

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**



**AKCİĞER KANSERİ TANISINDA YAPAY ZEKA
YÖNTEMLERİNİN KARŞILAŞTIRILMASI**

Yüksek Lisans Tezi

Sarp ÇOBAN

Danışman

Dr. Öğretim Üyesi Gökhan KAYHAN

SAMSUN
2023

TEZ KABUL VE ONAYI

Sarp ÇOBAN tarafından, Dr. Öğretim Üyesi Gökhan KAYHAN danışmanlığında hazırlanan “AKCİĞER KANSERİ TANISINDA YAPAY ZEKA YÖNTEMLERİNİN KARŞILAŞTIRILMASI” başlıklı bu çalışma, jürimiz tarafından 22.3.2023 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	Sonuç
Başkan	Doç. Dr. Abdulkadir KARACI Samsun Üniversitesi Yazılım Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi Gökhan KAYHAN Ondokuz Mayıs Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi İsmail İŞERİ Ondokuz Mayıs Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

Prof. Dr. Ahmet TABAK
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Yüksek Lisans tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi ?

Evet ☐ (Gerekli ise ekler kısmına ekleyiniz)

Hayır ☒

17 /04 / 2023
Sarp ÇOBAN

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı: AKCİĞER KANSERİ TANISINDA YAPAY ZEKA YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 17/04/2023 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 5

Tek kaynak oranı : % 1 çıkmıştır.

17 /04 / 2023
Dr. Öğr. Üyesi Gökhan KAYHAN

ÖZET

AKCİĞER KANSERİ TANISINDA YAPAY ZEKA YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Sarp ÇOBAN

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Ana Bilim Dalı

Yüksek Lisans, Nisan/2023

Danışman: Dr. Öğr. Üyesi Gökhan KAYHAN

Akciğer kanseri, en ölümcül kanser türlerinden biridir. 2020 yılında yaklaşık 2 milyon yeni vaka tespit edilmiştir. Kanser hastalarının yaklaşık %20'si akciğer kanseridir. Küçük hücreli ve küçük hücreli olmayan olmak üzere 2 alt türü bulunmaktadır. Küçük hücreli olmayanlar ise adenokarsinom, skuamöz hücreli karsinom ve büyük hücreli karsinom olmak üzere 3 alt gruba ayrılmaktadır. Alt türlerin tümör yapıları birbirinden farklıdır. Bu yüzden bilgisayarlı tomografi görüntülerinde ayrımı yapılabilmektedir. Bu çalışmada bilgisayarlı tomografi görüntüleri üzerinden kişinin akciğer kanseri olup olmadığına dair tanı konulmaktadır. Aynı zamanda akciğer kanserinin alt türü de tespit edilmektedir. Sınıflandırma işlemi tamamlandıktan sonra en iyi sınıflandırma yapan algoritma tespit edilmiştir. Bu çalışmada Naive Bayes, k en yakın komşu, destek vektör makinesi, momentumlu dereceli azalma, Levenberg-Marquardt, ölçeklenmiş eşlenik gradyan, evrişimsel sinir ağları, VGG16 ve ResNet101 modelleri karşılaştırılmıştır. Kaggle Chest CT-Scan veri setinden elde edilen görüntüler 80x40 boyutuna indirgenerek standartlaştırılmıştır. Görüntülerin dalgacık dönüşümünden geçebilmesi için görüntüler gri seviyeye dönüştürülmüştür. Elde edilen görüntülere 3. seviye dalgacık dönüşümü uygulanarak özellik çıkarma işlemi gerçekleştirilmiştir. Verilerin rastallığını sağlamak amacıyla 5 katmanlı çapraz doğrulama yöntemiyle veriler ayrılmıştır. Makine öğrenimi ve yapay sinir ağları tek boyutlu girdi aldığından görüntüler tek boyuta indirgenmiştir ve modellere girdi olarak verilmiştir. Derin öğrenme modelleri, görüntü işlemede otomatik olarak özellik çıkarabildiğinden veriler modellere doğrudan girdi olarak verilmiştir. En başarısız model %51,28 F1 puanı ve 0,335 kappa puanı ile Naive Bayestir. Naive Bayesten sonraki en başarısız model %74,22 F1 puanı ve 0,646 kappa puanı ile momentumlu dereceli azalma algoritması ile optimize edilen yapay sinir ağı modelidir. En başarılı iki model %98,78 F1 puanı ve 0,983 kappa puanı olan ResNet101 modeli ve evrişimsel sinir ağı modelleridir.

Anahtar Sözcükler: Akciğer kanseri, Derin öğrenme, Levenberg-Marquardt, Ölçeklenmiş eşlenik gradyan, Yapay sinir ağları

ABSTRACT

COMPARISON OF ARTIFICIAL INTELLIGENCE METHODS IN DIAGNOSIS OF LUNG CANCER

Sarp ÇOBAN

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Computer Engineering

Master, April/2023

Supervisor: Assist. Prof. Dr. Gökhan KAYHAN

Lung cancer is one of the deadliest types of cancer. Approximately 2 million new cases were detected in 2020. About 20% of cancer patients have lung cancer. There are two subspecies: small cell and non-small cell. Non-small cell carcinomas are divided into 3 subgroups: adenocarcinoma, squamous cell carcinoma, and large cell carcinoma. Tumor structures of subspecies differ from each other. Therefore, it can be differentiated in computed tomography images. In this study, a diagnosis of lung cancer is made through computed tomography images. At the same time, a subtype of lung cancer is detected. After the classification process was completed, the best classification algorithm was determined. In this study, Naive Bayes, k nearest neighbor, support vector machine, gradient descent with momentum, Levenberg-Marquardt, scaled conjugate gradient, convolutional neural networks, VGG16 and ResNet101 models are compared. The images obtained from the Kaggle Chest CT-Scan dataset were standardized by reducing them to 80x40 size. Images are converted to gray level so that the images can undergo wavelet transform. Feature extraction was performed by applying the 3rd level wavelet transform to the obtained images. In order to ensure the randomness of the data, the data were separated by the 5-fold cross-validation method. Since machine learning and artificial neural networks receive one-dimensional input, the images are reduced to one dimension and given as input to the models. Since deep learning models can automatically extract features in image processing, the data are given directly to the models. The most unsuccessful model is Naive Bayes with an F1 score of %51,28 and a kappa score of 0,335. The most unsuccessful model after Naive Bayes is the artificial neural network optimized by the gradient descent with momentum algorithm with an F1 score of 74,22% and a kappa score of 0,646. The two most successful models are the ResNet101 and convolutional neural network, which have an F1 score of 98,78% and a kappa score of 0,983.

Keywords: Lung cancer, Deep learning Levenberg-Marquardt, Scaled conjugate gradient, Artificial neural networks

ÖN SÖZ VE TEŞEKKÜR

Tez sırasında benden desteğini esirgemeyen, yol gösteren, sınırlarımı zorlayan ve ufkumun genişlemesini sağlayan danışmanım Dr. Öğr. Üyesi Gökhan KAYHAN hocama, tezim hakkında bana bilgi veren Dr. Öğr. Üyesi İsmail İŞERİ hocama teşekkürü borç bilirim.

Sarp ÇOBAN



İÇİNDEKİLER

TEZ KABUL VE ONAYI	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI	ii
ÖZET	iii
ABSTRACT.....	iv
ÖN SÖZ VE TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	xii
1.GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	4
3. YÖNTEM.....	13
3.1 Dalgacık Dönüşümü Algoritması	13
3.2 Veri Seti.....	14
3.3 Öğrenme Teknikleri.....	17
3.3.1 Yapay Sinir Ağları	23
3.3.2 Destek Vektör Makinesi.....	27
3.3.2.1 Lineer Destek Vektör Makinesi	29
3.3.2.2 Lineer Olmayan Destek Vektör Makinesi	30
3.3.3 Naive Bayes.....	31
3.3.4 K En Yakın Komşu	33
3.3.5 Evrişimsel Sinir Ağları.....	34
3.4 Optimizasyon Algoritmaları	39
3.4.1 Dereceli Azalma Algoritması.....	39
3.4.1.1 Dereceli Azalma Algoritmasının Yapay Sinir Ağlarına Uygulanması	40
3.4.2 Adam Algoritması	41
3.4.3 Levenberg-Marquardt Algoritması.....	42
3.4.4 Ölçeklendirilmiş Eşlenik Gradyan Algoritması	43
3.5 Önerilen Mimari	44
3.6 Başarı Metrikleri.....	45
3.6.1 Karmaşıklık Matrisi.....	45
3.6.2 Doğruluk Oranı	46
3.6.3 Kesinlik	46
3.6.4 Duyarlılık	46
3.6.5 F1 Puanı	46
3.6.6 Cohen'in Kappa Katsayısı.....	46
3.6.7 Ortalama Kare Hatası	47
3.6.8 Karekök Ortalama Kare Hatası	47
3.6.9 Ortalama Mutlak Hata	48
3.6.10 Çapraz Entropi.....	48
4. BULGULAR.....	49
4.1 Verilerin Hazırlanması	49
4.2 Öznitelik Çıkarımı	49
4.3 Naive Bayes Modeli ile Sınıflandırma	51
4.4 K En Yakın Komşu Modeli ile Sınıflandırma	55
4.5 Destek Vektör Makinesi Modeli ile Sınıflandırma.....	59
4.6 Yapay Sinir Ağı Modelleri ile Sınıflandırma	64
4.6.1 Ölçeklendirilmiş Eşlenik Gradyan ile Sınıflandırma	64
4.6.2 Levenberg-Marquardt ile Sınıflandırma.....	72
4.6.3 Momentumlu Dereceli Azalma ile Sınıflandırma	79
4.7 Evrişimsel Sinir Ağları Modeli ile Sınıflandırma.....	86
4.8 ResNetRS101 Modeli ile Sınıflandırma	94
4.9 VGG16 Modeli ile Karşılaştırma.....	101

