü posterior dağılımla gösterilen kararından, yüksek veya düşük bir güvenle emin olabilir. Bununla birlikte, DÖ'de öngörücü belirsizlik, iki ayrı belirsizlik biçiminde gösterilmektedir. Çıktıların gürültüden etkilenip etkilenmediği ve modelin öğrenme düzeyinin ölçülebilmesi için iki farklı belirsizlik türü işlenmiştir. Bunlar Aleatorik ve Epistemik belirsizliktir.

**Aleatorik Belirsizlik (Aleatoric Uncertainty):** İstatistiksel Belirsizlik veya İhtiyatlı Belirsizlik olarak da bilinen Aleatorik Benzerlik; veri oluşturma sürecinin, daha fazla gözlem veya veri örneği verildiğinde dahi açıklanamayan, içsel rastlantısallığını tanımlamaktadır. Bu tür belirsizlikler, işlev her değerlendirildiğinde ve bir gözlem yapıldığında farklılık gösteren bilinmeyenlerin sonucudur. Aleatorik Belirsizlik, sınıflama modelinde belirtilen hata terimine karşılık gelmektedir.

Bu tez çalışmasında ortaya konan istatistiksel belirsizlik, çekimin doğasında bulunan rastgelelik sonucunda ortaya çıkan türdür. Veride kesin parametreler bilinse bile, modelde dikkate alınmayan (örneğin sigara) veya basitçe ölçülemeyen (verideki kusurlar gibi) etkiler olabilir. Model girdisi göz önüne

alındığında, somut bir değerlendirmenin kesin çıktısını bilmenin bir yolu yoktur; çünkü her hâlükârda belirli bir miktar varyans olacaktır. BT görüntüleme bu, tarama edinimi sırasında fotonların rastgele dağılımından kaynaklanan sensor gürültüsünden kaynaklanabilir.

**Epistemik Belirsizlik:** "Sistemik Belirsizlik" olarak da bilinen Epistemik Belirsizlik, potansiyel olarak mevcut olan veri eksikliğinden kaynaklanmaktadır. Daha fazla sayıda gözlem, bu tür bir belirsizliği ortadan kaldırabilir. Epistemik Belirsizlik, yalnızca gerçek model oluşturmaktadır. Ancak bu, veri ön işlemede yapılan hataların bir sonucudur. 4K-ESA modelinde veriler üzerine İA işlemi yapıldığı için Epistemik Belirsizlik daha düşüktür. Ancak, farklı parametrelerle diğer geleneksel modellerde hem sistemik hem de Aleatorik belirsizlik bariz bir şekilde görülmektedir. Her ne olursa olsun, sonunda girdi katmanına yeterli miktarda BT verisi verildiğinde Epistemik Belirsizlik ortadan kalkacaktır. Geleneksel olarak, Epistemik belirsizlik altında model doğrulamasını uygulamak daima zor olmuştur. Bu nedenle, akciğer kanserine ait bir BT görüntüsünde kullanılan DÖ yönteminin model belirsizliğini elde etmek için Epistemik belirsizlik tahmin edilmektedir. Model belirsizliğinin ölçülerinden biri, tahmin dağılımının tahmini entropisi olan  $H$  değeridir. Aşağıda verilen Denklem 5.6'da belirsizlik ölçüğü gösterilmektedir.

$$H(\hat{y}|x, X, Y) = -\sum_c p(\hat{y} = c|x, X, Y) \log p(\hat{y} = c|x, X, Y) \quad (5.6)$$

Birinci belirsizlik ölçüsü; elde edilen belirsizlik değerlerinin aralığı, veri kümeleri, ağ mimarileri, MC örnekleme sayısı gibi değişkenlere bağlıdır. Bu nedenle, sonuçları rapor etmek ve çeşitli kümeler ile konfigürasyonlar arasında karşılaştırmayı kolaylaştırmak için tahmini belirsizlik normalleştirilmektedir. Analiz, akciğer kanserine ait BT görüntüsünün sınıflandırmasında varyasyonel ağırlık temelli iki belirsizlik ölçüsünün (Tahmin Edici Entropi (PH) ve Bayesian Aktif Öğrenme Anlaşmazlığı) karşılaştırmasını içermektedir. İkinci belirsizlik ölçüsü olan Bayesian Aktif Öğrenme Anlaşmazlığı ise model aktivasyon fonksiyonu ile tahmin dağılımının entropisi arasındaki ilişkiye dayanmaktadır (Gill, J., & Heuberger, S. (2019). Aşağıda verilen Denklem 5.7'de Bayesian Belirsizlik Ölçeği formülize edilmiştir.

$$MI [y^i, w|x^i, X, Y] \approx H [y^i|x^i, X, Y] - E [H [y^i|x^i w]] \quad (5.7)$$

Denklem 5.7’de verilenlerden hareketle test, karşılıklı bilgiyi en üst düzeye çıkararak, modelin ortalama olarak belirsiz olduğu noktadır. Ancak yüksek güvenlikle hatalı tahminler üreten model parametreleri bulunmaktadır. Bu, softmax katmanına (logitlere) girişte yüksek varyansa sahip noktalara eşdeğerdir. Bu nedenle modelden her bir stokastik ileri geçiş, farklı bir sınıf için en yüksek olasılığa sahip olacaktır. Uyuşmazlık Yoluyla Bayesian Aktif Öğrenme (UYBNN) modelin Epistemik belirsizliği ölçmesi beklenmektedir; bu sebeple Aleoratik belirsizlik mevcutsa yüksek bir değer döndürmeyecektir.

- **Bayes Modeli Belirsizliği**

DÖ modelinin öngörücü olasılıkları ile ilişkili Epistemik belirsizliği, test süresi boyunca düşük ağırlıkları açık tutarak ölçülmüştür. Bir Gauss çekirdeği ile Kernel Yoğunluğu Tahmininin MC stokastik ileri besleme numunesinde bir düşüş oranı olan  $p$  varyasyonunu göstermektedir. Ayrıca doğru ve hatalı tahminlerle gruplandırılmış BT test görüntülerinin çıktı arka dağılımlarını çizmek amacıyla kullanıldığı belirtilmektedir.

### **Belirsizlik ve tahmini doğruluk arasındaki ilişki**

Aşağıdaki verilen Çizelge 5.7’de öngörücü entropi ile tahmin hatası arasında güçlü bir korelasyon olduğu gösterilmektedir.

**Çizelge 5.7:** Belirsizlik ve tahmini doğruluk arasındaki ilişki

Spearman’s’ın Korelasyonu	Tahmini Entropi	UYBNN
DropWeights oranı: 0.5	0.9841	0.8865
DropWeights oranı: 0.3	0.9814	0.8891
DropWeights oranı: 0.1	0.9843	0.9016

Çizelge 5.7’de de görüldüğü üzere; Epistemik belirsizliğin bir ölçüsü olarak, olasılıkların entropisi ve tahmin hataları arasında  $\rho = 0.98$  ile güçlü bir korelasyon olduğunu ortaya koymaktadır. DropWeights oranları Tahmini Entropi ve UYBNN’ye göre 0.1, 0.3 ve 0.5 korelasyonu ile ölçülmüştür. Buna göre Tahmini Entropi değerleri sırasıyla 0.984, 0.9814 ve 0.9843 iken UYBNN’de bu değerler 0.8865, 0.8891 ve 0.9016 olarak bulunmuştur. Deneyler, tahmin belirsizliğinin doğruluk ile ilişkili olduğunu ve böylece yanlış tahminlerin veya bilinmeyen durumların tanımlanmasının mümkün olduğunu göstermektedir.

Gerçek hata, tahmini değerler ile gerçek değerler arasındaki farktır. Tahmine dayalı belirsizliğin kalitesini değerlendirmek için Tahmine Dayalı Entropi (PH) ve UYBNN arasındaki Spearman korelasyon katsayısından yararlanılmıştır. Tahmine dayalı doğruluk şu şekilde ölçülmüştür:

Wasserstein Mesafesi (WM); makine öğrenimi, stokastik programlama ve görüntü işleme konularında giderek daha önemli bir rol üstlenmektedir. Sinkhorn Mesafesi gibi, yaklaşık veya düzenlenmiş varyasyonlara yol açan yüksek hesaplama karmaşıklığının giderilmesi için büyük çabalar devam etmektedir. Bununla birlikte, büyük düzenlilik parametresine sahip düzenlenmiş varyasyonlar, birkaç önemli MÖ uygulamasında performansı düşürecektir; bu sebeple küçük düzenlilik parametresi, mevcut algoritmalarındaki sayısal kararlılık sorunları nedeniyle başarısız olacaktır. İki histogram arasındaki farklılığın belirlenmesi için WM değeri 1 olarak alınmaktadır. WM metriktir ve birçok noktasal mesafeye kıyasla iki histogram arasındaki mesafeyi aslına sadık bir şekilde ölçebilir.

Örneğin; WM, herhangi bir çift delta işlevi arasındaki mesafeyi ayrık desteklerle ayırt edebilir. Histogramlar düzleştirilmedikçe, mesafelerin çoğu birbirleriyle bağlantılı olmayan iki histogram arasındaki mesafeyi ayıramaz. WM, tahmin edilen belirsizliğin gerçek hatalarla ne kadar ilişkili olduğunu ölçmek için kullanılır. Aşağıda verilen Denklem 5.8' de WM gösterilmektedir.

$$W(P_r, P_g) = \inf_{\gamma \sim \Pi(P_r, P_g)} \mathbb{E}_{(x,y) \sim \gamma} [\|x - y\|] \quad (5.8)$$

Denklem 5.8'de de görüldüğü üzere;  $P_r$ , gerçek veri dağıtımını için WM ve oluşturulan veri dağıtımını,  $P_g$  ise matematiksel olarak herhangi bir taşıma planı için en büyük alt sınırı (en düşük) ifade etmektedir.

Bu çalışmada, sıfırdan çok daha derin olan bir modeli küçük bir veri kümesinde eğitmek yerine, bu deneyin bir aktarım öğrenme ortamında çalıştırılmasına karar verilmiştir. İlk olarak, önceden eğitilmiş bir ResNet50 modeli kullanılarak, veriler yalnızca orijinal modele ince ayar yapılmasıyla elde edilmiştir. Bu çözüm, veriler yardımcı bir alanda kullanılmak üzere ve bol miktarda olduğu zaman oldukça uygundur; ancak deney alanı için çok sınırlı sayıda etiketli veri bulunmaktadır. Daha sonra, ResNet50 evrişimli tabanın üstüne tamamen bağlı katmanlar eklenmiştir. DropWeights ve ardından



softmax ile etkinleştirilen bir katman, Gaussian Process'e (GP) bir yaklaşım olarak uygulanmıştır. Anlamlı model belirsizliğini tahmin etmek için tam bağlı katmanda yaklaşık çıkarım olarak Bayesian kullanılmıştır. Softmax katmanı sayesinde, olası her sınıf etiketi üzerinden olasılık dağılımı elde edilmiştir. Tüm görüntüler 224 x 224 piksel olacak şekilde, 4 x 4 piksel mahallesi üzerinde iki kübik enterpolasyon kullanılarak yeniden boyutlandırılmıştır. Görüntüler, BT veri setinin ortalama ve standart sapma değerleri kullanılarak standardize edilmiştir. Modelin aşırı uyumunu önlemek ve öğrenme yeteneğini geliştirmek için eğitim sırasında Keras ImageDataGenerator'dan yararlanılarak gerçek zamanlı veri arttırma uygulanmıştır. Eğitim görüntüleri ZCA ile beyazlatılmış, 20 derece döndürülmüş, rastgele yatay ve dikey olarak çevrilmiş, dışa ve içe ölçeklenmiş, kaydırılmış ve kesilmiştir. Adam Optimizer  $1e - 5$  öğrenme hızı ile 0,2 bozunma faktörü kullanılmıştır. Tüm deneyler 25 dönem boyunca yürütülerek parti boyutu 8'e ayarlanmıştır. Tam bağlı bir katmana 0.1, 0.3 ve 0.5 oranlarında damla ağırlıkları eklenmiştir. Doğrulama doğruluğu her dönemden sonra izlenerek, model doğrulama, veri setinde en iyi doğrulukla kaydedilmiştir. Test süresi boyunca DropWeights etkin kılınmıştır ve DropWeights dropout ile DropConnect'in birleşiminden oluşmaktadır (Budd et al., 2019).

- **Asimetrik Maliyet Fonksiyonu**

Bir hastaya akciğer kanseri olmadığı halde akciğer kanseri olduğuna dair bir teşhis (yanlış pozitif sonuç) koyulduğunda ortaya çıkan maliyet, hasta akciğer kanseri olduğu halde akciğer kanseri olmadığına dair bir teşhis (yanlış negatif sonuç) koyulduğunda ortaya çıkan maliyetten daha düşüktür.

Hata yapmanın asimetrik maliyeti çok yüksek olduğundan sınıf ağırlıkları gibi ağırlıkların gerçek posterioruna yaklaşmak için en uygun tahmin parametreleri uygulanmalıdır. Yani hata yapmanın bu asimetrik maliyetini ele almak için beklenen faydayı maksimize edecek bir fayda fonksiyonu ( $\alpha$ ) tanımlanmalıdır. Dolayısıyla ağırlıklı çapraz entropi kaybı işlevi Denklem 5.9'da belirtildiği şekilde ortaya çıkmaktadır:

$$L \approx \frac{1}{C} \sum_{c=1}^C \alpha_c * p(\hat{y} = c_i | w, \hat{x}) \quad (5.9)$$

Denklem 5.9'da  $\alpha_c$  çapraz entropi kaybındaki her bir sınıfa karşılık gelen ağırlıktır ve ağırlıklar üzerinden gerçek posteriora yaklaştırmak için en uygun tahminleri dikte etmektedir. En yüksek ağırlık kesin gerçekler düşük belirsizlikle doğru olduğunda, akciğer kanseri olmayan fakat enfekte olduğu için yanlış teşhis edilen bir görüntüye atanmaktadır.

Aşağıda verilen Şekil 5.24'te belirsizlik ölçeği neticesinde elde edilen sonuçlar gösterilmektedir.




**Şekil 5.24:** Belirsizlik uygulanan 4K-ESA modeline ait çıktılar

Şekil 5.24.a'da malignite ve Şekil 5.24.b'de ise benign sonuç gösterilmektedir. Bu sonuçlar tahminlere göre gruplanmış tüm test BT görüntüleri için öngörücü belirsizlik değerlerinin dağılımını göstermektedir. Tahmine dayalı dağılım ortalaması için en yüksek softmax çıktısına sahip olan sınıf, tahmini Epistemik belirsizlik olarak çıktı dağılımlarının tahmini ve öngörücü entropisi olarak kabul edilmiştir.

BT girdi görüntüsüne bağlı olarak bir ağ, tahmini posterior dağıtım ile verilen karardan yüksek veya düşük bir güvenle emin olabilir. Çıktı posterior dağılımları ne kadar genişse, model tahmininde o kadar az güvenlidir. Bunun nedeni, posterior tarafından yakalanan ağırlık uzayındaki belirsizliğin öngörücü belirsizliğe dahil edilmesidir ve bu da modelin "bilmiyorum" demesi gibi düşünülebilir.

- **Model performansı**

Bayesian 4K-ESA modelinden elde edilen sonuçlar hem YP hem de YN açısından bakıldığından umut vericidir. Aşağıda verilen Şekil 5.25'te uygulanan modellerin tahmin doğruluğunu özetleyen hata matrisi gösterilmektedir.




**Şekil 5.25:** 4K-ESA model sonuçları ve ROC eğrisi

Şekil 5.25'te Bayesian belirsizlik modeli uygulanmış mimarilerin Aleatorik ve Epistemik ile doğruluk sonuçları verilmiştir. En iyi sonuç Bayesian 4K-ESA mimarinde tespit edilmiştir. Modelin Aleatorik değeri 0.0021 iken Epistemik değeri 0.0004 olarak hesaplanmış, doğrulama oranı ise %98 olarak ölçülmüştür.


### Model Belirsizliği

Derin öğrenme modelinin öngörücü olasılıkları ile ilişkili olan Epistemik belirsizlik, test süresi boyunca düşük ağırlıklar açık tutularak ölçülmüştür. Aşağıda verilen Şekil 5.26'da bir Gauss Çekirdeği ile Kernel Yoğunluğu Tahminine ait MC seyreltme değerlerini gösterilmektedir.



**Şekil 5.26:** Doğru ve hatalı tahminlere göre gruplandırılan tüm test numuneleri için tahmin belirsizliğinin dağılımı

Şekil 5.26'da görüldüğü üzere; çalışılan modellerin, sırasıyla 0.1, 0.2, 0.3 ile bir düşüş oranı olan p varyasyonu ile elde edilen doğru ve hatalı tahminler gruplandırılmıştır. Bu da tüm BT test görüntülerinin posterior çıktı dağılımlarını çizmek için kullanıldığını göstermektedir. Ayrıca en düşük ağırlık oranındaki p değişiminin belirsizlik ölçümlerine etkisi gösterilmektedir. Bu nedenle belirsizlik bilgisi, belirsiz görüntüleri daha fazla araştırma yapılması için radyologlara yönlendirirken; nokta tahminine dair ek bir iç görüş sağlayarak genel tahmin performansını artırmaktadır. MC numunelerinin sayısı ve DropWeights oranı için değerlerden bağımsız olarak, yanlış sınıflandırma için daha yüksek bir belirsizlik gözlemlenebilir. Belirsizlik tahmini için MC seyreltme ağırlıkları, her görüntü sınıflandırıcıda kullanılabilir. Bunun amacı, genellikle birden fazla ileri geçiş gerçekleştirmenin ek hesaplama maliyetini ve insan-makine kombinasyonunun tahmin doğruluğunu belirsizliğe duyarlı yönlendirme yoluyla iyileştirmektir. Aşağıda verilen Şekil 5.27'de 4K-ESA ile Belirsizlik ölçeği uygulanmış olan BNN 4K-ESA'nın hassaslık kalitesi ve YPO oranlarına göre karşılaştırılmaları gösterilmektedir.



**Şekil 5.27:** 4K-ESA ile belirsizlik ölçeği uygulanmış olan BNN 4K-ESA'nın karşılaştırılması

Şekil 5.27'de de görüldüğü üzere; FROC ile gösterilen şemada, önerilen sistemin bir taramasındaki duyarlılığa karşı YP oranı belirtilmektedir. Test aşaması, Sigmoid fonksiyonunun uygulanmasından önce sıfırın altındaki

değerlerle eşik algılama olasılığı tekniği ile gerçekleştirilmiştir. Kırmızı renk ile gösterilen çizgi, standart bir 4K-ESA metodu ile yapılan işlemi göstermektedir. YP oranının yüksek olmasına rağmen, yeşil renk ile gösterilen çizgi ise FROC skoru ile gerçekleştirilen akciğer nodülü tespit işleminin daha başarılı olduğu saptanmıştır. 4K-ESA mimarisinde MC seyreltme hem test hem de eğitim süresinde aktif bırakılmıştır. Önerilen sistem, ortaya çıkan sonuçlara 4K-ESA MC sayesinde daha az parametre kullanarak ulaşmıştır. Sonuçlar birbirine yakın olmasına rağmen geliştirilen modelde MC seyreltmenin kullanılmasıyla daha iyi sonuç elde edildiği görülmektedir.

### **5.3 Model Sonuçlarının Başarı Değerlendirmesi**

Çizelge 5.7, uygulanan 5 farklı mimari arasındaki performansın ölçülmesini göstermektedir. Önerilen sistemler geleneksel ve yenilikçi mimarilerin farklarını açıkça ortaya koymuştur. Karşılaştırılan tüm sistemler aynı KAM veri tabanını kullanmıştır. Yenilikçi mimaride farklı BT görüntü temizleme metotları uygulanmıştır. Yapılan deneyler arasında en iyi sonuç veren mimarinin 4K-ESA mimarisi olduğu görülmektedir. Bu sonucun ortaya çıkmasında, uygulanan İA bölgesi çıkarma ve 10K çapraz doğrulama işlemlerinin payı büyüktür.

### **5.4 Belirsizliğe Duyarlı Akciğer Kanseri Sınıflandırması ve Yönlendirme Yoluyla Performans Artışı**

Tüm akciğer kanseri test görüntüleri için tahminler yapılmış ve bu tahminler, ilişkili tahmin belirsizliğine (PH) göre sıralanmıştır. Daha sonra, daha fazla teşhis için çeşitli belirsizlik seviyelerine dayalı tahminlere başvurulmuş, kalan vakalar için tahminlerin doğruluğu (0,5'te eşik) ölçülmüştür. Şekil 5.24'te gösterilen tahmin doğruluğu, belirtilen görüntülerin fraksiyonu ile artmıştır. Tahmine dayalı doğruluğu hesaplamak için yalnızca referans verilmeyen görüntüler dikkate alınmıştır. Aynı davranış, artan model belirsizliği seviyeleri için yapılan tahmin doğruluğunda da gözlemlenmiştir. Burada dikkat edilmesi gereken noktalardan biri; yeni başlayan bir radyolog açısından doğru tanı koymak için yalnızca DÖ modellerine güvenmenin genel anlamda zor olmasıdır. Bununla birlikte, deneyimli bir radyolog için (yani %80 doğruluk),

en belirsiz örneklerin neredeyse %40'ını veya  $Hnorm \geq 0,4$  olan örnekleri reddederken birleşik performans neredeyse %90'a ulaşmaktadır. Daha sonraki incelemeler için atıfta bulunulan kararların %2'sinden daha azı için, örtüşmeyen iki senaryonun %95 güven aralığı bulunmaktadır. Uygulanan belirsizlik ölçeği ile radyoloğun deneyimli ya da deneyimsiz olmasına bakılmaksızın modele güven aratacaktır.

### **5.5 Belirsizliği ve Yorumlanabilirliği Görselleştirme**

Derin öğrenme modelleri genellikle "kara kutular" olarak bilinmektedir. Bu nedenle modellerin kesin ve yorumlanabilir olması, tahminlerdeki belirsizliğin iyi anlaşılması gerekmektedir. Farklı özelliklerin görselleştirilmesinin yanı sıra güvenilir bir şekilde tahmin edilen belirsizlik, nokta tahminine ek bir iç görüş olarak, derin öğrenmede anlaşılma kolaylığını artıracak ve daha bilinçli bir karar verme süreci ile sonuçlanacaktır.

### **5.6 Deney sonucu ve karşılaştırma**

Bu çalışmada Bayesian Derin Öğrenme sınıflandırıcısı, model belirsizliğini tahmin etmek için akciğer kanseri BT görüntülerinde aktarım öğrenme yöntemi kullanılarak eğitilmiştir. Deney, model belirsizliği ile tahminin doğruluğu arasında güçlü bir ilişki olduğunu göstermiştir. Derin öğrenmedeki tahmini belirsizlik, radyologları yanlış tahminler konusunda uyarabilen daha güvenilir tahmin sağlamakta ve bu da derin öğrenmenin hastalık tespitinde klinik uygulama açısından kabulünü arttırmaktadır. Bu Bayesian Derin Öğrenme tabanlı sınıflandırmayla veri seti ve tedavi yanıtları ile ilişkili çalışmalar, görüntüleme belirteçleri hakkında iç görüşleri ve akciğer kanseri için gelişmiş tanı ve tedaviye yönelik bulguları daha da çok ortaya çıkarmaktadır. Aşağıda verilen Çizelge 5.8'te Belirsizlik (Bayesian) olmadan elde edilen sonuçlar gösterilmektedir.

**Çizelge 5.8:** Belirsizlik (Bayesian) olmadan elde edilen sonuçlar

Modeller	MCC	F2 skoru	Doğruluk	Özgüllük	Hassasiyet	F1
ResNet50	0.943	0.794	0.965	0.799	0.982	0.974
AlexNet	0.962	0.854	0.837	0.781	0.854	0.911
Inception v3	0.976	0.733	0.849	0.737	0.865	0.917
VGG16	0.941	0.801	0.826	0.795	0.869	0.903
4K-ESA MC	0.988	0.816	0.971	0.825	0.974	0.962

Çizelge 5.8’te de görüldüğü üzere; UQ (belirsizlik) uygulamadan elde edilen ölçümlerle ResNet50 modelinde MCC değeri 0.943, F2 skoru 0.794, doğruluk oranı 0.965, özgüllük 0.799, hassasiyet 0.982 ve F1 skoru ise 0.974; AlexNet modelinde MCC değeri 0.962, F2 skoru 0.854, doğruluk oranı 0.837, özgüllük 0.781, hassasiyet 0.854 ve F1 skoru ise 0.911; Inception v3 modelinde MCC değeri 0.976, F2 skoru 0.733, doğruluk oranı 0.849, özgüllük 0.737, hassasiyet 0.865 ve F1 skoru ise 0.917; VGG16 modelinde MCC değeri 0.941, F2 skoru 0.801, doğruluk oranı 0.826, özgüllük 0.795, hassasiyet 0.869 ve F1 skoru ise 0.903 ve 4K-ESA modelinde ise MCC değeri 0.988, F2 skoru 0.816, doğruluk oranı 0.971, özgüllük 0.825, hassasiyet 0.974 ve F1 skoru ise 0.962 olarak bulunmuştur.