4.10 Bulguların Karşılaştırılması.....	108
5. SONUÇ VE TARTIŞMA	109
KAYNAKÇA.....	111
ÖZ GEÇMİŞ.....	119



ŞEKİLLER DİZİNİ

Şekil 1.1: Akciğer kanserinin alt türlerini gösteren öbek.....	1
Şekil 1.2:(a) Normal akciğer tomografisi (b) Kanserli akciğer tomografisi	2
Şekil 3.1. Dalgacık Dönüşümü İşlemi	14
Şekil 3.2: Normal sınıfına ait akciğer tomografisi.....	15
Şekil 3.3: Adenokarsinom hücreli akciğer tomografisi.....	15
Şekil 3.4: Büyük hücreli karsinoma sahip akciğer tomografisi	16
Şekil 3.5: Skuamöz hücreli karsinoma sahip akciğer tomografisi	16
Şekil 3.6. Regresyon	18
Şekil 3.7. Sınıflandırma	18
Şekil 3.8. Kümeleme.....	19
Şekil 3.9. Yarı Danışmanlı Öğrenme	19
Şekil 3.10. Takviyeli öğrenme şeması	20
Şekil 3.11. Örnek yapay sinir ağları modeli.....	24
Şekil 3.12. Nöronun yapısı.....	24
Şekil 3.13. Hopfield Sinir Ağı örneği	26
Şekil 3.14. RBF sinir ağı.....	27
Şekil 3.15. Destek vektör makinesi örneği	28
Şekil 3.16. Lineer destek vektör makinesi	29
Şekil 3.17. Lineer olmayan destek vektör makinesi	30
Şekil 3.18. Kernel İşlemi	31
Şekil 3.19. K en yakın komşu örneği	33
Şekil 3.20. Evrişimsel sinir ağı örneği	35
Şekil 3.21. LeNet-5 mimarisi (Tra vd, 2017).....	35
Şekil 3.22. AlexNet mimarisi (Khvostikov vd, 2018)	36
Şekil 3.23.VGGNET mimarisi (Sovrirajan vd, 2023).....	36
Şekil 3.24. Başlangıç katmanının yapısı	37
Şekil 3.25. Evrişimsel katman ve işlevi	37
Şekil 3.26. Ortalama havuzlama tekniği	39
Şekil 3.27. Maksimum havuzlama tekniği.....	39
Şekil 3.28. Önerilen Mimari Yapısı	44
Şekil 3.29. Karmaşıklık matrisi	45
Şekil 4.1. Veri hazırlama yapısının öbek çizgisi.....	49
Şekil 4.2. Öznitelik Çıkarımı	50
Şekil 4.3. Naive Bayes Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri	52
Şekil 4.4. Naive Bayes Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri	52

Şekil 4.5. Naive Bayes Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri	54
Şekil 4.6. Naive Bayes Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri	54
Şekil 4.7. K En Yakın Komşu Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri.....	56
Şekil 4.8: K En Yakın Komşu Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	57
Şekil 4.9. K En Yakın Komşu Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri	58
Şekil 4.10. K En Yakın Komşu Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	59
Şekil 4.11. Destek Vektör Makinesi Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri.....	61
Şekil 4.12. Destek Vektör Makinesi Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	61
Şekil 4.13. Destek Vektör Makinesi Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri.....	63
Şekil 4.14. Destek Vektör Makinesi Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	63
Şekil 4.15. Kullanılan Yapay Sinir Ağı Modeli.....	64
Şekil 4.16. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri	67
Şekil 4.17. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri	67
Şekil 4.18. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Veri Seti Üzerindeki Hata Grafikleri	68
Şekil 4.19. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri	70
Şekil 4.20. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	71
Şekil 4.21. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Veri Seti Üzerindeki Hata Grafikleri	71
Şekil 4.22. Levenberg-Marquardt Algoritmasının Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri.....	74
Şekil 4.23. Levenberg-Marquardt Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	74
Şekil 4.24. Levenberg-Marquardt Algoritmasının Artırılmamış Veri Seti Üzerindeki Hata Grafikleri	75
Şekil 4.25: Levenberg-Marquardt Algoritmasının Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri.....	77
Şekil 4.26: Levenberg-Marquardt Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	78

Şekil 4.27. Levenberg-Marquardt Algoritmasının Artırılmış Veri Seti Üzerindeki Hata Grafikleri	78
Şekil 4.28. Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri	81
Şekil 4.29. Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri	81
Şekil 4.30. Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Veri Seti Üzerindeki Hata Grafikleri	82
Şekil 4.31. Momentumlu Dereceli Azalma Algoritmasının Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri	84
Şekil 4.32. Momentumlu Dereceli Azalma Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri	85
Şekil 4.33. Momentumlu Dereceli Azalma Algoritmasının Artırılmış Veri Seti Üzerindeki Hata Grafikleri.....	85
Şekil 4.34. Kullanılan Evrişimsel Sinir Ağı Modeli	86
Şekil 4.35. Evrişimsel Sinir Ağları Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri.....	89
Şekil 4.36. Evrişimsel Sinir Ağları Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisi.....	89
Şekil 4.37. Evrişimsel Sinir Ağları Modelinin Artırılmamış Veri Seti Üzerindeki Hata Grafikleri	90
Şekil 4.38. Evrişimsel Sinir Ağları Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri.....	92
Şekil 4.39. Evrişimsel Sinir Ağları Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	93
Şekil 4.40. Evrişimsel Sinir Ağları Modelinin Artırılmış Veri Seti Üzerindeki Hata Grafikleri	93
Şekil 4.41. ResNetRS101 Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri	96
Şekil 4.42. ResNetRS101 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri.....	96
Şekil 4.43. ResNetRS101 Modelinin Artırılmamış Veri Seti Üzerindeki Hata Grafikleri	97
Şekil 4.44. ResNetRS101 Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri	99
Şekil 4.45. ResNetRS101 Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri	100
Şekil 4.46. ResNetRS101 Modelinin Artırılmış Veri Seti Üzerindeki Hata Grafikleri	100
Şekil 4.47. VGG16 Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri	103
Şekil 4.48. VGG16 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri	103
Şekil 4.49. VGG16 Modelinin Artırılmamış Veri Seti Üzerindeki Hata Grafikleri	104
Şekil 4.50. VGG16 Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri	106

Şekil 4.51. VGG16 Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisi ...	107
Şekil 4.52. VGG16 Modelinin Artırılmış Veri Seti Üzerindeki Hata Grafikleri	107
Şekil 4.53: Yapay zeka algoritmalarının karşılaştırılması	108



TABLÖLAR DİZİNİ

Tablo 3.1: Veri setinin sınıflara göre dağılımı	17
Tablo 3.2:Kappa istatistiğinin yorumlanması	47
Tablo 4.1: Naive Bayes Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı.....	51
Tablo 4.2: Naive Bayes Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı.....	51
Tablo 4.3: Naive Bayes Modelinin Artırılmış Test Verileri Üzerindeki Başarısı.....	53
Tablo 4.4: Naive Bayes Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı.....	53
Tablo 4.5: K En Yakın Komşu Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı..	55
Tablo 4.6: K En Yakın Komşu Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı	55
Tablo 4.7: K En Yakın Komşu Modelinin Artırılmış Test Verileri Üzerindeki Başarısı	57
Tablo 4.8: K En Yakın Komşu Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı ..	58
Tablo 4.9: Destek Vektör Makinesi Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı	60
Tablo 4.10: Destek Vektör Makinesi Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı	60
Tablo 4.11: Destek Vektör Makinesi Modelinin Artırılmış Test Verileri Üzerindeki Başarısı	62
Tablo 4.12: Destek Vektör Makinesi Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı	62
Tablo 4.13: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Test Verileri Üzerindeki Başarısı	65
Tablo 4.14: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Başarısı	65
Tablo 4.15: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Test Verileri Üzerindeki Hata Oranları	66
Tablo 4.16: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları	66
Tablo 4.17: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Test Verileri Üzerindeki Başarısı	68
Tablo 4.18: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Başarısı	69
Tablo 4.19: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Test Verileri Üzerindeki Hata Oranları	69
Tablo 4.20: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Hata Oranı.....	70
Tablo 4.21: Levenberg-Marquardt Algoritmasının Artırılmamış Test Verileri Üzerindeki Başarısı	72
Tablo 4.22: Levenberg-Marquardt Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Başarısı	72
Tablo 4.23: Levenberg-Marquardt Algoritmasının Artırılmamış Test Verileri Üzerindeki Hata Oranları	73