Otomatik akciğer nodülü saptama ve sınıflandırma teknikleri, çok sayıda yanlış pozitif sonuçla yüksek algılama yeteneklerine sahiptir. Öte yandan, klinik biyobelirteçler düşük algılama kapasitesine ve yüksek özgüllüğe sahiptir. Tanı, klinik biyobelirteçlerle bağlantılı olarak otomatik BT analiz teknikleriyle yapıldığında, toplu karar yanlış pozitif sonuçların azaltılmasına yardımcı olmaktadır. Klinik kanıtların varlığında, nodüllerin tespiti malignite olasılığını artırmakta; klinik kanıt olmaksızın nodüllerin tespiti ise nihai bir karardan önce nodül morfolojisinin dikkatli bir şekilde incelenmesine yol açabilmektedir. Klinik bilgi tabanı ayrıca BT analiz teknikleriyle daha iyi kararlar almaya yardımcı olmaktadır. Akciğer kanseri tespiti için önerilen Belirsizlik (Bayesian) olmadan elde edilen sonuçlar (Bkz. Çizelge 5.7) ve Belirsizlik (Bayesian) dikkate alınarak elde edilen sonuçlar (Bkz. Çizelge 5.8); sistemin performansı, yanlış pozitif azaltma oranı, MCC, özgüllük, doğruluk ve AUC gibi çeşitli istatistiksel ölçütlere dayalı olarak değerlendirilmiştir. AUC değerleri 0,5 ile 1 arasında değişmektedir. Daha yüksek AUC değerleri, sistemin performansını önemli ölçüde etkilemektedir. İstatistiksel ölçümler, sistem performansını ölçmek için matematiksel denklemler şeklinde temsil

edilmektedir. Burada MCC, F2 skoru, doğruluk, özgüllük, hassasiyet ve f1 skoruna bakıldığında, Belirsizlik (Bayesian) ile elde edilen sonuçlar 4K-ESA MC açısından daha umut vericidir. Diğer geleneksel modellerde her ne kadar belirsizlik kullanılsa da MC seyreltme uygulanmamıştır. Aşağıda verilen Çizelge 5.9’da Belirsizlik (Bayesian) ile elde edilen sonuçlar gösterilmektedir.

**Çizelge 5.9:** Belirsizlik (Bayesian) ile elde edilen sonuçlar

Modeller	MCC	F2 skoru	Doğruluk	Özgüllük	Hassasiyet	F1
BNN ResNet50	0.91	0.87	0.89	0.81	0.85	0.81
BNN AlexNet	0.89	0.81	0.86	0.78	0.83	0.85
BNN Inception v3	0.94	0.89	0.91	0.79	0.94	0.88
BNN VGG16	0.83	0.85	0.77	0.74	0.84	0.90
BNN 4K-ESA	0.98	0.88	0.98	0.94	0.97	0.96

Çizelge 5.9’da görüldüğü üzere; UQ (belirsizlik) uygulanarak elde edilen ölçümlerle (modellere belirsizlik eklendiğinde ) BNN ResNet50 modelinde MCC değeri 0.91, F2 skoru 0.87, doğruluk oranı 0.89, özgüllük 0.81, hassasiyet 0.85 ve F1 skoru ise 0,81; BNN AlexNet modelinde MCC değeri 0.89, F2 skoru 0.81, doğruluk oranı 0.86, özgüllük 0.78, hassasiyet 0.83 ve F1 skoru ise 0,85; BNN Inception v3 modelinde MCC değeri 0.94, F2 skoru 0.89, doğruluk oranı 0.91, özgüllük 0.79, hassasiyet 0.94 ve F1 skoru ise 0,88; BNN VGG16 modelinde MCC değeri 0.83, F2 skoru 0.85, doğruluk oranı 0.77, özgüllük 0.74, hassasiyet 0.84 ve F1 skoru ise 0.90 ve BNN 4K-ESA MC modelinde ise MCC değeri 0.98, F2 skoru 0.88, doğruluk oranı 0.98, özgüllük 0.94, hassasiyet 0.97 ve F1 skoru ise 0,96 olarak bulunmuştur.


Aşağıda verilen Çizelge 5.10’da çalışma kapsamında kullanılan tüm modellerin özellikleri gösterilmektedir.

**Çizelge 5.10:** Kullanılan modellerin özellikleri

Model	Katman sayısı	Filtre boyutu	Parametre (milyon)	Konfigürasyon	Eğitim süresi
AlexNet	8	11x11	60	GT75	6 gün
VGGNet	19	3x3	138	Titan	3 hafta
Inception	22	5x5	5	4K-071	2 hafta
ResNet	152	3x3	60”	GTX 8G, 32GB	3 hafta
4K-ESA MC	4	3X3	60	4TB SSD	3 hafta




Çizelge 5.10’da görüldüğü üzere; nodüllerin içyapılarını daha iyi öğrenebilmek açısından daha fazla evrişimli katman eklenmiştir. Bu 3B ağları eğitmek hem zaman hem de GPU gücü gerektirmektedir. Söz konusu gereksinimlerin karşılanmasıyla daha karmaşık mimariler denenebilir. Ayrıca, evrişimli katmanda 3x5x5 filtre boyutu kullanılmış, 7x7x7 gibi daha büyük boyutlar kullanılarak veya art arda 1x1x1 gibi daha küçük boyutlu filtreler kullanılarak, bu filtreler nodüller üzerinde daha büyük veya belirli özellikleri yakalayabileceğinden performans artırılabilir. Aşağıda verilen Şekil 5.28’de çalışma kapsamında kullanılan belirsizlik ölçeği eklenmemiş tüm modellere ait eğitim, test çalışma süresi ve başarı performansları gösterilmektedir.



**Şekil 5.28:** Belirsizlik ölçeği eklenmeden modellere ait çalışma ve başarı süreleri. Şekil 5.28’de de görüldüğü üzere; en uzun çalışma süresi 00:06:48 sn. olarak hesaplanmıştır. Dolayısıyla model eğitimi için harcanan en azami süre AlexNet mimarisine aittir. Oysa daha verimli olan 4K-ESA mimarisinin çalışma süresi 00:03:21sn sürmüştür. Böylece 4K-ESA’nın en hızlı (4 Katman olduğundan) model olduğu yapılan testler sonucunda anlaşılmıştır. Ek olarak, 4K-ESA’nın test çalışma süresi AlexNet ve Inception v3’e kıyasla 2 kat daha hızlıdır; dolayısıyla bu, BT görüntülerinde tanı sonuçları daha hızlı döndürülebildiğinden klinikler için daha kullanışlıdır.

Aşağıda verilen Şekil 5.29’da çalışma kapsamında kullanılan belirsizlik ölçeği eklenmiş tüm modellere ait eğitim, test çalışma süresi ve başarı performansları gösterilmektedir.



**Şekil 5.29:** Belirsizlik ölçeği ile çalışılan modellere ait çalışma ve başarı süreleri

Şekil 5.29’da da görüldüğü üzere; en uzun çalışma süresi 00:08:49 sn. olarak hesaplanmıştır. Dolayısıyla model eğitimi için harcanan en azami süre BNN AlexNet mimarisine aittir. Fakat daha verimli olan BNN 4K-ESA mimarisinin çalışma süresi 00:04:01 sn. sürmüştür. Böylece BNN 4K-ESA’nın en hızlı model olduğu yapılan testler sonucunda anlaşılmıştır.

## 6. SONUÇLAR VE TARTIŞMA

Kanser, vücudun her bölümüne kan damarları veya lenfatik sistemler aracılığıyla yayılabilen bir hastalık türüdür. Bilinen 200'den fazla kanser türünün insanları etkilediği ifade edilmektedir. Söz konusu bilinen kanser türleri arasındaysa en ölümcül olanı akciğer kanseridir. Sağlıklı bir akciğer dokusunun yapısında bulunan bazı hücrelerin, ihtiyaç dışı ve kontrol edilemez bir biçimde çoğalmasıyla akciğerin içinde normal olmayan kitleler oluşmakta ve böylece akciğer kanseri oluşmaya başlamaktadır. Akciğer kanserini, semptom ve bulguların takip edilmesiyle teşhis ve tedavi etmek oldukça önemlidir. Ancak hastalığın hangi aşamada olduğuna bağlı olarak, örneğin hastalık başka organlara da yayılmışsa, semptomlarda farklılıklar görülebilir. Fakat hastalığa ilişkin herhangi bir semptom görülmediğinde, elde edilmiş bir bulgu olmadığı için hekimler tarafından yapılan fiziksel muayene sırasında hastalık gözden kaçırılabilir. Dolayısıyla bu gibi durumların yaşanmaması için hastalığın tanısında Manyetik Rezonans Görüntüleme (MR), BT vb. tekniklerin kullanılmasıyla akciğer bölgesinin ayrıntılı olarak görüntülenmesi oldukça önemlidir. Bu yöntemler sayesinde her yıl yüz binlerce can kurtarılabilmesi amacıyla kanser hastalığı erken safhada tespit edilebilmektedir. Fakat söz konusu bu yüz binlerce hastaya ait taramaların analiz edilmesi radyologlar açısından zaman ve emek gerektiren ciddi bir iş yüküdür. Çok sayıda radyoloğun zaman ve yoğun emek gerektiren bu ciddi iş yükünün neden olduğu gözlemci yorgunluğu sebebiyle performansları da olumsuz şekilde etkilenmektedir. Dolayısıyla BT taramalarının daha verimli şekilde okunarak saptanması ve değerlendirilmesi amacıyla bir sisteme gereksinim duyulmaktadır.

Çalışma kapsamında bu gereksinimden hareketle; DÖ ve ÖA yöntemlerine dayalı olarak 4K-ESA modeli geliştirilmiştir. Geliştirilen 4K-ESA modelinin geleneksel modellerden (AlexNet, MobileNet vb.) öncelikli farkı; 4 katmanlı olması sebebiyle bilgisayara fazla yük getirmemesi ve seyreltme tekniği yerine

DropWeights tekniğini kullanmasıdır. Çünkü geleneksel modeller çok katmanlı ve çok parametrelili yapılaraya sahip olmaları sebebiyle yanlış hata oranlıları oldukça yüksek olan modellerdir. Ayrıca geliştirilen 4K-ESA modeli geleneksel yöntemlerin (ImageNet gibi) aksine, BT görüntülerini işlemeye uygun ince ayarlar yapılarak hazırlanması ve fazla yük ve parametrelerden arındırılmış olması sebebiyle yalnızca bir konuya yönelerek veriyi 00:03:21sn (Bkz: Şekil 5.28) gibi bir sürede işleyebilmektedir. Geliştirilen 4K-ESA yönteminin yanı sıra çalışma kapsamında geliştirilen ikinci yöntem ise 4K-ESA üzerine UQ eklenmesiyle oluşturulan BNN 4K-ESA modelidir. Geliştirilen BNN 4K-ESA modeli sayesinde ise 4K-ESA modelinden elde edilen sonuçlar güven ölçeğine tabi tutulmaktadır. Ayrıca BNN 4K-ESA modeli sayesinde hangi katmanlarda hata yapıldığının sebebi açıkça görülmektedir.