Tablo 4.24: Levenberg-Marquardt Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları	73
Tablo 4.25: Levenberg-Marquardt Algoritmasının Artırılmış Test Verileri Üzerindeki Başarısı	75
Tablo 4.26: Levenberg-Marquardt Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Başarısı	76
Tablo 4.27: Levenberg-Marquardt Algoritmasının Artırılmış Test Verileri Üzerindeki Hata Oranları.....	76
Tablo 4.28: Levenberg-Marquardt Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Hata Oranları	77
Tablo 4.29: Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Test Verileri Üzerindeki Başarısı	79
Tablo 4.30: Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Başarısı	79
Tablo 4.31: Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Test Verileri Üzerindeki Hata Oranları	80
Tablo 4.32: Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları	80
Tablo 4.33: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Test Verileri Üzerindeki Başarısı	82
Tablo 4.34: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Başarısı	83
Tablo 4.35: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Test Verileri Üzerindeki Hata Oranları	83
Tablo 4.36: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Hata Oranları	84
Tablo 4.37: Evrişimsel Sinir Ağları Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı	87
Tablo 4.38: Evrişimsel Sinir Ağları Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı	87
Tablo 4.39: Evrişimsel Sinir Ağları Modelinin Artırılmamış Test Verileri Hata Oranları	88
Tablo 4.40: Evrişimsel Sinir Ağları Modelinin Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları	88
Tablo 4.41: Evrişimsel Sinir Ağları Modelinin Artırılmış Test Verileri Üzerindeki Başarısı	90
Tablo 4.42: Evrişimsel Sinir Ağları Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı	91
Tablo 4.43: Evrişimsel Sinir Ağları Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı	91
Tablo 4.44: Evrişimsel Sinir Ağları Modelinin Artırılmış Test Verileri Üzerindeki Hata Oranları.....	91
Tablo 4.45: ResNetRS101 Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı.....	94
Tablo 4.46: ResNetRS101 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı	94


Tablo 4.47: ResNetRS101 Modelinin Artırılmamış Test Verileri Üzerindeki Hata Oranları.....	95
Tablo 4.48: ResNetRS101 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları.....	95
Tablo 4.49: ResNetRS101 Modelinin Artırılmış Test Verileri Üzerindeki Başarısı	97
Tablo 4.50: ResNetRS101 Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı	98
Tablo 4.51: ResNetRS101 Modelinin Artırılmış Test Verileri Üzerindeki Hata Oranları	98
Tablo 4.52: ResNetRS101 Modelinin Artırılmış Eğitim Verileri Üzerindeki Hata Oranları	98
Tablo 4.53: VGG16 Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı	101
Tablo 4.54: VGG16 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı	101
Tablo 4.55: VGG16 Modelinin Artırılmamış Test Verileri Üzerindeki Hata Oranları	102
Tablo 4.56: VGG16 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları....	102
Tablo 4.57: VGG16 Modelinin Artırılmış Test Verileri Üzerindeki Başarısı	104
Tablo 4.58: VGG16 Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı	105
Tablo 4.59: VGG16 Modelinin Artırılmış Test Verileri Üzerindeki Hata Oranları	105
Tablo 4.60: VGG16 Modelinin Artırılmış Eğitim Verileri Üzerindeki Hata Oranları	105

1.GİRİŞ

Günümüzde hastalığın tanısında, laboratuvarlar ve görüntüleme uygulamaları kullanılmaktadır. Bu yöntemler çok zaman tüketmektedir ve çok maliyetlidir. Bundan dolayı hızlı ve doğru sonuç üreten bilgisayar destekli cihazlar gerekmektedir. Bu cihazlar, yapay zekâ yardımıyla tanı koymaktadır. Dünya genelinde bu tür cihazlar artmaktadır ve bu yönde çalışmalar yapılmaktadır (Temurtaş vd, 2019).


Akciğer kanseri, akciğer dokularında bulunan hücrelerin kontrolsüz bir şekilde çoğalmasıyla meydana gelen hastalıktır. Dünya genelinde en sık rastlanan ve en ölümcül kanser türüdür. 2020 yılında yaklaşık olarak 2,2 milyon yeni akciğer kanseri vakası görülmüştür ve 1,8 milyon kişi akciğer kanseri nedeniyle hayatını kaybetmiştir. Geç evrede tespit edilebildiğinden dolayı ölüm oranı yüksektir. Bundan dolayı yaşama oranı yaklaşık %15'tir. Uzun süre boyunca gelişmektedir ve bundan dolayı çeşitli tümörler oluşmaktadır. Süreklilik durumunda metabolizmada ve genomda değişiklikler meydana gelmektedir. (Thong et al, 2023; Temurtaş vd, 2019; Schmidt et al, 2023; Vas and Dessai, 2017).

Akciğer kanseri hücreleri, küçük hücreli ve küçük hücreli olmayanlar olarak iki ana gruba ayrılmaktadır. Küçük hücreli olmayanlar ise adenokarsinom, büyük hücreli karsinom ve skuamöz hücreli karsinom olmak üzere üçe ayrılmaktadır. Akciğer kanseri olan hastaların yaklaşık %90'ı küçük hücreli olmayan, yaklaşık %10'u ise küçük hücreli akciğer kanserine yakalanmışlardır. Şekil 1.1'de akciğer kanserinin alt türlerini gösteren öbek görülmektedir.



Şekil 1.1: Akciğer kanserinin alt türlerini gösteren öbek

Akciğer kanseri 4 evreden meydana gelmektedir. Birinci evrede kanser hücresi sadece akciğerde bulunmaktadır. İkinci ve üçüncü evrede kanser hücreleri göğüste, dördüncü evrede ise vücudun diğer kısımlarında görülmektedir. X-ray, tomografi, manyetik rezonans görüntüleme ve balgam sitolojisi yöntemleriyle akciğer kanseri tanısı konulabilir. Ana tedavi yaklaşımı kemoterapidir ancak kanser hücreleri, ilaç inaktivasyonu, DNA onarımı, ilaç hedefi değişikliği ve hücre ölümü inhibisyonu gibi mekanizmalarla kemoterapiye karşı dirençli hale gelebilirler. (Vas and Dessai, 2017; Wu et al, 2022). Şekil 1.2’de normal akciğerin ve kanserli akciğerin tomografi görüntüsü görülmektedir.



Şekil 1.2:(a) Normal akciğer tomografisi (b) Kanserli akciğer tomografisi

Bu tez çalışmasının amacı, tomografi görüntüleri üzerinden kişinin akciğer kanseri olup olmadığına dair tanı konulmasıdır. Kanser ise alt türünün de tanısı konulur. Tanısı konulan kanser türü küçük hücreli olmayan akciğer kanseridir. Bu çalışmanın önemi en doğru tanının en hızlı şekilde konulmasını sağlamaktır. Bu çalışmada küçük hücreli akciğer kanserinin tanısı konulamamaktadır. Bundan dolayı küçük hücreli akciğer kanserine sahip tomografi görüntüsünün tanısı doğru konulamamaktadır. Akciğer kanseri tanısı konulan çalışmalarda genel olarak tek bir algoritma üzerinden değerlendirme yapılmıştır. Bazı çalışmalarda kanserin alt türleri tespit edilmiştir ancak bu çalışmalar tek bir algoritma ile sınıflandırılmıştır. Birden çok algoritmanın karşılaştırıldığı çalışmalarda ise sadece akciğer kanseri olup olmadığına dair tanı konulmaktadır. Alt türünün tanısı konulamamaktadır. Bu tez çalışmasında hem akciğer kanserinin alt türünün tanısı konulmaktadır hem de bu işlemi en iyi yapan algoritma tespit edilmektedir.

Çalışmanın devamı şu şekilde yapılandırılmıştır. İkinci bölümde literatürde bulunan ilgili çalışmalar açıklanmıştır. Üçüncü bölümde kullanılan yöntemler açıklanmıştır. Kullanılan yöntemler arasında öznetelik çıkarımı için dalgacık

dönüşümü, öğrenme teknikleri olarak yapay sinir ağı, evrişimsel sinir ağı, VGG16, ResNet101, destek vektör makinesi, naive bayes ve k en yakın komşu modelleri uygulanmıştır. Yapay sinir ağında kullanılan öğrenme algoritmaları, momentumlu dereceli azalma, Levenberg-Marquardt ve ölçeklendirilmiş eşlenik gradyan algoritmalarıdır. Dördüncü bölümde elde edilen bulgular açıklanmıştır. Beşinci bölümde sonuç ve tartışma verilmiştir.



2. LİTERATÜR ARAŞTIRMASI

Lei ve arkadaşları, çalışmalarında akciğerdeki tümörleri iyi veya kötü olarak sınıflandırmışlardır. Meta Sıralı Set kullanarak Meta Sıralı Ağırlıklı Ağ modelinden yararlanmışlardır. Mow-Net modeli ile 0.6870 doğruluk oranı elde edilmiştir (Lei et al, 2021).

Rehman ve arkadaşları, çalışmalarında bilgisayarlı tomografi görüntüsü üzerinde makine öğrenimi teknikleriyle akciğer kanseri tespiti üzerinde çalışmışlardır. Sadece kanseri tespit etmemişlerdir. Kanserinin cinsini de tespit etmişlerdir. Bunlar büyük hücreli karsinom, skuamöz hücreli karsinom ve adenokarsinomdur. En iyi sonuçlar destek vektör makinesi ve k en yakın komşu yöntemleriyle elde edilmiştir. Doğruluk oranları sırasıyla 0.93 ve 0.91'dir (Rehman et al, 2021).

Agnes ve arkadaşları, çalışmalarında akciğer tümörü sınıflandırması üzerine çalışmışlardır. CT görüntüleri üzerinde evrimsel uzun kısa süreli hafızalı sinir ağı (ConvLTSM) ile sınıflandırma yapılmıştır. 0.93 doğruluk oranı elde edilmiştir. Bu sonuç tek başına evrimsel sinir ağı (CNN) ve uzun kısa dönem hafıza (LTSM) modellerinden daha iyi bir sonuçtur (Agnes et al, 2021).