Geliştirilen model sırasıyla; ön işlem, sınıflandırma, belirsizlik ölçeğinin uygulanması ve karar verme olmak üzere temel olarak dört adımdan oluşmaktadır. Ön işlem adımında, verinin %80'i eğitim, %10'u test ve geriye kalan %10'u ise doğrulama için kullanılmaktadır. KAM merkezinden alınan 639598 BT görüntüsü dikkatlice ön işleme tabi tutularak; her bir taramada kaç dilim bulunduğu, iki ardışık dilim arasındaki mesafeler ve aynı düzlemde bulunan iki voksel arasındaki gerçek dünya boyutlarıyla ilgili işlemler yapılmıştır. Daha sonra histogram, optimal eşikleme, otsu yöntemi, kenar belirleme, gri seviyeli görüntü, negatif görüntü, Gaussian filtresi, ortalama filtresi ve görüntünün bölünüp döndürülmesine ilişkin işlemler yapılmıştır. Bu işlemler neticesinde bütün BT taramaları yeniden ölçeklendirilip, mini-paket veya orta boy paket (yama boyutları) olup olmadıkları belirlendikten sonra çalışmada kullanılan tüm modellere (AlexNet, Inception v3, ResNet, VGG16 ve 4K-ESA) girdi değişkenleri olarak verilmiştir. Böylece bu adımda, farklı hacimsel boyutların eğitim ve test performanslarını nasıl etkilediği belirlenmiştir. Bu belirleme neticesinde toplam 4997 mini-paket şeklinde verilen girdilerin çalışmada kullanılan tüm modellerin performansları üzerinde etkili olduğu belirlenmiştir. Bu adımda elde edilen sonuçtan hareketle; verilerin mini-paket şeklinde verilmesinin bütün modellerin performanslarını olumlu yönde etkilediği kanıtlanmıştır. Örneğin; AlexNet'e 1024 mini-paket

şeklinde veri verildiğinde modelin çalışmayı 21 günde tamamlayabildiği gözlemlenmiştir (Bkz: Şekil 5.28). Önileme aşamasından hemen sonra ise elde edilen görüntüler üzerine ADD işlemi yapılarak görüntülerin öznelik çıkarımları gerçekleştirilmiştir.

Sınıflandırma adımında; iki aşamalı olarak gerek geleneksel modellere gerekse geliştirilen modele veriler sıralıyla mini-paket halinde verilmiştir. Geleneksel modeller için başlangıç olarak 128 mini-paket boyutu ile veriler beslendikten sonra, dropout değerleri 0.2 seçilerek farklı değerler ile bu işleme devam edilmiştir. Daha sonra öğrenme oranları 0.01, 0.002 ve 0.0001 şeklinde değişik değerler ile denenerek aktivasyon fonksiyonları tanh, sigmoid ve ReLU olarak girilmiştir. Bu tez kapsamında Geliştirilen model olan 4K-ESA modelinde ise seyreltme olarak DropWeights, aktivasyon fonksiyonu olarak da softmax denenmiştir. Böylece modellere girdi olarak verilen BT görüntülerinin kanserli olup olmadığı, kanserli ise bunun iyi mi yoksa kötü huylu mu oldukları belirlenmiştir.

Belirsizlik ölçeğinin uygulanması adımında; öncelikle geleneksel modellere BNN UQ, geliştirilen modele ise BNN UQ ve MCS eklenerek modeller çalıştırılmıştır. Geleneksel modellere eklenen BNN UQ ile anlamlı, güvenli sonuçlar elde edilmiştir. Fakat makine konfigürasyonunun sınırlı olması sebebiyle parametre sayılarının yüksek oluşu 4K-ESA'ya göre geleneksel modellerin daha düşük performans sergilemelerine neden olmuştur. Dolayısıyla çalıştırılan modeller arasında en iyi sonuç veren modelin, parametre sayıları geleneksel modellere göre daha düşük olan 4K-ESA modeli olduğu görülmüştür. Bu sonucun ortaya çıkmasında, modele uygulanan MCS ve DropWeights tekniklerinin payı oldukça büyüktür.

Karar verme adımında ise; UQ eklenmeden yapılan deneyler sonucunda (I) ResNet50 modelinin MCC değeri 0.943, F2 skoru 0.794, doğruluk oranı 0.965, özgüllük 0.799, hassasiyet 0.982 ve F1 skoru 0.974; (II) AlexNet modelinin MCC değeri 0.962, F2 skoru 0.854, doğruluk oranı 0.837, özgüllük 0.781, hassasiyet 0.854 ve F1 skoru, 0.911; (III) Inception v3 modelinin MCC değeri 0.976, F2 skoru 0.733, doğruluk oranı 0.849, özgüllük 0.737, hassasiyet 0.865 ve F1 skoru 0.917; (IV) VGG16 modelinin MCC değeri 0.941, F2 skoru 0.801, doğruluk oranı 0.826, özgüllük 0.795, hassasiyet

0.869 ve F1 skoru 0.903 ve (V) 4K-ESA modelinin MCC değeri 0.988, F2 skoru 0.816, doğruluk oranı 0.971, özgüllük 0.825, hassasiyet 0.974 ve F1 skoru ise 0.962 olarak bulunmuştur.

UQ eklenerek yapılan deneyler sonucunda ise; BNN ResNet50 modelinin MCC değeri 0.91, F2 skoru 0.87, doğruluk oranı 0.89, özgüllük 0.81, hassasiyet 0.85 ve F1 skoru 0,81; BNN AlexNet modelinin MCC değeri 0. 89, F2 skoru 0. 81, doğruluk oranı 0.86, özgüllük 0.78, hassasiyet 0.83 ve F1 skoru 0,85; BNN Inception v3 modelinin MCC değeri 0.94, F2 skoru 0.89, doğruluk oranı 0.91, özgüllük 0.79, hassasiyet 0.94 ve F1 skoru 0,88; BNN VGG16 modelinin MCC değeri 0.83, F2 skoru 0.85, doğruluk oranı 0.77, özgüllük 0.74, hassasiyet 0.84 ve F1 skoru 0.90 ve BNN 4K-ESA MC modelinin MCC değeri 0.98, F2 skoru 0.88, doğruluk oranı 0.98, özgüllük 0.94, hassasiyet 0.97 ve F1 skoru ise 0,96 olarak bulunmuştur.

Deneylerin sonucunda belirsizlik Tahmini Entropisi ve UYBNN oranları %90 olarak bulunmuştur. Bu oran sayesinde akciğer hastalıklarının tespiti için DÖ'nün klinik uygulamalar açısından kabulünün sağlanabileceği düşünülmektedir.

Shen, Han, Aberle, Bui ve Hsu (2019) tarafından nodülün malignite olup olmadığının teşhis edilebilmesi ve nodülde bulunan anlamsal özelliklere dair tahminlerin ortaya çıkarılabilmesini amaçlayan bir ağ (Hiyerarşik Anlamsal ESA) geliştirilmiştir. Fakat geliştirdikleri modeli eğitirken; yalnızca LIDC-IDRI veri kümesini kullanarak geleneksel ESA'ya bağlı kalmaları sebebiyle modelleri başarısızlığa uğramıştır.

Dolayısıyla geliştirdikleri modelde belirsizlik ölçeğinin kullanılmayışı, kullanılan veri kümesinin çok küçük olması sebebiyle ağ öğrenimini sınırlayabilecek olması gibi sebeplerden hareketle; bu çalışma kapsamında geliştirilen 4K-ESA ve BNN 4K-ESA modellerinin Shen vd. tarafından geliştirilen Hiyerarşik Anlamsal ESA modeline göre daha avantajlı olduğu belirtilebilir.

Bu çalışma kapsamında geliştirilen 4K-ESA ve BNN 4K-ESA modellerinin akciğer kanserinin teşhisi aşamasında meydana gelen güven sorununu, teşhis aşamasında DÖ algoritmalarının rahatlıkla kullanabilmesiyle ortadan

kaldıracağı düşünülmektedir. Ayrıca radyologlar açısından oldukça önemli olan nodül tespiti ve akciğer BT görüntülerinin sınıflandırılması hususunda meydana sorunlarında geliştirilen bu yöntem sayesinde ortadan kaldırılabilceđi düşünülmektedir.

Bu çalışma kapsamında geliştirilen modellerin, gelecek çalışmalarda kanserli dokuların bulunduđu yerin tespit edilebilmesi açısından bir ön adım niteliğinde olduđu düşünülmektedir. Geliştirilen modellerin tek sınırlı yanı, çalışmada yerel (ulusal) veri kaynağının bulunmamasıdır. Ulusal akciğer BT taraması bulunduğunda çalışma kapsamında geliştirilen modeller söz konusu ulusal veriler üzerinde de denenebilir. Geliştirilen modellerin, diđer hastalık sınıflandırmaları ve farklı görüntüleme yöntemlerinde de kullanılabileceđi öngörülmektedir.





## KAYNAKLAR

- Agostinelli, F., Hoffman, M., Sadowski, P., & Baldi, P. (2014).** "Learning activation functions to improve deep neural networks", *arXiv preprint arXiv:1412.6830*.
- Al-Tarawneh, M. S. (2012).** "Lung cancer detection using image processing techniques", *Leonardo Electronic Journal of Practices and Technologies*, 11(21), 147-158.
- Alakwaa, W., Nassef, M., & Badr, A. (2017).** "Lung cancer detection and classification with 3D convolutional neural network (3D-CNN)", *Lung Cancer*, 8(8), 409.
- Alifax, K., & Scotta, N. (1997).** "An introduction to wavelet theory and its applications in statistics", Dalhousie University.
- Ardila, D., Kiraly, A. P., Bharadwaj, S., Choi, B., Reicher, J. J., Peng, L., Tse, D., Etemadi, M., Ye, W., & Corrado, G. (2019).** "End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography", *Nature medicine*, 25(6), 954-961.
- Avanzo, M., Stancanello, J., Pirrone, G., & Sartor, G. (2020).** "Radiomics and deep learning in lung cancer. *Strahlentherapie und Onkologie*", 1-9.
- Aydın, F., & Aslan, Z. (2017).** "Yapay öğrenme yöntemleri ve dalgacık dönüşümü kullanılarak nöro dejeneratif hastalıkların teşhisi", *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 32(3)
- Ayub, A., Rehmani, S. S., Al-Ayoubi, A. M., Raad, W., Flores, R. M., & Bhora, F. Y. (2017).** "Pulmonary resection for second lung cancer after pneumonectomy: a population-based study", *The Annals of thoracic surgery*, 104(4), 1131-1137.
- Basiri, M. E., Abdar, M., Cifci, M. A., Nemati, S., & Acharya, U. R. (2020).** "A novel method for sentiment classification of drug reviews using fusion of deep and machine learning techniques", *Knowledge-Based Systems*, 198, 105949.
- Bhatia, S., Sinha, Y., & Goel, L. (2019).** "Lung cancer detection: a deep learning approach", In *Soft Computing for Problem Solving* (pp. 699-705). Springer.
- Bottou, L. (1991).** "Stochastic gradient learning in neural networks", *Proceedings of Neuro-Nimes*, 91(8), 12.
- Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R. L., Torre, L. A., & Jemal, A. (2018).** "Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries", *CA: a cancer journal for clinicians*, 68(6), 394-424.
- Budd, S., Sinclair, M., Khanal, B., Matthew, J., Lloyd, D., Gomez, A., Toussaint, N., Robinson, E. C., & Kainz, B. (2019).** "Confident head circumference measurement from ultrasound with real-time feedback for sonographers", International Conference on Medical Image Computing and Computer-Assisted Intervention,
- Burkov, A. (2019).** "*The hundred-page machine learning book* (Vol. 1)", Andriy

Burkov Canada.

- Celeng, C., Takx, R. A., Lessmann, N., Maurovich-Horvat, P., Leiner, T., Iřgum, I., & De Jong, P. A.** (2020). "The association between marital status, coronary computed tomography imaging biomarkers, and mortality in a lung cancer screening population", *Journal of thoracic imaging*, 35(3), 204-209.
- Chakraborty, A., & Goswami, D.** (2017). "Prediction of slope stability using multiple linear regression (MLR) and artificial neural network (ANN)", *Arabian Journal of Geosciences*, 10(17), 1-11.
- Chen, J., & Shen, Y.** (2017). "The effect of kernel size of CNNs for lung nodule classification", 2017 9th international conference on advanced infocomm technology (ICAIT),
- Choe, J., Lee, S. M., Do, K.-H., Lee, G., Lee, J.-G., Lee, S. M., & Seo, J. B.** (2019). "Deep learning–based image conversion of CT reconstruction kernels improves radiomics reproducibility for pulmonary nodules or masses", *Radiology*, 292(2), 365-373.
- Choi, H., Ryu, S., & Kim, H.** (2018). "Short-term load forecasting based on ResNet and LSTM", 2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm),
- Cifci, M. A., & Aslan, Z.** (2020). "Deep Learning Algorithms for Diagnosis of Breast Cancer with Maximum Likelihood Estimation", International Conference on Computational Science and Its Applications.
- Da Fonseca, J. B.** (2013). "Are Rosenblatt multilayer perceptrons more powerful than sigmoidal multilayer perceptrons? From a counter example to a general result", ESANN.
- Daubechies, I.** (1988). "Orthonormal bases of compactly supported wavelets", *Communications on pure and applied mathematics*, 41(7), 909-996.
- Dean, J.** (2020). "1.1 the deep learning revolution and its implications for computer architecture and chip design", 2020 IEEE International Solid-State Circuits Conference-(ISSCC),
- Dey, R., Lu, Z., & Hong, Y.** (2018). "Diagnostic classification of lung nodules using 3D neural networks", 2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018),
- Ding, J., Li, A., Hu, Z., & Wang, L.** (2017). "Accurate pulmonary nodule detection in computed tomography images using deep convolutional neural networks", International Conference on Medical Image Computing and Computer-Assisted Intervention,
- Du, J.** (2019). "The frontier of SGD and its variants in machine learning. Journal of Physics", Conference Series,
- Durmuş, S.** (2020). "Akciğer kanserli hastalarda pulmoner tromboemboli sıklığı, risk faktörleri (yaş, cinsiyet, trombosit düzeyleri, d-dimer, kanser tipi) ve evre ile ilişkisi", Acikerisim.pau.
- Gaber, M., Bakheet, R. A. E.-A., & Mahmoud, F. I.** (2017). "Risk factors of cancer and how to prevent", *Sohag Medical Journal*, 21(2), 179-183.
- Gong, J., Liu, J., Hao, W., Nie, S., Zheng, B., Wang, S., & Peng, W.** (2019). "A deep residual learning network for predicting lung adenocarcinoma manifesting as ground-glass nodule on CT images", *European radiology*, 1-9.
- Goodwin, J. S., Nishi, S., Zhou, J., & Kuo, Y.-F.** (2019). "Use of the shared

- decision-making visit for lung cancer screening among Medicare enrollees", *JAMA internal medicine*, 179(5), 716-718.
- Heigener, D. F., & Reck, M.** (2018). "Advanced non-small cell lung cancer: the role of PD-L1 inhibitors", *Journal of thoracic disease*, 10(Suppl 13), S1468.
- Hoffer, E., Hubara, I., & Soudry, D.** (2017). "Train longer, generalize better: closing the generalization gap in large batch training of neural networks", *arXiv preprint arXiv:1705.08741*.
- Jain, R., Nagrath, P., Kataria, G., Kaushik, V. S., & Hemanth, D. J.** (2020). "Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning", *Measurement*, 165, 108046.
- Jiang, Y., Xie, J., Han, Z., Liu, W., Xi, S., Huang, L., Huang, W., Lin, T., Zhao, L., & Hu, Y.** (2018). "Immunomarker support vector machine classifier for prediction of gastric cancer survival and adjuvant chemotherapeutic benefit", *Clinical Cancer Research*, 24(22), 5574-5584.
- Jye Kho, S., Yalamanchili, H., Raymer, M. L., & Sheth, A. P.** (2017). "A Novel Approach for Classifying Gene Expression Data using Topic Modeling".
- Jyotiyana, M., & Kesswani, N.** (2020). "Classification and prediction of Alzheimer's disease using multi-layer perceptron", *International Journal of Reasoning-based Intelligent Systems*, 12(4), 255-263.
- Kaur, P., & Bhatia, R.** (2017). "A Review on Lung Cancer Detection Using PET/CT Scan", *International Journal*, 7(5).
- Keller, J. M., Liu, D., & Fogel, D. B.** (2016). "Fundamentals of computational intelligence: Neural networks, fuzzy systems, and evolutionary computation", John Wiley & Sons.
- Klang, E.** (2018). "Deep learning and medical imaging", *Journal of thoracic disease*, 10(3), 1325.
- Kozłowski, B.** (2005). "Time series denoising with wavelet transform", *Journal of Telecommunications and Information Technology*, 91-95.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2017). "ImageNet classification with deep convolutional neural networks", *Communications of the ACM*, 60(6), 84-90.
- Kumar, D., Wong, A., & Clausi, D. A.** (2015). "Lung nodule classification using deep features in CT images", 2015 12th Conference on Computer and Robot Vision,
- Lakshmanaprabu, S., Mohanty, S. N., Shankar, K., Arunkumar, N., & Ramirez, G.** (2019). "Optimal deep learning model for classification of lung cancer on CT images", *Future Generation Computer Systems*, 92, 374-382.
- Levine, Z. H., Peskin, A. P., Holmgren, A. D., & Garboczi, E. J.** (2018). "Preliminary X-ray CT investigation to link Hounsfield unit measurements with the International System of Units (SI)", *Plos one*, 13(12), e0208820.
- Li, C., Zhang, L., Meng, G., Wang, Q., Lv, X., Zhang, J., & Li, J.** (2019). "Circular RNAs: pivotal molecular regulators and novel diagnostic and prognostic biomarkers in non-small cell lung cancer", *Journal of cancer research and clinical oncology*, 145(12), 2875-2889.
- Li, F., Huang, H., Wu, Y., Cai, C., Huang, Y., & Ding, X.** (2019). "Lung nodule detection with a 3d convnet via iou self-normalization and maxout unit", ICASSP 2019-2019 IEEE International Conference on Acoustics,

- Speech and Signal Processing (ICASSP),
- Liao, F., Liang, M., Li, Z., Hu, X., & Song, S.** (2019). "Evaluate the malignancy of pulmonary nodules using the 3-d deep leaky noisy-or network", *IEEE transactions on neural networks and learning systems*, 30(11), 3484-3495.
- Lima, L. L., Ferreira Junior, J. R., & Oliveira, M. C.** (2020). "Toward classifying small lung nodules with hyperparameter optimization of convolutional neural networks", *Computational Intelligence*.
- Liu, F., Liu, D., Tian, J., Xie, X., Yang, X., & Wang, K.** (2020). "Cascaded one-shot deformable convolutional neural networks: Developing a deep learning model for respiratory motion estimation in ultrasound sequences", *Medical Image Analysis*, 65, 101793.
- Luo, P., Wang, X., Shao, W., & Peng, Z.** (2018). "Towards understanding regularization in batch normalization", *arXiv preprint arXiv:1809.00846*.
- Mesleh, A. M.** (2017). "Lung Cancer Detection Using Multi-Layer Neural Networks with Independent Component Analysis: A Comparative Study of Training Algorithms", *Jordan Journal of Biological Sciences*, 10(4).
- Minsky, M., & Papert, S. A.** (2017). "Perceptrons: An introduction to computational geometry", MIT press.
- Miranda-Filho, A., Piñeros, M., & Bray, F.** (2020). "The descriptive epidemiology of lung cancer and tobacco control: a global overview 2018", *salud pública de méxico*, 61, 219-229.
- Mirsky, Y., Mahler, T., Shelef, I., & Elovici, Y.** (2019). "CT-GAN: Malicious tampering of 3D medical imagery using deep learning", 28th {USENIX} Security Symposium ({USENIX} Security 19),
- Nason, G. P., & Silverman, B. W.** (1994). "The discrete wavelet transform in S", *Journal of Computational and Graphical statistics*, 3(2), 163-191.
- National Lung Screening Trial Research Team.** (2019). "Lung cancer incidence and mortality with extended follow-up in the national lung screening trial", *Journal of Thoracic Oncology*, 14(10), 1732-1742.
- Nizam, A., & Korürek, M.** (2011). "Karıncı koloni optimizasyonuna dayalı yeni bir aritmi sınıflama tekniği", *İtühergisi/d*, 10(1).
- Nlst, N.** (2015). "National Lung Screening Trial- National Lung Screening Trial Public Access", *Cancer Imaging Archive Wiki*. Retrieved 5 February 2020, from <https://wiki.cancerimagingarchive.net/display/NLST/National+Lung+Screening+Trial#5800702cca39708a07d4cfa8e4685bcf6002070>
- Pandiangan, T., Bali, I., & Silalahi, A.** (2019). "Early lung cancer detection using artificial neural network", *Atom Indonesia*, 45(1), 9-15.
- Pati, S. P., Pattanaik, P., & Kamilla, S.** (2020). "mHealth (Mobile health) An Advanced Option for Assessment of Human health", *European Journal of Molecular & Clinical Medicine*, 7(6), 1279-1291.
- Ramos, R., Valdez-Salas, B., Zlatev, R., Schorr Wiener, M., & Bastidas Rull, J. M.** (2017). "The discrete wavelet transform and its application for noise removal in localized corrosion measurements", *International Journal of Corrosion*, 2017.
- Rawat, A., Singh, A., & Kumar, G.** (2018). "Emerging role of EGFR and lung cancer treatments", *MOJ Anat & Physiol*, 5(5), 281-282.
- Romme, E. A., Murchison, J. T., Phang, K. F., Jansen, F. H., Rutten, E. P., Wouters, E. F., Smeenk, F. W., Van Beek, E. J., & Macnee, W.**

- (2012). "Bone attenuation on routine chest CT correlates with bone mineral density on DXA in patients with COPD", *Journal of Bone and Mineral Research*, 27(11), 2338-2343.
- Rossetto, A. M., & Zhou, W.** (2019). "Improving classification with CNNs using wavelet pooling with Nesterov-accelerated Adam", Proc. 11th Int. Conf. Bioinf. and Comput. Biol,
- Sajja, T., Devarapalli, R., & Kalluri, H.** (2019). "Lung Cancer Detection Based on CT Scan Images by Using Deep Transfer Learning", *Traitement du Signal*, 36(4), 339-344.
- Salaken, S. M., Khosravi, A., Khatami, A., Nahavandi, S., & Hosen, M. A.** (2017). "Lung cancer classification using deep learned features on low population dataset", 2017 IEEE 30th Canadian Conference on Electrical and Computer Engineering (CCECE),
- Saravanan, N., & Ramachandran, K.** (2010). "Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN)", *Expert Systems with Applications*, 37(6), 4168-4181.
- Shaffie, A., Soliman, A., Fraiwan, L., Ghazal, M., Taher, F., Dunlap, N., Wang, B., Van Berkel, V., Keynton, R., & Elmaghraby, A.** (2018). "A generalized deep learning-based diagnostic system for early diagnosis of various types of pulmonary nodules", *Technology in cancer research & treatment*, 17, 1533033818798800.
- Shankar, V.** (2004). "Texture-Based Automated Lithological Classification Using Aeromagnetic Anomaly Images Citeseer".
- Sharma, S.** (2017). "Activation functions in neural networks", *towards data science*, 6.
- Shen, S., Han, S. X., Aberle, D. R., Bui, A. A., & Hsu, W.** (2019). "An interpretable deep hierarchical semantic convolutional neural network for lung nodule malignancy classification", *Expert systems with applications*, 128, 84-95.
- Sibi, P., Jones, S. A., & Siddarth, P.** (2013). "Analysis of different activation functions using back propagation neural networks", *Journal of theoretical and applied information technology*, 47(3), 1264-1268.
- Skourt, B. A., El Hassani, A., & Majda, A.** (2018). "Lung CT image segmentation using deep neural networks", *Procedia Computer Science*, 127, 109-113.
- Song, Q., ZHAO, L., LUO, X., & DOU, X.** (2017). "Using deep learning for classification of lung nodules on computed tomography images", *Journal of healthcare engineering*, 2017.
- Stanković, R. S., & Falkowski, B. J.** (2003). "The Haar wavelet transform: its status and achievements", *Computers & Electrical Engineering*, 29(1), 25-44.
- Steinbichler, T. B., Dudás, J., Skvortsov, S., Ganswindt, U., Riechelmann, H., & Skvortsova, I.-I.** (2018). "Therapy resistance mediated by cancer stem cells", *Seminars in cancer biology*,
- Sun, W., Zheng, B., & Qian, W.** (2017). "Automatic feature learning using multichannel ROI based on deep structured algorithms for computerized lung cancer diagnosis", *Computers in biology and medicine*, 89, 530-539.
- Tang, J., Deng, C., & Huang, G.-B.** (2015). "Extreme learning machine for multilayer perceptron", *IEEE transactions on neural networks and*

*learning systems*, 27(4), 809-821.