Li ve arkadaşları, çalışmalarında akciğer kanserinin alt türleri arasında histopatolojik görüntüleri kullanarak sınıflandırma çalışması yapmışlardır. Destek vektör makinesi, Lasso-destek vektör makinesi, RELIEF-destek vektör makinesi, lineer ayrık analiz-destek vektör makinesi, bipolar ağaçlar, karar ağaçları ve naive bayes modelleriyle karşılaştırma yapılmıştır. Elde edilen en iyi sonuçlar şu şekildedir. Büyük hücreli karsinom- adenokarsinom arasındaki sınıflandırmada en iyi doğruluk oranını bipolar ağaç, destek vektör makinesi ve RELIEF-destek vektör makinesi algoritmaları elde etmiştir. Bu oran 0.7391'dir. Büyük hücreli karsinom-skuamöz hücreli karsinom arasındaki sınıflandırmada en iyi doğruluk oranını 0.8391 ile RELIEF-SVM elde etmiştir. Adenokarsinom- skuamöz hücreli karsinom arasındaki karşılaştırmada en iyi doğruluk oranını 0.8667 ile bipolar ağaç modeli elde etmiştir (Li et al, 2021).

Chen ve arkadaşları, LDNNET modeli ile akciğerdeki tümörün cinsini sınıflandırma için çalışma yapmışlardır. LDNNET, katmanlar arası doğrudan bağlantısı olan bir derin sinir ağı modelidir. Çalışmalarında LUNA16 ve KAGGLE

DSB 2017 veri setlerini kullanmışlardır. LUNA16 veri setinde 0.9883 doğruluk oranı, 0.9945 özgüllük, 0.9820 hassaslık elde edilmiştir. KAGGLE DSB 2017 veri setinde ise 0.9994 doğruluk oranı, 0.9996 özgüllük, 0.9989 hassaslık elde edilmiştir (Chen et al, 2021).

Ali ve arkadaşları, bilgisayarlı tanı sistemi üzerinde hazır yapay zekâ modellerini destek vektör makinesi ve AdaBoostM2 algoritmalarıyla optimize etmişlerdir. LUNGx verisetini kullanmışlardır. Bu algoritmalar sayesinde doğruluk oranları artmıştır. Doğruluk oranı artışında destek vektör makinesi, AdaBoostM2'ye karşı üstün gelmiştir. En iyi doğruluk oranı Res-Net-101 modelinin SVM ile optimizasyonu ile elde edilmiştir. Bu oran 0.8628'dir (Ali et al, 2021).

Surendar ve Bala, bilgisayarlı tomografi görüntüleri üzerinde derin sinir ağları ile uyarlanabilir sinüs kosinüs karga araması algoritmalarının hibrit modeli ile akciğer tümörlerinin sınıflandırılması üzerinde çalışma yapmışlardır. 0.9917 doğruluk oranı elde etmişlerdir (Surendar and Bala, 2021).

Nanglia ve arkadaşları, ileri beslemeli geri yayımlı sinir ağı ile destek vektör makinesi algoritmalarını birleştirerek Kernel Attribute Selected Classifier adlı hibrit algoritmayı geliştirmişlerdir. Bu algoritma akciğer kanseri sınıflandırması yapmaktadır. Genetik algoritma ile de optimizasyon yapılmaktadır. Bu algoritma 0.9808 doğruluk oranı elde etmektedir (Nanglia et al, 2020).

Moitra ve Mandal, küçük hücreli olmayan akciğer kanseri sınıflandırması üzerinde çalışma yapmışlardır. Tek boyutlu evrişimsel sinir ağı modelini kullanmışlardır. Bu modelin, iki ve üç boyutlu evrişimsel sinir ağı modelleri gibi kullanışlı olduğu anlaşılmıştır. 0.96 doğruluk oranı elde edilmiştir (Moitra and Mandal, 2020).

ALzubi ve arkadaşları, maksimum olabilirlik artışlı optimize ağırlıklı sinir ağını kullanarak kanser hastalığı teşhisi üzerine çalışma yapmışlardır. Newton-Raphsons maksimum olabilirlik ve minimum artıklık modeli ile sınıflandırma süresini azaltmışlardır. 0.93 doğruluk oranı elde edilmiştir (ALzubi et al, 2019).

Toğaçar ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde hazır LeNet, AlexNet ve VGG-16 evrişimsel sinir ağları modellerine, lineer regresyon, lineer ayrık analiz, karar ağaçları, destek vektör makinesi, k en yakın komşu ve softmax sınıflandırıcılarını ekleyerek akciğer kanseri tespiti üzerinde çalışma

yapmışlardır. En iyi doğruluk oranı AlexNet'e k en yakın komşu eklenerek 0.9874 olarak elde edilmiştir. Minimum fazlalık maksimum alaka metodu uygulanınca başarı oranı 0.9951'e çıkmıştır (Toğaçar et al, 2019).

Bebas ve arkadaşları, adenokarsinom ve skuamöz hücreli karsinom akciğer kanseri türleri arasında sınıflandırma yapmışlardır. PET/MR görüntülerinde destek vektör makinesi, k en yakın komşu, rastgele orman ve derin öğrenme algoritmalarını uygulamışlardır. En iyi doğruluk oranını 0.7548 ile destek vektör makinesi algoritmasıyla yakalamışlardır (Bebas et al, 2021).

Huang ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde derin transfer evrişimsel sinir ağı ile ekstrem öğrenen makine yöntemlerini kullanarak, akciğer tümörlerinin iyi veya kötü huylu olduğuna dair sınıflandırma yapmışlardır. LIDC-IDRI veri seti üzerinde yapılan bu çalışmada 0.9457 doğruluk oranı, 0.9369 hassaslık ve 0.9515 özgüllük elde edilmiştir (Huang et al, 2020).

Zhang ve arkadaşları, hazır evrişimsel sinir ağı modellerini kullanarak, üç boyutlu bilgisayarlı tomografi görüntüleri üzerinde akciğerdeki tümörün cinsini tespit etmek için çalışma yapmışlardır. Bu hazır modelleri 3 boyutlu bilgisayarlı tomografi görüntülerini işleyebilecek hale getirmişlerdir. En iyi doğruluk oranı, özgüllük ve kesinlik DenseNet121 modeli ile elde edilmiştir. Bunlar sırasıyla 0.8777, 0.9238 ve 0.8788'dir. En iyi hassaslık 0.8273 ile Xception aracılığıyla elde edilmiştir (Zhang et al, 2019).

Tiwari ve arkadaşları, hedef tabanlı ağırlıklı DL Elman sinir ağı ve maske tabanlı 3FCM algoritmalarını kullanarak bilgisayarlı tomografi görüntülerinde akciğer tümörü ve kanseri tespiti üzerinde çalışma yapmışlardır. Bu çalışmada 0.96 doğruluk oranı elde edilmiştir (Tiwari et al, 2021).

Asuntha ve Srinivasan, bilgisayarlı tomografi görüntüleri üzerinde akciğer kanseri tümörü tespiti için çalışma yapmışlardır. Bulanık parçacık sürüsü optimizasyonu algoritmasını kullanarak, özellik seçiminde en iyi özelliği seçmişlerdir. En iyi doğruluk oranı, bulanık parçacık sürüsü optimizasyonu evrişimsel sinir ağı ile elde edilmiştir. Bu oran 0.9931'dir (Asuntha and Srinivasan, 2020).

Madan ve arkadaşları, evrişimsel sinir ağı yöntemiyle bilgisayarlı tomografi görüntülerinde akciğer kanseri tespiti üzerinde çalışma yapmışlardır. Doğruluk oranı

0.93, kesinlik oranı 0.893, hatırlama oranı 0.72, özgüllük oranı 0.982 olarak elde edilmiştir (Madan et al, 2020).

Jawarkar ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde evrimsel sinir ağı yöntemini uygulayarak hem akciğer kanserini hem de derecesini tespit etmişlerdir. 0.9688 doğruluk oranı elde etmişlerdir (Jawarkar et al, 2021).

Subramanian ve arkadaşları, AlexNet hazır modeline; destek vektör makinesi, derin k en yakın komşu ve softmax algoritmalarını uygulayarak bilgisayarlı tomografi görüntüleri üzerinde akciğer kanseri tahmini üzerinde çalışmalar yapmışlardır. En iyi doğruluk oranı AlexNet modelinin softmax ile olan birleşiminden elde edilmiştir. Bu oran 0.9952'dir (Subramanian et al, 2020).

Serj ve arkadaşları, derin CNN yöntemiyle Kaggle-DSB-2017 veriseti aracılığıyla akciğer kanseri teşhisi üzerinde çalışma yapmışlardır. 0.94 doğruluk oranı, 0.87 hassaslık, 0.991 özgüllük ve 0.95 F1 puanı elde edilmiştir (Serj et al, 2018).

Yektai ve Manthouri, bilgisayarlı tomografi görüntüleri üzerinde çok ölçekli evrimsel sinir ağı yöntemini kullanarak akciğer kanserini teşhis etmişlerdir. Bu çalışmada 0.937 doğruluk oran elde edilmiştir (Yektai and Manthouri, 2020).

Nasser ve Abu-Nasser, yapay sinir ağlarıyla akciğer kanseri tespiti üzerine çalışma yapmışlardır. Sarı parmaklar, alerji, öksürük, nefes darlığı, göğüs ağrısı vb. semptomları parametre olarak kullanmışlardır. 0.9667 doğruluk oranı elde edilmiştir (Nasser and Abu-Nasser, 2019).

Numan ve arkadaşları, ileri beslemeli sinir ağları ile akciğer kanseri tespiti üzerinde bir çalışma yapmışlardır. Tümör boyutu ve yaş gibi parametreler kullanılmıştır. Akciğer kanserinin beş aşaması vardır ve bu beş aşama tespitinde elde edilen doğruluk oranları şu şekildedir. Birinci aşama 0.9621, ikinci aşama 0.874, üçüncü aşama 0.823, dördüncü aşama 0.797 ve beşinci aşama 0.753'tür (Numan et al, 2016).

Shakeel ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde gelişmiş bol kümeleme tekniğini ve anında eğitilen derin öğrenmeli sinir ağlarını kullanarak akciğer kanseri tespiti üzerinde çalışma yapmışlardır. 0.9842 doğruluk oranı elde edilmiştir (Shakeel et al, 2019).

Alakwaa ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde 3 boyutlu evrişimsel sinir ağı modeli ile akciğer kanseri tanısı üzerinde çalışma yapmışlardır. Veri seti olarak Kaggle Data Science Bowl 2017'yi kullanmışlardır. Eşikleme yöntemiyle bölümleme yapmışlardır. 0.8660 doğruluk oranı elde etmişlerdir (Alakwaa et al, 2017).

Karaçavuş ve arkadaşları, PET/BT görüntüleri üzerinde çeşitli doku analizi yöntemlerini kullanarak küçük hücreli olmayan akciğer kanserini evreleme çalışması yapmışlardır. Sınıflandırma algoritması olarak k en yakın komşu algoritması kullanılıp, $k = 3$ ve Öklid uzaklık algoritması seçilmiştir. En iyi doğruluk oranı entropi, sivrilik ve homojenize teknikleri kullanılarak 0.8108 olarak elde edilmiştir (Karaçavuş vd, 2014).

Rao ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde evrişimsel sinir ağı aracılığıyla, akciğerde bulunan tümörlerin iyi veya kötü huylu olduğunu tespit etmek üzere çalışma yapmışlardır. Bunun için CanNet adında model geliştirmişlerdir, yapay sinir ağı ve LeNet modelleri ile karşılaştırma yapmışlardır. CanNet modeli ile 0.7600 doğruluk oranı elde etmişlerdir. Bu oran hem yapay sinir ağı hem de LeNet ile elde edilen doğruluk oranından daha büyüktür (Rao et al, 2014).

Tekade ve Rajeswari, bilgisayarlı tomografi görüntülerinde U-Net mimarisini ve 3 boyutlu VGG benzeri ağı birleştirerek akciğer kanserini tespit etmeye çalışmışlardır. Veri seti olarak LUNA16 ve Kaggle Data Science Bowl 2017'yi kullanmışlardır. 0.9560 doğruluk oranı elde edilmiştir (Tekade and Rajeswari, 2018).

Song ve arkadaşları, bilgisayarlı tomografi görüntülerinde akciğerdeki tümörlerin sınıflandırmasını yapmışlardır. Evrişimsel sinir ağları, derin sinir ağları ve seyrek otomatik kodlayıcı algoritmaları arasında karşılaştırma yapmışlardır. Görüntüleri LIDC-IDRI veri tabanından elde etmişlerdir. En iyi sonuç evrişimsel sinir ağı algoritmasıyla elde edilmiştir. Doğruluk oranı 0.8415, hassaslık 0.8396 ve özgüllük 0.8432'dir (Song et al, 2017).

Sun ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinden derin öğrenme yöntemlerini kullanarak akciğer kanseri tanısı üzerinde çalışmışlardır. Evrişimsel sinir ağı, derin inanç ağları ve istiflenmiş gürültü giderici otomatik kodlayıcı algoritmalarıyla ve geleneksel bilgisayarlı tanı sistemi arasında karşılaştırma yapmışlardır. Evrişimsel sinir ağı algoritmasından elde edilen doğruluk oranı 0.7976,

derin inanç ağı algoritmasından elde edilen doğruluk oranı 0.8119, istiflenmiş gürültü giderici otomatik kodlayıcı algoritmasından elde edilen doğruluk oranı 0.7929 ve geleneksel bilgisayarlı tanı sisteminden elde edilen doğruluk oranı 0.7940'tır (Sun et al, 2016).

Bhatia ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde derin kalıcı öğrenme metotlarını kullanarak akciğer kanseri tespiti üzerinde çalışma yapmışlardır. U-Net mimarisi ve Rastgele Orman algoritmasının birleşimiyle elde edilen doğruluk oranı 0.7400, ResNet mimarisi ve XGBoost algoritmasının birleşimiyle elde edilen doğruluk oranı 0.7600 ve iki metodun da birleşimiyle elde edilen doğruluk oranı 0.8400'dır (Bhatia et al, 2018).

Elnakib ve arkadaşları, düşük dozlu bilgisayarlı tomografi görüntüleri üzerinde derin öğrenme optimizasyonu tekniklerini kullanarak erken aşamadaki akciğer kanserini tespit etmeye yönelik çalışma yapmışlardır. Optimizasyon için genetik algoritma kullanılmıştır. International Early Lung Cancer Action Project veri setini kullanmışlardır. En iyi sonuç, VGG19 mimarisinin destek vektör makinesi algoritmasının birleşimiyle elde edilmiştir. 0.9625 doğruluk oranı, 0.9750 hassaslık ve 0.9500 özgüllük elde edilmiştir (Elnakib et al, 2020).

Singh ve Gupta, bilgisayarlı tomografi görüntüleri üzerinde akciğer tümörü tespiti ve sınıflandırılması üzerine çalışma yapmışlardır. Çeşitli makine öğrenmesi tekniklerinin karşılaştırılmasını yapmışlardır. En iyi sonuç yapay sinir ağlarıyla elde edilmiştir. 0.8855 doğruluk oranı elde edilmiştir (Singh and Gupta, 2019).

Nasrullah ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde CMixNet mimarisiyle ve gradyan güçlendirme algoritmasıyla akciğerdeki tümörlerin tespiti ve sınıflandırılması üzerine çalışma yapmışlardır. Yanlış tanıyı engellemek için fiziksel semptomlar da dikkate alınmıştır. LIDC-IDRI ve hastaneden elde ettikleri veri setlerini kullanmışlardır. LIDC-IDRI veri setinden 0.8879 doğruluk oranı, 0.9397 hassaslık ve 0.8983 özgüllük elde edilmiştir. Hastane veri setinden ise 0.9417 doğruluk oranı, 0.9800 hassaslık ve 0.9435 özgüllük elde edilmiştir (Nasrullah et al, 2019).

P.R ve arkadaşları, data.world ve UCI Machine Learning Repository veri setleri üzerinde akciğer kanserinin tespiti üzerinde çalışma yapmışlardır. Bunlar özellikli veri setleridir. Naive Bayes, destek vektör makinesi, karar ağaçları ve

lojistik regresyon algoritmaları arasında karşılaştırma yapılmıştır. En iyi sonuç data.world veri seti üzerinde destek vektör makinesi algoritmasıyla elde edilmiştir. Doğruluk oranı 0.9920'dir (PR et al, 2019).

Sangamithraa ve Govindaraju, bilgisayarlı tomografi görüntüleri üzerinde akciğer kanserini tespit etmeye yönelik çalışma yapmışlardır. Öncelikle medyan ve wiener filtreleme yöntemleriyle bilgisayarlı tomografi görüntüsü üzerinde ön işleme yapılmıştır. Sonraki adımda K-means kümeleme yöntemiyle görüntüler kümelenmiştir. Kümelenen bu görüntüler tekrar EK-means yöntemiyle kümelenmiştir. Geri yayımlı ağ ile sınıflandırma işlemi yapılmıştır. 0.9087 doğruluk oranı elde edilmiştir (Sangamithraa and Govindaraju, 2016).

Liu ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde evrimsel sinir ağı algoritması ile akciğer tümörünün tipinin tespiti üzerine çalışma yapmışlardır. LIDC-IDRI ve ELCAP veri setlerini kullanmışlardır. LIDC-IDRI veri setinden elde edilen doğruluk oranı 0.9183, ELCAP veri setinden elde edilen doğruluk oranı ise 0.9116'dır (Liu et al, 2018).

Agnes ve Anitha, bilgisayarlı tomografi görüntüleri üzerinde derin öğrenme teknikleriyle akciğer kanseri tanısı üzerine çalışma yapmışlardır. Yinelenen sinir ağı, uzun kısa vadeli bellek ve evrimsel sinir ağı algoritmalarını karşılaştırmışlardır. Yinelenen sinir ağı ile 0.5290 hassaslık, 0.7380 özgüllük, 0.5980 kesinlik ve 0.6490 doğruluk oranı elde edilmiştir. Uzun kısa vadeli bellek ile 0.8180 hassaslık, 0.9150 özgüllük, 0.8760 kesinlik ve 0.8735 doğruluk oranı elde edilmiştir. Evrimsel sinir ağı ile 0.8100 hassaslık, 0.9110 özgüllük, 0.8780 kesinlik ve 0.8726 doğruluk oranı elde edilmiştir (Agnes and Anitha, 2020).

Shen ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde çok ölçekli evrimsel sinir ağı ile akciğer tümörlerinin sınıflandırılması üzerine çalışma yapmışlardır. LIDC-IDRI veri setinden faydalanmışlardır. Evrimsel Sinir Ağ₁₀ ile gürültü seviyesi 0.5 olan görüntüler incelenmiştir. Evrimsel sinir ağ₁₁ ile gürültü seviyesi 1 olan görüntüler incelenmiştir. Evrimsel sinir ağ₁₂ ile gürültü seviyesi 2 olan görüntüler incelenmiştir. Evrimsel sinir ağ₁₀ ile 0.8612, Evrimsel sinir ağ₁₁ ile 0.8388 ve Evrimsel sinir ağ₁₂ ile 0.7900 doğruluk oranı elde edilmiştir (Shen et al, 2015).