- Teramoto, A., Yamada, A., Kiriya, Y., Tsukamoto, T., Yan, K., Zhang, L., Imaizumi, K., Saito, K., & Fujita, H.** (2019). "Automated classification of benign and malignant cells from lung cytological images using deep convolutional neural network", *Informatics in Medicine Unlocked*, 16, 100205.
- Türkçetin, A. Ö., Bayrakçı, H. C., Danişman, I., & Aksoy, Ö. Ü. B.** (2019). Akciğer kanserinin tespit edilmesinde derin öğrenme algoritmalarının kullanılması.
- Wang, H., Zhou, Z., Li, Y., Chen, Z., Lu, P., Wang, W., Liu, W., & Yu, L.** (2017). "Comparison of machine learning methods for classifying mediastinal lymph node metastasis of non-small cell lung cancer from 18 F-FDG PET/CT images", *EJNMMI research*, 7(1), 1-11.
- Wang, S., Liu, Z., Chen, X., Zhu, Y., Zhou, H., Tang, Z., Wei, W., Dong, D., Wang, M., & Tian, J.** (2018). "Unsupervised deep learning features for lung cancer overall survival analysis", 2018 40th Annual international conference of the IEEE engineering in medicine and biology society (EMBC),
- Wang, Y., Zhang, H., Chae, K. J., Choi, Y., Jin, G. Y., & Ko, S.-B.** (2020). "Novel convolutional neural network architecture for improved pulmonary nodule classification on computed tomography", *Multidimensional Systems and Signal Processing*, 31(3), 1163-1183.
- Wani, S. H., & Lone, S. A.** (2018). "*Cancer: Diseases*", Education Publishing.
- Weng, S., Xu, X., Li, J., & Wong, S. T.** (2017). "Combining deep learning and coherent anti-Stokes Raman scattering imaging for automated differential diagnosis of lung cancer", *Journal of biomedical optics*, 22(10), 106017.
- Xie, Y., Xia, Y., Zhang, J., Song, Y., Feng, D., Fulham, M., & Cai, W.** (2018). "Knowledge-based collaborative deep learning for benign-malignant lung nodule classification on chest CT", *IEEE transactions on medical imaging*, 38(4), 991-1004.
- Yip, R., Li, K., Liu, L., Xu, D., Tam, K., Yankelevitz, D. F., Taioli, E., Becker, B., & Henschke, C. I.** (2018). "Controversies on lung cancers manifesting as part-solid nodules", *European radiology*, 28(2), 747-759.
- Yoshida, Y., & Miyato, T.** (2017). "Spectral norm regularization for improving the generalizability of deep learning", *arXiv preprint arXiv:1705.10941*.
- Zahra, N. E., Sevindir, H. K., Aslan, Z., & Siddiqi, A.** (2012). "Wavelets in medical imaging",. AIP Conference Proceedings,
- Zhang, Y., Ng, P. K.-S., Kucherlapati, M., Chen, F., Liu, Y., Tsang, Y. H., De Velasco, G., Jeong, K. J., Akbani, R., & Hadjipanayis, A.** (2017). "A pan-cancer proteogenomic atlas of PI3K/AKT/mTOR pathway alterations", *Cancer cell*, 31(6), 820-832. e823.

## **EKLER**

**EK A:** Veri ve Yöntem

**EK B:** Analiz ve Uygulama

**EK C:** Analiz ve Uygulama






## EK A: Veri ve Yöntem

**Çizelge A.1:** Deneylerde kullanılan fonksiyon öğrenme algoritmaları

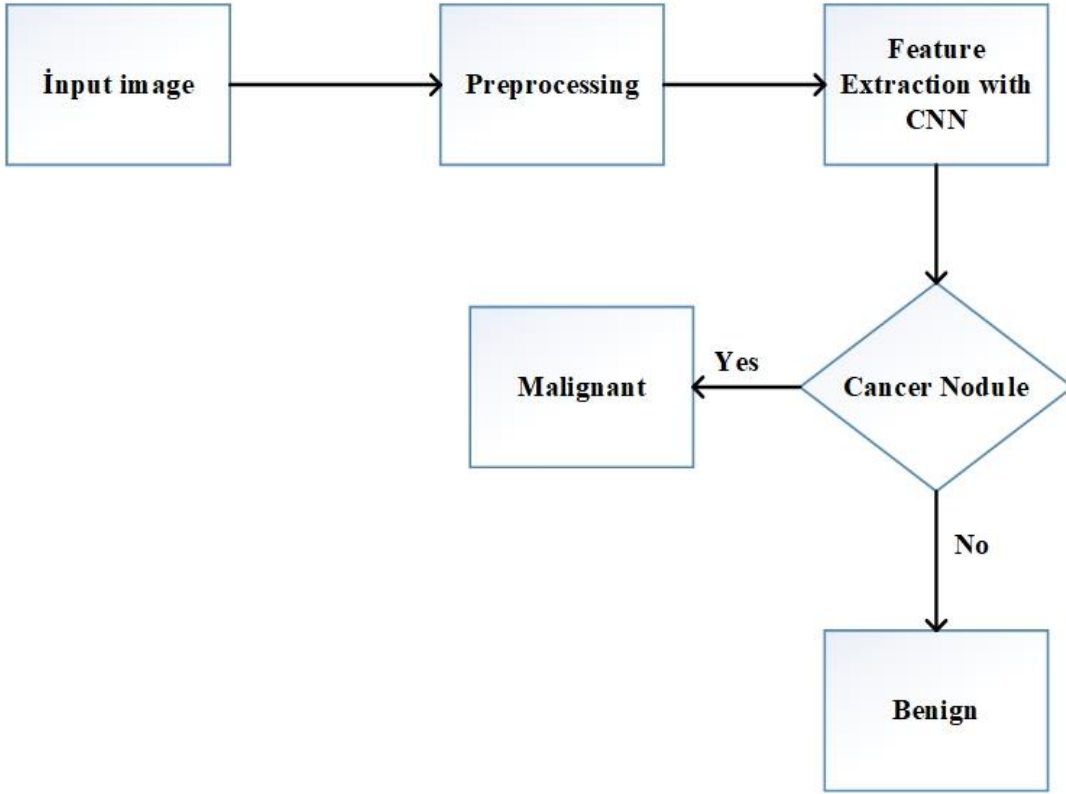
	Dairesel komşuluk algoritması	
	1. başla	
	2. kenar piksel konumlarını algıla	
	3. her şekil için (küresel, eliptik)	
	4. her kenar pikseli için	
	5. alanı kontrol et	
	6. kabul edilirse devam et	
	7. son	

**Çizelge A.2:** Yoğunluğa dayalı kümeleme algoritması

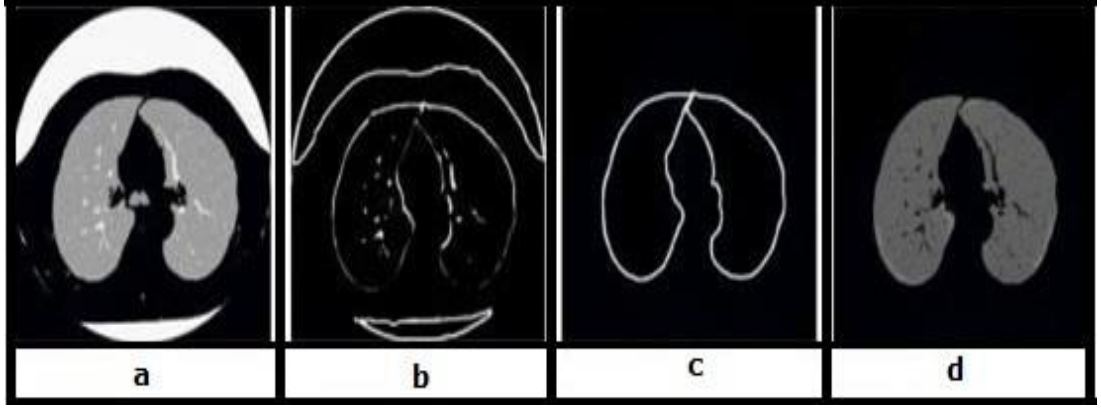
	Kümeleme algoritması	
	8. başla	
	9. her boyut türü için	
	10. her şekil için	
	11. her bir merkezi piksel için	
	12. dairesel bir yarıçap içindeki pikselleri bul	
	13. piksel yoğunluğunu bul	
	14. Figürlü piksellerle dairesel bölge belirleme	
	15. $ort >$ eşik ise dairesel bölge içindeki ortalama yoğunlukları hesapla	
	16. merkezi pikseli nodul piksele ata	
	17. merkezi piksel bitir	
	18. son	




Şekil A.1: Akciğer İA çıkarımı: a. orijinal CT görüntüsü, b. bit düzlemi, c. erozyon, d. ortanca filtresi,




Şekil A.2: Temel çalışma akışı gösterimi



Şekil A.3: Büyütme, b) ana hatlarıyla gösterim, c. kenar belirleme d. İA bölgesi.



Şekil A.4: 2B ADD için frekans düzlemi



**Şekil A.5:** MC seyreltme, RoS ve RuS yöntemleri denenerak BT veri setindeki dengesizliğin giderilmesi

CINSİYET	YAŞ	SİGARA	ANKSİYETE	KRONİK	YORGUNLUK	ALERJİ	ALKOL	ÖKSÜRÜK	NEFES	DARLIĞI	GÖĞÜS AĞRISI	KANSER
E	69	1	2	1	2	1	2	2	2	2	2	EVET
E	74	2	1	2	2	2	1	1	2	2	2	EVET
K	59	1	1	1	2	1	1	2	2	2	2	HAYIR
E	63	2	2	1	1	1	2	1	1	2	2	HAYIR
K	63	1	1	1	1	1	1	2	2	1	2	HAYIR
K	75	1	1	2	2	2	1	2	2	2	2	EVET
E	52	2	1	1	2	1	2	2	2	2	2	EVET
K	51	2	2	1	2	2	1	1	2	1	2	EVET
K	68	2	2	1	2	1	1	1	1	1	2	HAYIR
E	53	2	2	2	1	2	2	1	1	2	2	EVET
K	61	2	2	2	2	1	1	2	2	1	2	EVET
E	72	1	1	2	2	2	2	2	2	2	2	EVET
K	60	2	1	1	2	1	1	1	2	1	2	HAYIR
E	58	2	1	1	2	2	2	2	2	2	2	EVET
E	69	2	1	1	1	2	2	2	2	1	2	HAYIR
K	48	1	2	2	2	2	1	2	2	2	2	EVET
E	75	2	1	2	1	2	2	2	2	2	2	EVET
E	57	2	2	2	1	1	2	1	1	2	2	EVET
K	68	2	2	2	2	1	1	2	2	1	2	EVET
K	61	1	1	2	2	1	1	1	2	1	2	HAYIR
K	44	2	2	2	2	1	1	1	2	1	2	EVET
K	64	1	2	1	1	2	1	2	1	1	2	EVET
K	21	2	1	2	2	2	1	1	2	1	2	HAYIR
E	60	2	1	1	2	2	2	2	2	2	2	EVET
E	72	2	2	2	1	2	2	2	2	1	2	EVET
E	65	1	2	1	2	1	2	2	2	2	2	EVET
K	61	2	2	1	2	2	2	1	2	2	2	EVET
E	69	1	1	1	2	1	1	2	2	2	2	HAYIR
K	53	2	2	2	1	1	2	1	2	2	2	EVET
E	55	1	1	1	2	1	2	2	2	1	2	HAYIR
K	57	2	1	1	1	1	1	1	2	1	2	HAYIR
E	62	2	2	1	1	2	2	1	2	2	2	EVET
E	56	2	2	1	1	1	1	1	2	1	2	HAYIR
K	67	2	2	2	1	1	1	1	2	2	2	EVET
E	59	1	2	1	1	1	1	1	1	1	2	HAYIR
K	59	2	2	2	1	1	1	1	2	1	2	EVET

**Şekil A.6:** Etiketli kanser verisi özellikleri

**Çizelge A.3:** 2B ADD' de kullanılan dalgacıklar

Denklem	Açıklama
$\psi^D(x, y) = \varphi(x)\psi(y)$	AY
$\psi^K(x, y) = \psi(x)\psi(y)$	YA
$\psi^Y(x, y) = \psi(x)\varphi(y)$	YY