Narayanan ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde destek vektör makinesi algoritması aracılığıyla, akciğerdeki tümörlerin cinsini tespit etmeye yönelik çalışma yapmışlardır. Lung Nodule Analysis 2016 veri setini kullanmışlardır. Sınıflandırmayı 10-fold algoritmasıyla yapmışlardır. Destek vektör makinesi algoritmasıyla 82.82 hassaslık elde edilmiştir (Narayanan et al, 2018).

Shen ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde kendi geliştirdikleri derin hiyerarşik anlamsal evrimsel sinir ağı ile akciğer tümörünün kötü huylu olup olmadığını tespit etmeye çalışmışlardır. İki tür çıktı üretmektedir. Bunlar düşük seviyeli anlamsal özellikler ve yüksek seviyeli kötü huyluluk tahminidir. LIDC veri setini kullanmışlardır. 0.7050 hassaslık, 0.8890 özgüllük ve 0.8420 doğruluk elde edilmiştir (Shen et al, 2019).

Saleh ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde akciğer kanseri tanısı koyma üzerine çalışma yapmışlardır. Ayrıca akciğer kanserinin türünü de tespit etmişlerdir. Chest CT Scan Images veri setini kullanmışlardır. Evrimsel sinir ağı-destek vektör makinesi algoritmasını kullanmışlardır. 0.9791 doğruluk oranı, 0.9790 hassaslık, 0.9932 özgüllük ve 0.9796 hassaslık değeri elde edilmiştir (Saleh et al, 2021).

Abdullah ve arkadaşları, bilgisayarlı tomografi görüntüleri üzerinde akciğer kanseri tahmini ve sınıflandırması üzerine çalışma yapmışlardır. UCI veri setini kullanmışlardır. Evrimsel sinir ağları, destek vektör makinesi ve k en yakın komşu algoritmaları arasında karşılaştırma yapılmıştır. En yüksek doğruluk oranı destek vektör makinesi ile elde edilmiştir. 0.9556 olarak elde edilmiştir. İkinci en yüksek doğruluk oranı evrimsel sinir ağı ile 0.9211 olarak elde edilmiştir. K en yakın komşu ile 0.8965 doğruluk oranı elde edilmiştir (Abdullah et al, 2021).

Al-Huseiny ve Sajid, bilgisayarlı tomografi görüntüleri üzerinde GoogleNet mimarisiyle transfer öğrenmesi metodunu uygulayarak akciğer kanseri tespiti üzerine çalışma yapmışlardır. IQ-OTH/NCCD veri setini kullanmışlardır. 0.9508 hassaslık, 0.9370 özgüllük ve 0.9438 doğruluk oranı elde edilmiştir (Huseiny and Sajid, 2021).

Jeevana ve Charan, X-Ray görüntüleri üzerinde evrimsel sinir ağı algoritmasıyla akciğer kanseri tespiti üzerine çalışma yapmışlardır. 0.8100 kesinlik, 0.8050 duyarlılık, 0.8075 F1 puanı ve 0.8000 doğruluk oranı elde edilmiştir (Jeevana and Charan, 2021).

Patra, bilgisayarlı tomografi görüntüleri üzerinde akciğer tümörlerinin sınıflandırılması üzerine çalışma yapmıştır. UCI veri setinden yararlanmıştır. K en yakın komşu, naive bayes, J48 ve radyal tabanlı fonksiyon algoritmalarını karşılaştırmıştır. 10-fold sınıflandırma yönteminden yararlanmıştır. En iyi sonucu radyal tabanlı fonksiyon algoritması vermiştir. Radyal tabanlı fonksiyon algoritmasıyla 0.8130 kesinlik, 0.8130 duyarlılık, 0.8130 F1 puanı ve 0.8125 doğruluk elde edilmiştir (Patra, 2020).

Literatür araştırmasına göre algoritmaların karşılaştırıldığı çalışmalarda tümörün iyi huylu ya da kötü huylu olduğuna ya da kanser mi değil mi olduğuna bakılmıştır. Kanser türlerini sınıflandırma amaçlı yapılan çalışmalarda ise bir algoritmanın genellikle bir algoritmanın başarımı değerlendirilmiştir. Bazı çalışmalar ise hastanın medikal bilgileri üzerinden kanser değerlendirmesi üzerinedir ancak bu tür çalışmalar görüntü üzerinden yapılan çalışmalar kadar doğru tanı koyabilme yeteneğine sahip değildir.

Bu tez çalışmasında kişinin hem akciğer kanseri olup olmadığının tespiti yapılmaktadır, hem de kanserin alt türü tespit edilmektedir. Bunun yanı sıra yapay zekâ algoritmalarının başarımları da karşılaştırılıp hangi algoritmanın daha başarılı olduğu tespit edilmeye çalışılmıştır.

3. YÖNTEM

3.1 Dalgacık Dönüşümü Algoritması

Dalgacık dönüşümü, işaretin zaman-frekans analizinde kullanılan algoritmadır. Ses ve görüntü gibi birçok farklı sinyal tipine uygulanabileceği görülmüştür. Sinyallerde gürültü temizleme amacıyla kullanılmaktadır. İki boyutlu görüntülerde, satır ve sütunlar bir boyutlu sinyal olarak kullanılır. Dalgacık dönüşümü ayrılabilir olduğundan, geçişler satırlarda ve sütunlarda ayrı ayrı yapılır. (Öner vd, 2017; Zhang, 2019).

Birinci seviye ayrıştırmada öncelikle, görüntü ölçeklenir yani görüntünün ağırlıklı ortalaması alınır ve dalgacık dönüşümü yapılır yani görüntünün ağırlıklı farkı alınır. Bu işleme dikey dönüştürme denir. İlk adımın çıktısı olarak, biri ölçeklenme katsayısına, diğeri dalgacık katsayısına sahip iki adet yarım görüntü oluşmaktadır. İki görüntü de orijinal görüntünün satırının yarısı genişliğindedir. İkinci adımda ölçekleme ve dalgacık dönüşümü, elde edilen iki yarım görüntünün sütunlarına uygulanır. Sonucunda görüntünün yaklaşımı, yatay detayları, dikey detayları ve çapraz detayları olmak üzere dört adet görüntü oluşmaktadır. İkinci ve daha büyük seviyeler elde edilen görüntünün yaklaşımına uygulanır. Görüntü ölçeklenemeyecek hale gelene kadar bu işlem devam eder (Zhang, 2019).

Görüntünün yaklaşımının hesaplaması Eşitlik (3.1)'de, görüntünün dikey detaylarının hesaplaması Eşitlik (3.2)'de, görüntünün yatay detaylarının hesaplaması, Eşitlik (3.3)'te ise görüntünün çapraz detaylarının hesaplaması Eşitlik (3.4)'te açıklanmaktadır.

$$\phi(x, y) = \phi(x)\phi(y) \quad (3.1)$$


$$\psi^H(x, y) = \phi(x)\psi(y) \quad (3.2)$$

$$\psi^V(x, y) = \psi(x)\phi(y) \quad (3.3)$$

$$\psi^D(x, y) = \psi(x)\psi(y) \quad (3.4)$$

Φ ölçeklendirme fonksiyonunu, ψ dalgacık fonksiyonunu, x satırı ve y sütunu temsil etmektedir. Şekil 3.1'de dalgacık dönüşümü işleminin gerçekleşmesi görülmektedir ve dalgacık ağacı olarak bilinen bu ağaç yapısı görüntüyü önce yarısı daha düşük çözünürlükte ve diğer yarısı daha yüksek çözünürlükte olacak şekilde iki alt görüntüye ayırır. Bu alt görüntüler daha sonra yine dalgacık ağacı yapısı

kullanılarak ayrıştırılır ve bu ağaç bileşenlerinden gerekli özellikler seçilerek öznitelik çıkarılır ve birçok uygulamada kullanılır.



Şekil 3.1. Dalgacık Dönüşümü İşlemi

3.2 Veri Seti

Veri seti olarak Kaggle Chest CT-Scan kullanılmıştır (Hany, 2020). Kullanılan veri seti bilgisayarlı tomografi görüntülerinden meydana gelmektedir. Veri setindeki görüntüler standart boyutta değildir. Bundan dolayı görüntüler, 80×40 boyutuna indirgenerek standartlaştırılmıştır. Veri setinde dört adet sınıf bulunmaktadır. Sınıfların isimleri normal, adenokarsinom, büyük hücreli karsinom ve skuamöz hücreli karsinomdur.

Normal sınıfında, akciğer tomografisinde herhangi bir tümör bulunmamaktadır. Bundan dolayı görüntüde beyaz kristaller nadir görülmektedir. Şekil 3.2’de normal sınıfına ait akciğer tomografisi görülmektedir.



Şekil 3.2: Normal sınıfına ait akciğer tomografisi


Adenokarsinom, küçük hücreli olmayan kanser hücrelerinden biridir. Tüm akciğer kanserlerinin yaklaşık %40'ını oluşturduğundan, en yaygın akciğer kanseri türü olarak kabul edilmektedir. Beş yıllık yaşama oranları %20'den azdır. Mukus ve diğer maddeleri salgılayan epiteli ve tip 2 alveol hücrelerinden gelişmektedir. Gen mutasyonları, hücrenin ölümüne karşı kanser hücresi duyarlılığını düzenlemektedir. Bundan dolayı, tedavi duyarlılığındaki farklar adenokarsinom hücrelerinin ölümüne duyarlılığına bağlıdır (Peng et al, 2022, Zhang et al, 2022). Şekil 3.3'de adenokarsinom hücreli akciğerin tomografi görüntüsü görülmektedir.



Şekil 3.3: Adenokarsinom hücreli akciğer tomografisi


Büyük hücreli karsinom, küçük hücreli olmayan kanser türlerinden biridir. Tüm akciğer kanserlerinin yaklaşık %10'unu oluşturmaktadır. Kanser evresine göre cerrahi operasyon, kemoterapi, radyasyon tedavisi, hedefe yönelik tedavi ve immünoterapi gibi yöntemlerle tedavi sağlanmaktadır. Büyük hücreli karsinomun diğerlerinden ayrımı zordur, bundan dolayı cerrahi operasyon geçirmiş hastalarda beş yıllık yaşama oranı yaklaşık %38'dir. Ayrımı ışık mikroskobu aracılığıyla

yapılmaktadır. Hızlı büyümektedir ve tanısı konulduğunda oldukça büyüktür. Radyografik görünümleri genellikle 4 cm'den büyüktür. Metastazlar oldukça geç ortaya çıkmaktadır. (Iwasaki, 2000; Wu et al, 2022). Şekil 3.4'te büyük hücreli karsinoma sahip akciğerin tomografisi görülmektedir.



Şekil 3.4: Büyük hücreli karsinoma sahip akciğer tomografisi

Skumöz hücreli karsinom, adenokarsinomdan sonra en yaygın küçük hücreli olmayan kanser türüdür. Akciğer kanseri hastalarının yaklaşık %30'u skumöz hücreli karsinom hücrelerine sahiptir. Tedavisi, diğer küçük hücreli olmayan kanser hücrelerine göre zordur ancak geçmiş yıllara nazaran daha iyi hale gelmiştir. Genellikle merkezi bölgelerde görülmektedir. (Moin et al, 2021; Na et al, 2022; Wistuba and Gazdar, 2006). Şekil 3.5'te skumöz hücreli karsinoma sahip akciğerin tomografisi görülmektedir.



Şekil 3.5: Skumöz hücreli karsinoma sahip akciğer tomografisi

Veri seti dengesiz olduğundan ve başarı oranlarının artması için veri artırımı metotları uygulanmıştır. Görüntüler 15 derece sağa ve sola çevrilmiştir ve parlaklıkları artırılıp azaltılmıştır. Tablo 3.1'de veri setinin sınıflara göre dağılımı görülmektedir.


Tablo 3.1: Veri setinin sınıflara göre dağılımı

	Normal	Adenokarsinom	Büyük Hücreli Karsinom	Skvamöz Hücreli Karsinom
Artırılmamış	215	338	187	260
Arttırılmış	1935	3042	1683	2340

3.3 Öğrenme Teknikleri


Danışmanlı öğrenme, makine öğreniminde önemli bir parçadır. Öğrenme süreci, gözlem değişkenlerinin etiketleri altında yapıldığından danışmanlı öğrenme denir. Danışmanlı öğrenmede, veri seti, makine öğrenmesi modelinin oluşması için eğitim setiyle eğitilir ve sonrasında test setindeki yeni verileri etiketlemek amacıyla kullanılır. Eğitim seti, girdi değişkenlerini içerir, tahmin edilen değişkenin doğruluğunu etkileyecek özellikleri barındırır. Hem nicel hem de nitel değişkenleri içerir. Çıktı değişkeni, danışmanlı öğrenmenin yeni gözlemleri etiketleyeceği etiketlerdir. Çıktı değişkenlerine göre, danışmanlı öğrenmenin işlevi iki türe ayrılır; sınıflandırma işlemi ve regresyon işlemi. Sınıflandırma işleminin çıktı değişkenleri kategorik değişkenlerdir ve regresyon işleminin ise sürekli değişkenlerdir. Örneğin, duygu analizi sınıflandırma işlemidir, hisse senedi fiyatlarının tahmini ise regresyon işlemidir (Wang et al, 2021).

Regresyon, nicel veriler arasındaki ilişkileri tahmin etmede ve bulmada kullanılan danışmanlı öğrenme tekniğidir. En eski öğrenme tekniklerinden biridir ve hala yaygın olarak kullanılmaktadır. Bu teknik aracılığıyla, bir şirketin reklam bütçesi ile satışları arasında bir ilişki olup olmadığı incelenebilir. Ayrıca radyasyon tedavisi ile tümör boyutları arasında bir ilişki olup olmadığı da belirlenebilir. Şekil 3.6'da regresyon örneği görülmektedir.




Şekil 3.6. Regresyon

Verileri analiz ederek veya kalıpları tanıyarak nitel bir yanıtı tahmin etmeye odaklanan tekniklere sınıflandırma denir. Bu teknik aracılığıyla, herhangi bir kredi kartı işleminin hileli olup olmadığını sınıflandırılabilir. Birçok farklı sınıflandırma tekniği bulunmaktadır, yaygın olarak kullanılanlardan bazıları şunlardır; mantıksal regresyon, doğrusal ayrık analiz, k-en yakın komşular, ağaçlar, sinir ağları ve destek vektör makineleridir (Talabis et al, 2015). Şekil 3.7’de sınıflandırma örneği görülmektedir.




Şekil 3.7. Sınıflandırma

Danışmansız öğrenme, etiketlenmemiş ve sınıflandırılmamış verileri kullanır. Danışmansız öğrenmenin amacı, etiketlenmemiş verilerdeki kalıpları keşfetmektir. Danışmanlı öğrenmenin tersine, danışmansız öğrenme yöntemleri, çıktı değerlerinin ne olabileceğine dair hiçbir fikri olmadığından dolayı regresyon veya sınıflandırma problemine direkt uygulanamaz. Kümeleme, veri setindeki kalıpları veya gruplamaları tespit etmek için kullanılan en yaygın danışmansız öğrenme algoritmasıdır. Danışmansız öğrenmede kullanılan yaygın algoritmalar şunlardır; kümeleme, anormallik algılama ve sinir ağlarıdır (El Bouchefry and De Souza, 2020). Şekil 3.8’de kümeleme örneği görülmektedir.



Şekil 3.8. Kümeleme


Çok sayıda gerçek dünya makine öğrenimi problemlerinde, az sayıda etiketlenmiş veri ve çok sayıda etiketlenmemiş veri seti bulunmaktadır. Büyük sayıda etiketlenmemiş veri kolayca elde edilebilmektedir, ancak etiketlenmiş veri seti oluşturabilmenin maliyeti yüksektir. Bu sebepten dolayı, doğru öğrenme modelini oluşturabilmek için etiketlenmiş verilerdeki bilgilerin ve etiketlenmemiş verilerdeki bilgilerin birleştirilmesi arzu edilir. Yarı danışmanlı öğrenme, bu tür durumları ele almayı amaçlayan danışmanlı ve danışmansız öğrenmenin bir kombinasyonudur. Yarı danışmanlı öğrenme modelleri arasında EM tabanlı algoritmalar, kendi kendine eğitim, birlikte eğitim, yarı denetimli SVM ve graf tabanlı yöntemler bulunmaktadır (Armoogum and Li, 2019). Şekil 3.9'da yarı danışmanlı öğrenme örneği görülmektedir.



Şekil 3.9. Yarı Danışmanlı Öğrenme

Takviyeli öğrenme, makine öğrenimi modellerinin amaçlarına ulaşabilmesi ve dinamik ortamla etkileşime geçerken manuel yorum olmaksızın bağımsız olarak çalışmasını sağlayan yapay zekâ alanıyla ilgilenir. Bundan dolayı, yazılım ve makineler ideal hale ulaşabilir. Geri bildirimlerden komut alarak nasıl davranış göstereceğini öğrenir ve kendisini geliştirir. Geri besleme sinyaline pekiştirme sinyali denir. Eylemler, danışmanlı öğrenmeden farklı bir biçimde yapılır. Danışmanlı öğrenmede, doğru cevabın öğrenilmesi için talimat verilir. Oysa takviyeli öğrenmede cevap anahtarı bulunmamaktadır. Makine öğrenimi modeli kendi deneyimlerinden öğrenir. Riskleri en aza indirip ödülü en üst düzeye çıkaracak

şekilde kendi kendini gözlemleme yöntemiyle çalışır. Yinelemeli olarak çalışır ve sürekli öğrenir. Şekil 3.10'te takviyeli öğrenme şeması görülmektedir.



Şekil 3.10. Takviyeli öğrenme şeması

Takviyeli öğrenme şu şekilde çalışır. İlk aşamada aracı, giriş durumunu sağlar. Sonraki aşamada eylem, aracının sağladığı karar verme işlevi tarafından gerçekleştirilir. Son aşamada çevre, aracıya ödül sağlar. Takviyeli öğrenme algoritmaları arasında derin çekişmeli ağlar, Q öğrenme ve geçici fark bulunmaktadır (Sengupta et al, 2021). Öğrenme teknikleri makine öğrenimi teknikleri için uygulanabilmektedir.

Makine öğrenimi, verilerin kullanılabilir modellere dönüşebilmesi için hesaplama algoritmalarını kullanan çalışma alanıdır. Yapay zekanın alt dalıdır ve istatistik biliminden faydalanmaktadır. Bilgisayarlara programlanmadan öğrenme yeteneği sağlar ve yeni veriler geldiğinde yeni duruma uyum sağlar. (Edgar and Manz, 2017; Kalali et al, 2019; Subasi, 2020).