**Çizelge A.4:** Geleneksel modellerin karşılaştırılması


Model	AlexNet	VGG16	Inception v3	ResNet50
Sunum tarihi	2012	2014	2014	2015
Katman sayısı	8	16	22	152
Hata oranı	16.4	7.3	6.7	3.57
Veri geliştirme	evet	evet	evet	evet
Evrşim sayısı	5	16	21	151
TBK	3	3	1	1

**Çizelge A.5:** Hata matrisi gösterimi


Hata Matrisi		Gerçek	
		Pozitif	Negatif
Tahmin	Pozitif	DP (Doğru Pozitif)	YP (Yanlış Pozitif)
	Negatif	YN (Yanlış Negatif)	DN (Doğru Negatif)



**EK B: Analiz ve Uygulama**




**Şekil B.1:** Maske uygulanmış akciğer BT görüntüsü




**Şekil B.2:** Maske uygulanmış akciğer BT görüntüsü







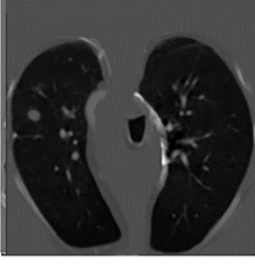
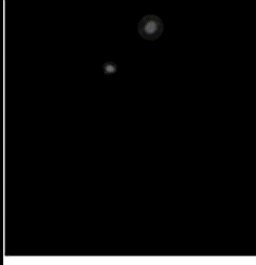
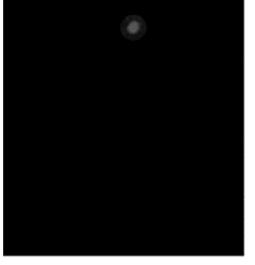


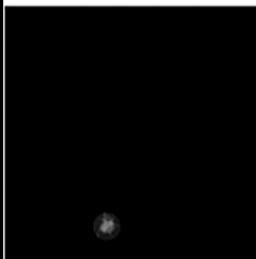
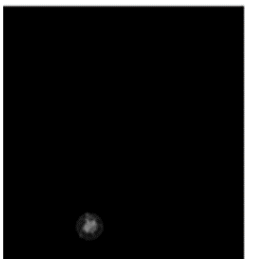
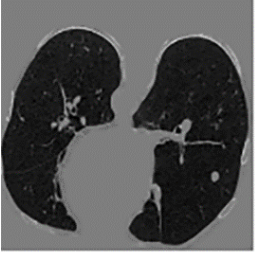

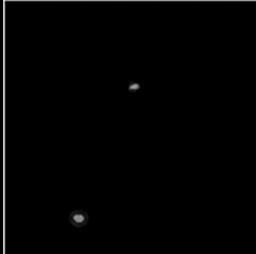
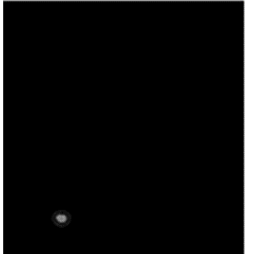
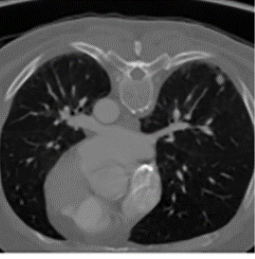
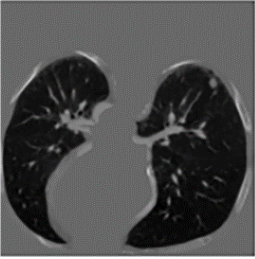

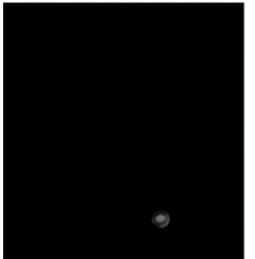



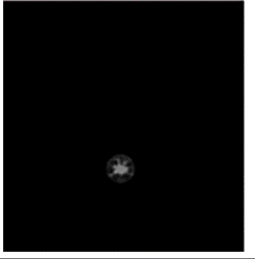
**Şekil B.3:** Maske uygulanmış akciğer BT görüntüsü



**Şekil B.4:** Maske uygulanmış akciğer BT görüntüsü



Şekil B.5: Maske uygulanmış akciğer BT görüntüsü

BT Görüntüsü	Kanserli doku şüphesi	Benign/ Malignant	Malignant
			
			
			
			
			

Şekil B.6: 4K-ESA model sonuçları

SoftMax çapraz Entropi Denklemi

$$H_{y'}(y) = -\sum_i y'_i \log(y_i)$$

B (1.1)

**Çizelge B.1:** Hounsfield üniteleri ve anlamları

Madde	Değer (HU)
Havva	-1000
Akciğer	-500
Su	0
Kan	30 to 45
Yumuşak Doku	100 to 300
Kemik	700 to 3000

**Çizelge B.2:** ESA mimarisi kod parçacıkları

---

```
import tensorflow as tf

import numpy as np

import veri_generators as dg

import small_data_generators as sdg

def ESA (X):

    pad_yuksek = 470

    n_hidden_dim = 200

    paket_boyutu = X.shape[0]

    LSTM = tf.contrib.ESA.LSTMCell(num_units = n_hidden_dim)

    initial_durum = durum = LSTM.zero_durum(paket_boyutu,tf.float32)

    X_ = tf.expand_dims(X, 4)

    x = tf.layers.average_ortaklamaing3d(inputs=X_,
    ortaklama_size=[1,2,2],strides=[1,2,2], padding="valid")

    for t in range(pad_yuksek):

        x_ = x[:,t,:,:,:]

        with tf.variable_scope("cnn",reuse=False):

            if t>0:

                tf.get_variable_scope().reuse_variables()

            conv1 = tf.layers.conv2d(inputs=x_, filters=16, strides=(3, 3), cekirdek_size=[5,
            5], padding="same", activation=tf.nn.relu, name='conv1')

            ortaklama1 = tf.layers.max_ortaklamaing2d(inputs=conv1, ortaklama_size=[3,
            3], strides=2, name='ortaklama1')
```

---

### Çizelge B.3: ESA mimarisi kod parçacıkları

---

```
ortaklama2 = tf.layers.max_ortaklamaing2d(inputs=conv2, ortaklama_size=[3,
3], strides=2, name='ortaklama2')

ortaklama_flat = tf.contrib.layers.flatten(ortaklama2, scope='ortaklamaflat')

with tf.variable_scope("ESA", reuse=False):

    if t>0:

        tf.get_variable_scope().reuse_variables()

        ESA_CIKTI, durum = LSTM(ortaklama_flat, durum)

        ESA_dropout = tf.layers.dropout(inputs=ESA_CIKTI, rate=0.5)

        dense = tf.layers.dense(inputs=ESA_dropout, units=50, activation=tf.nn.relu)

        logits = tf.layers.dense(inputs=dense, units=1)

    return logits

def apply_sinif_loss_ESA(model_function):

    with tf.Graph().as_default() as g:

        with tf.device("/gpu:0"):

            trainer = tf.train.AdamOptimizer()

            x_ = tf.placeholder(tf.float32, [1, 470, 512, 512])

            y_ = tf.placeholder(tf.int32, [1, 1])

            y_logits = model_function(x_)

            loss = tf.nn.sigmoid_cross_entropy_with_logits(labels=tf.cast(y_,
tf.float32), logits=y_logits)

            cross_entropy_loss = tf.reduce_mean(loss)

            train_op = trainer.minimize(cross_entropy_loss)

            y_prob = tf.sigmoid(y_logits)

            y_pred = tf.cast(tf.round(y_prob), tf.int32)
```

---

#### Çizelge B.4: ESA mimarisi kod parçacıkları

---

```
correct_prediction = tf.equal(y_pred, y_)

Doğruluk = tf.cast(correct_prediction, tf.float32)

model_dict = {'graph': g, 'inputs': [x_, y_], 'train_op': train_op,
'pred':y_pred,'prob':y_prob,
' Doğruluk ': Doğruluk, 'loss': cross_entropy_loss}

return model_dict

def train_model(model_dict, veriseti_generators, epoch_n, print_every):

with model_dict['graph'].as_default(), tf.Session() as sess:

sess.run(tf.global_variables_initializer())

test_record = ()

for epoch_i in range(epoch_n):

sonuc_loss= []

sonuc_acc = []

for iter_i, data_batch in enumerate(veriseti_generators['train']):

train_feed_dict = dict(zip(model_dict['inputs'], data_batch))

train_to_compute = [model_dict['train_op'],model_dict['loss'],model_dict['
Doğruluk ']]

_, loss, acc = sess.run(train_to_compute, feed_dict=train_feed_dict)

sonuc_loss.append(loss)

sonuc_acc.append(acc)

print(np.mean(sonuc_loss, axis=0),np.mean(sonuc_acc, axis=0))

sonuc_arr = []

for a, test_batch in enumerate(veriseti_generators['test']):

test_feed_dict = dict(zip(model_dict['inputs'], test_batch))
```

---

#### Çizelge B.5: ESA mimarisi kod parçacıkları

---

```

to_compute = [model_dict['loss'], model_dict[' Doğruluk ']]

sonuc_arr.append(sess.run(to_compute, test_feed_dict))

test_averages = np.mean(sonuc_arr, axis=0)

test_record += tuple(test_averages)

fmt = (epoch_i,) + tuple(test_averages)

print('epoch {:d}, loss: {:.3f}, '
      ' Doğruluk: {:.3f}'.format(*fmt))

print('the_test_record_is')

for i in range(len(test_record)//2):

    print(test_record[2*i], test_record[2*i+1])

    for a, test_batch in enumerate(veriseti_generators['test']):

        test_feed_dict = dict(zip(model_dict['inputs'], test_batch))

        print(sess.run(model_dict['pred'], test_feed_dict))

def main():

    train_data_filepath = 'processed_train_data/train_data'

    train_labels_filepath = 'processed_train_data/train_labels'

    test_data_filepath = 'processed_test_data/test_data'

    test_labels_filepath = 'processed_test_data/test_labels'

    train_data_pathlist, train_labels_pathlist = dg.creat_datapath(train_data_filepath,
                                                                    train_labels_filepath, 8)

    test_data_pathlist, test_labels_pathlist = dg.creat_datapath(test_data_filepath,
                                                                    test_labels_filepath, 2)

    veriseti_generators = {

        'train': dg.veriseti_2d_iterator(train_data_pathlist, train_labels_pathlist),

```

---



**EK C: Analiz ve Uygulama****Çizelge C.1: Çalışılan geleneksel model özeti**

Katman (türü)	Çıktı Format	Ağ
girdi_1 (GirdiKatman)	None, 512, 512, 1)	
evrişim2d_1	(None, 512, 512, 32)	girdi_1[0][0]
evrişim2d_2	(None, 512, 512, 32)	evrişim2d_1[0][0]

**Çizelge C.2: Çalışılan geleneksel model özeti**

maks_Havuzlama2d_1	(None, 256, 256, 32)	evrişim2d_2[0][0]
evrişim2d_3	(None, 256, 256, 64)	maks_Havuzlama2d_1[0][0]
evrişim2d_4	(None, 256, 256, 64)	evrişim2d_3[0][0]
maks_Havuzlama2d_2	(None, 128, 128, 64)	evrişim2d_4[0][0]
evrişim2d_5	(None, 128, 128, 128 )	maks_Havuzlama2d_2[0][0]
evrişim2d_6	(None, 128, 128, 128)	evrişim2d_5[0][0]
maks_Havuzlama2d_3	(None, 64, 64, 128)	evrişim2d_6[0][0]
evrişim2d_7	(None, 64, 64, 256)	maks_Havuzlama2d_3[0][0]
evrişim2d_8	(None, 64, 64, 256)	evrişim2d_7[0][0]

**Çizelge C.3: Çalışılan geleneksel model özeti**

maks_Havuzlama2d_4	(None, 32, 32, 256)	evrişim2d_8[0][0]
evrişim2d_9	(None, 32, 32, 512)	maks_Havuzlama2d_4[0][0]
evrişim2d_10	(None, 32, 32, 512)	evrişim2d_9[0][0]
evrişim2d_transpose_1	(None, 64, 64, 256)	evrişim2d_10[0][0]

birleřtir_1	(None, 64, 64, 512)	evriřim2d_transpose_1[0][0]
evriřim2d_11	(None, 64, 64, 256)	birleřtir_1[0][0]
evriřim2d_12	(None, 64, 64, 256)	evriřim2d_11[0][0]
birleřtir_2	(None, 128, 128, 256 )	evriřim2d_transpose_2[0][0]
evriřim2d_13	(None, 128, 128, 128 )	birleřtir_2[0][0]
birleřtir_3	(None, 256, 256, 128 )	evriřim2d_transpose_3[0][0]

**Çizelge C.4: Çalışılan geleneksel model özeti**

evriřim2d_16 (Evrıřim2D)	(None, 256, 256, 64)	evriřim2d_15[0][0]
evriřim2d_transpose_4	(None, 512, 512, 32)	evriřim2d_16[0][0]
birleřtir_4	(None, 512, 512, 64)	evriřim2d_transpose_4[0][0]
evriřim2d_17 (Evrıřim2D)	(None, 512, 512, 32)	birleřtir_4[0][0]

**Çizelge C.5: Inception v3 alt ađlarındaki parametre sayısı.**

Evrřm	Boyutlar	Adım_kaydırma =	Toplam	Eđitilebilir	Eđitilemez
Evrřm1	1 x 1 x 16,	1			
Evrřm2	1 x 1 x 16,	1	6,834,468	6,819,492	14,976
Evrřm3	1 x 1 x 16,	1	8,978,340	8,959,524	18,816
Evrřm4	1 x 3 x 16,	1	10,679,972	10,658,596	21,376
Evrřm5	3 x 1 x 16,	1	12,676,431	12,651,641	24,789
Evrřm6	1 x 3 x 16,	1	15,730,916	15,703,012	27,904
Evrřm7	3 x 1 x 16,	1	21,810,980	21,776,548	34,404
Evrřm8	1 x 3 x 16,	1	22,498,859	22,462,348	36,493
Evrřm8	3 x 1 x 16,	1	25,274,195	25,234,028	40,145
Evrřm8	1 x 1 x 64,	1	28,049,530	28,005,707	43,796

---

**Çizelge C.6:** ResNet50 ile yapılan 85 devirli bir deney

---

Devir 1/100  
85/85 [=====] - ETA: 0s - loss: 0.9681  
Devir 00001: kayip\_deger 0.59800  
85/85 [=====] - 36s 423ms/step - loss: 0.9681 -  
kayip\_deger: 0.5980 - ogr\_kat: 0.0010  
Devir 2/100  
85/85 [=====] - ETA: 0s - loss: 0.3290  
Devir 00002: kayip\_deger 0.59800 to 0.26672,  
85/85 [=====] - 34s 395ms/step - loss: 0.3290 -  
kayip\_deger: 0.2667 - ogr\_kat: 0.0010  
Devir 3/100  
85/85 [=====] - ETA: 0s - loss: 0.2262  
Devir 00003: kayip\_deger 0.26672 to 0.25576,  
85/85 [=====] - 34s 396ms/step - loss: 0.2262 -  
kayip\_deger: 0.2558 - ogr\_kat: 0.0010  
Devir 4/100  
85/85 [=====] - ETA: 0s - loss: 0.2109  
Devir 00004: kayip\_deger 0.25576 to 0.25240,  
85/85 [=====] - 34s 396ms/step - loss: 0.2109 -  
kayip\_deger: 0.2524 - ogr\_kat: 0.0010

---

**Çizelge C.7:** ResNet50 ile yapılan 85 devirli bir deney

---

Devir 5/100  
85/85 [=====] - ETA: 0s - loss: 0.2102  
Devir 00005: kayip\_deger bulunmuştur 0.25240  
85/85 [=====] - 34s 394ms/step - loss: 0.2102 -  
kayip\_deger: 0.2660 - ogr\_kat: 0.0010  
Devir 6/100  
85/85 [=====] - ETA: 0s - loss: 0.2059  
Devir 00006: kayip\_deger bulunmuştur 0.25240  
85/85 [=====] - 34s 397ms/step - loss: 0.2059 -  
kayip\_deger: 0.2543 - ogr\_kat: 0.0010  
Devir 7/100  
85/85 [=====] - ETA: 0s - loss: 0.1977  
Devir 00007: kayip\_deger 0.25240 to 0.25149,  
85/85 [=====] - 32s 382ms/step - loss: 0.1977 -  
kayip\_deger: 0.2515 - ogr\_kat: 0.0010  
Devir 8/100  
85/85 [=====] - ETA: 0s - loss: 0.1899  
Devir 00008: kayip\_deger 0.25149 to 0.25139,  
85/85 [=====] - 33s 394ms/step - loss: 0.1899 -  
kayip\_deger: 0.2514 - ogr\_kat: 0.0010

---

**Çizelge C.8:** ResNet50 ile yapılan 85 devirli bir deney

Devir 9/100
85/85 [=====] - ETA: 0s - loss: 0.1894
Devir 00009: kayip_deger bulunmuştur 0.25139
85/85 [=====] - 33s 383ms/step - loss: 0.1894 - kayip_deger: 0.2517 - ogr_kat: 0.0010
Devir 10/100
85/85 [=====] - ETA: 0s - loss: 0.1851
Devir 00010: kayip_deger bulunmuştur 0.25139
85/85 [=====] - 33s 393ms/step - loss: 0.1851 - kayip_deger: 0.2517 - ogr_kat: 0.0010
Devir 11/100
85/85 [=====] - ETA: 0s - loss: 0.1841
Devir 00011: kayip_deger 0.25139 to 0.25008,
85/85 [=====] - 33s 390ms/step - loss: 0.1841 - kayip_deger: 0.2501 - ogr_kat: 0.0010
Devir 12/100
85/85 [=====] - ETA: 0s - loss: 0.1820
Devir 00012: kayip_deger bulunmuştur 0.25008
85/85 [=====] - 33s 390ms/step - loss: 0.1820 - kayip_deger: 0.2541 - ogr_kat: 0.0010

## ÖZGEÇMİŞ

**Soyadı** : ÇİFÇİ

**Adı** : Mehmet Akif

### Eğitim

Eğitim Bilgileri	Diploma
İstanbul Aydın Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, Bilgisayar Mühendisliği 2017-2021	Doktora
İstanbul Aydın Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, Bilgisayar Mühendisliği 2013-2015	Yüksek Lisans
University of People, Pasadena, CA, USA, Bilgisayar Mühendisliği, NA	Lisans (BCS.)
Dokuz Eylül Üniversitesi, Eğitim Fakültesi, İngilizce Öğretmenliği, İzmir, 2002-2006	Lisans (BA.)

### Uluslararası Dergilerde Yayımlanan SCI Makaleleri

- Basiri, M. E., Abdar, M., Cifci, M. A., Nemati, S., & Acharya, U. R. (2020). A novel method for sentiment classification of drug reviews using fusion of deep and machine learning techniques. Knowledge-Based Systems, 105949.
- Mehmet Akif Cifci, Duygu Celik Ertugrul, Atilla Elci, A Search Service for Food Consumption Mobile Applications via Hadoop and MapReduce Technology, IEEE ESAS 2016: The 11th IEEE International Workshop on E-Health Systems and Semantic Web Held in conjunction with COMPSAC, IEEE 40th Annual Computer Software and Applications Conference (COMPSAC), 10–14 June 2016, Atlanta, USD.
- Fetal Heart Rate Monitoring System

### Uluslararası Dergilerde Yayımlanan SCIE Makaleleri

- Cifci, M. A., & Aslan, Z. (2021, February). Deep Learning Algorithms for Diagnosis of Breast Cancer with Maximum Likelihood Estimation. Medical Imaging and Computer-Aided Diagnosis Springer.

- Hussain, S., Akif, C., Tamayo, J. D., & Safdar, A. (2018). Big data and learning analytics model. *International Journal of Computer Sciences and Engineering*, 6(7), 654-663.1
- Cifci, M. A., & Hussain, S. (2018). Data mining usage and applications in health services. *JOIV: International Journal on Informatics Visualization*, 2(4), 225-231.
- Cifci, M. A. Deep Learning Model for Diagnosis of Corona Virus Disease from CT Images.
- Cifci, M. A., & Hussain, S. (2018). Data mining usage and applications in health services. *JOIV: International Journal on Informatics Visualization*, 2(4), 225-231.

#### **Ulusal Dergilerde Yayınlanan Makaleleri**

- Cifci, M. A. (2021). Derin Öğrenme Metodu Kullanarak BT Görüntülerinden Akciğer Kanseri Teşhisi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*.
- Mehmet Akif CİFCİ, Duygu CELİK ERTUGRUL (2016). Hadoop ve Mapreduce Teknolojisi aracılığıyla Gıda-tabanlı Mobil Uygulamaları için bir Arama Hizmeti, *Cumhuriyet Üniversitesi Fen-Edebiyat Fakültesi Fen Bilimleri Dergisi*, (Revision Stage).
- Cifci, M. A., & Sonmez, F. Kablosuz Algılayıcı Ağlar Enerji-Verimli OEK Protokolleri. *Harran Üniversitesi Mühendislik Dergisi*, 4(1), 56-68.
- Cifci, Mehmet Akif; ATILLA, E. L. C. İ. Yapay Zekâ İle Kablosuz Algılayıcı Ağları
- Eniyileme. *Türkiye Bilisim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 10.2: 64 76.

#### **Kitap Bölümleri**

- Cifci, M. A. (2020). Optimizing WSNs for CPS Using Machine Learning Techniques. In *Artificial Intelligence Paradigms for Smart Cyber-Physical Systems* (pp. 204-228). IGI Global.
- Cifci, M. A., & Aslan, Z. (2020, July). Deep Learning Algorithms for Diagnosis of Breast Cancer with Maximum Likelihood Estimation. In *International Conference on Computational Science and Its Applications* (pp. 486-502). Springer, Cham.

#### **Öne çıkan özellikler**

Derin öğrenme ve belirsizlik modelleri üzerine araştırma yapmıştır.

## **İlgi Alanları**

- Makine Öğrenimi ve Yapay Zekâ, Görüntü İşleme
- Büyük Veri, Hadoop ve MR Teknolojileri
- Sağlık sistemleri ve E-sağlık sistemleri, E-öğrenme
- Ağ, Kablosuz Ağlar
- Hesaplamalı Araştırma ve Geliştirme
- Sınıflandırma Algoritmaları
- M-Health sistemleri ve E-sağlık sistemleri
- Sensör Tabanlı Mobil Sağlık Sistemleri

Yüksek Lisans Tezi: Hadoop ve Mapreduce Teknolojisi aracılığıyla Gıda-tabanlı Mobil Uygulamaları için bir Arama Hizmeti

Doktora Tezi: Derin Öğrenme ve Dalgacık Dönüşümüne Dayalı Akciğer Kanseri Erken Tanısında Belirsizlik Ölçeğinin Saptanması (İAÜ Yüksek Lisans Enst., Bilgisayar Mühendisliği programında devam etmekte, Danışman: Prof. Dr. Zafer ASLAN.)

## **Yabancı Diller**

İngilizce C1

## **Bilgisayar Becerileri**

Diller: Python, Java, R, Bash, LaTeX Platformlar: Hadoop, Spark, Hive, Zookeeper

Veritabanları: HBase, Oracle, MySQL, NoSQL

İşletim Sistemleri: Linux (Centos, Ubuntu), Mac OSX, Windows

## **Çalışma Tecrübesi:**

### **Scribendi Akademik Danışmanlık/Araştırmacı**

- Yapay zekâ konusunda akademik danışmanlık ve araştırma görevi

### **Türkiye Bilimsel ve Teknolojik Araştırma Kurumu**

- Ph.D. araştırmacı ‘Derin öğrenme yöntemleri kullanarak BT görüntülerinden erken COVID-19 tanısı’

### **Ulusal ve Uluslararası Dergilerde Yaptığı Hakemlikler**

- IJCSDf\*51
- Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi\*3
- Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi
- Cumhuriyet Science Journal
- Book chapter IGI-GLOBAL
- Elsevier
- IEEE

#### **Uluslararası Dergilerde Yaptığı Editörlükler**

- Frontiers

#### **Aldığı Ödüller**

- Tam burs, Lisans, UoPeople Üniversitesi
- YL ve Doktora bursu İstanbul Aydın Üniversitesi
- TÜBİTAK Üniversite Öğrencileri Araştırma Projeleri Desteği

#### **Bilimsel Kuruluşlara Üyelikleri**

1. Association for Computing Machinery (ACM)
2. IEEE & IEEE Computer Society
3. Akademik Bilişim Vakfı Kurucu Üyesi