Makine öğreniminde öncelikle veriler elde edilir. Elde edilen verilere ön işleme uygulanır. Ön işleme teknikleri arasında, merkezleme, normalleştirme ve ölçeklendirme gibi teknikler uygulanmaktadır. Ön işlemeden geçen verilere özellik çıkarımı teknikleri uygulanır. Bu işlem, ön işlemenin parçası da olabilir. Seçim operatörü regresyonu ve temel bileşen analizi gibi işlemler özellik çıkarma algoritmalarına örnektir. Modeldeki veriler eğitim ve test seti olarak ayrılır. K katlı, birini dışarıda bırak veya genel çapraz doğrulama yöntemlerinden biri uygulanmaktadır. Eğitim verileriyle model eğitilir, bu işlem birkaç kez uygulanır. Performansların karşılaştırılması için diğer makine öğrenimi modelleri de eğitilebilir. Genellikle en iyi doğruluk oranını veren model tercih edilir. Son olarak test verileri modele gösterilir, bu şekilde hiç görmediği verilerde nasıl tahmin yaptığı gözlemlenir

(Tuena, 2022). Sınıflandırma işlemlerinde modeller genellikle lineer değildir. Bundan dolayı aktivasyon fonksiyonları kullanılır.

Derin öğrenme, makine öğreniminin alt dalıdır. Çok katmanlı sinir ağlarını kullanarak verileri yorumlar. Model, amaç fonksiyonu aracılığıyla eğitilir. Amaç fonksiyonu, modelin amacı hakkında bilgi vermektedir. Danışmanlı, danışmansız ve yarı-danışmanlı öğrenme modeli olarak kullanılabilir. (Mao vd, 2019; Santosh vd, 2022).

Derin öğrenme modelleri, özellik çıkarma uygulanmaksızın ham verilerden öğrenebilmektedir. Görüntü verilerinde, gereksiz veri ve gürültü bulunabilmektedir. Evrişimsel sinir ağları aracılığıyla görüntüler kolaylıkla işlenebildi. Uzun kısa süreli bellekler sayesinde ise sıralı veriler işlenebilmektedir. Derin ağlarda karmaşık fonksiyonlar daha rahat temsil edilebilir ancak patlayan veya kaybolan gradyan problemiyle karşılaşmaktadır. Uzun kısa süreli bellekler, sıralı verilerde bu durumun üstesinden gelmiştir ancak görüntü verilerinde hala bu problem devam etmekteydi. Evrişimsel sinir ağları, özellik çıkarımı konusunda oldukça başarılıdır ancak derinlik büyüdüğünde gradyan problemleri devam etmektedir. AlexNet gibi mimarilerin oluşmasıyla bu sorunun üstesinden gelinmiştir. Derin sinir ağları; sınıflandırma, tespit, segmentasyon, kavramsallaştırma ve sıralı öğrenme gibi problemlerin çözümü için kullanılmaktadır (Santosh vd, 2022).

Aktivasyon fonksiyonları, sinir ağındaki lineer olmayan varyasyonların oluşturulması amacıyla kullanılmaktadır. Doğrusal aktivasyon fonksiyonları geri yayılım işlemini yerine getiremez, bundan dolayı sinir ağlarında kullanılması tavsiye edilmemektedir. Aktivasyon fonksiyonu olmayan bir model, verilen görevi doğrusal şekilde gerçekleştirmesine rağmen verimlilik ve doğruluk bakımından yoksundur. Aktivasyon fonksiyonu, sistemin zor görevleri öğrenmesini ve yürütmesini sağlarsa yeterli derecede güçlüdür. Aktivasyon fonksiyonları sayesinde sinir ağı daha güçlü hale gelir (Tharsanee et al, 2021).

Aktivasyon fonksiyonları, bir sonraki katmanın girdisi olacak olan mevcut katmandaki çıktının belirlenmesi için çeşitli ağırlık ve girdi değerlerinin çarpımının toplamını eşik değeri ile hesaplar (Jain et al, 2021). Optimizasyon işlemlerinin gerçekleşebilmesi için aktivasyon fonksiyonları sınırlı, sürekli, monotonik ve ağırlıklara göre sürekli türevlenebilir olmalıdır (Bakr and Negm, 2012).

En yaygın olarak kullanılan aktivasyon fonksiyonlarından biri sigmoid aktivasyon fonksiyonudur (Bakr and Negm, 2012). Sürekli olarak türevlenebilmektedir 0 ile 1 aralığındaki giriş sinyallerini basit bir biçimde eşleyebilmektedir. Sigmoid fonksiyonu, aktivasyon fonksiyonu olarak iyi özelliklere sahiptir. Matematiksel açıdan, orta ve iki taraflı bölgelerde sinyal kazanımı üzerinde farklı bir etkiye sahiptir (Liu, 2020). Sigmoid aktivasyon fonksiyonu Eşitlik (3.5)'te, türevi ise Eşitlik (3.6)'da açıklanmaktadır.

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

$$\sigma'(x) = \sigma(x)(1 - \sigma(x)) \quad (3.6)$$

ReLU fonksiyonu, Richard HR Hahnloser ve arkadaşları tarafından geliştirilen aktivasyon fonksiyonudur. Bu yöntem sayesinde, derin öğrenme tekniklerinde eğitimin daha iyi sonuçlar verdiği görülmektedir çünkü ReLU fonksiyonu patlayan ve kaybolan gradyanlar problemlerine karşı daha dayanıklıdır. Aktivasyon fonksiyonuna gelen değerler 0'dan küçükse 0 olarak dışarı çıkar değilse aynı şekilde dışarı çıkar (Agarap, 2018; Suk, 2017). Eşitlik (3.7)'de ReLU aktivasyon fonksiyonu açıklanmaktadır.

$$y = \max(0, x) \quad (3.7)$$

Eşitlik (3.7)'de x girdiyi, y çıktığı temsil etmektedir.

Hiperbolik tanjant fonksiyonu, en yaygın kullanılan aktivasyon fonksiyonlarından biridir (Wang et al, 2019). Hiperbolik tanjant fonksiyonu -1 ile 1 aralığında bulunan S şeklindeki bir eğridir (Arul, 2021). Hiperbolik tanjant fonksiyonu kaybolan gradyan problemiyle karşılaşabilmektedir (Suk, 2017). Eşitlik (3.8)'de hiperbolik tanjant aktivasyon fonksiyonu, Eşitlik (3.9)'da türevi açıklanmıştır.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.8)$$

$$\tanh'(x) = 1 - \tanh^2(x) \quad (3.9)$$

Softmax fonksiyonu, sabit değerleri 0 ile 1 aralığında eşler ve toplamalarını 1 olarak tutar. Görüntü işleme ve doğal dil işleme uygulamalarında kullanılır, derin öğrenme modellerinde çok sınıflı sınıflandırma işlevini yerine getirmektedir. Girdi olarak dizi halindeki öznitelikleri alır ve doğrusal olmayan haritalama yoluyla

sınıflandırma sonucu elde edilir (Li et al, 2018). Eşitlik (3.10)'da softmax aktivasyon fonksiyonu açıklanmaktadır.

$$s(x)_i = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}} \quad (3.10)$$

Eşitlik (3.10)'da s softmax fonksiyonunu, x girdiyi, N dizideki eleman sayısını, i ve j indisleri temsil etmektedir.

Doğrusal olmayan fonksiyon dizisi olan işaret (signum) fonksiyonu, bazı işlemsel yükselteçler kullanılarak elde edilebilen devre uygulamalarına sahiptirler. Geleneksel aktivasyon fonksiyonlarıyla karşılaştırıldığında, işaret aktivasyon fonksiyonunun bazı avantajı vardır. İşaret aktivasyon fonksiyonu, devreler için daha kolay bir yapıya sahiptir, bu sayede fiziksel uygulaması kolaylaşır. Hatanın işareti doğru elde edildiği sürece ekstradan hatanın doğru hesaplanmasına gerek yoktur, bu da işaret fonksiyonu kullanılan sinir ağlarının daha sağlam olduğunu gösterir (Zhang et al, 2017).


İşaret fonksiyonu Eşitlik (3.11)'de açıklanmaktadır.

$$sgn(x) = \begin{cases} -1, & y < 0 \text{ ise} \\ 0, & y = 0 \text{ ise} \\ 1, & y > 1 \text{ ise} \end{cases} \quad (3.11)$$

3.3.1 Yapay Sinir Ağları

Yapay sinir ağları mimarisi, beyindeki sinir ağlarının yapısına ve işlevine benzemektedir. Nöronlar beyne hatırlama, akıl yürütme ve uygulama yeteneği verir. Beyinde yaklaşık 100 milyar nöron vardır ve insan beyninin gücü bu nöronların çok sayıda olmasından ve aralarındaki çoklu bağlantılardan gelir (Imran ve Alsuhbani, 2019). Beyinde bulunan nöronlardaki gibi, yapay sinir ağları çeşitli katmanlarda düzenlenmiş nöronlardan oluşmaktadır. Yapay sinir ağları, örüntü tanımayı gerçekleştirme amacıyla harici verileri almak için bir giriş katmanı, problemin çözümünü üreten bir çıkış katmanı ve diğer katmanları birbirinden ayıran gizli katmandan oluşur. Giriş katmanından çıkış katmanına doğru birbirine bitişik nöronlar, döngüsel olmayan yaylarla bağlanır. Yapay sinir ağları, hedef çıktı ile gerçek çıktı arasındaki hata oranına bağlı olarak nöron ağırlıklarını değiştiren eğitim algoritmasından yararlanır. Yapay sinir ağları, veri setini öğrenebilmek için eğitim


algoritması olarak geri yayılım algoritmasını kullanır (Sairamya et al, 2019). Şekil 3.11’de örnek yapay sinir ağları modeli görülmektedir.



Şekil 3.11. Örnek yapay sinir ağları modeli

Yapay sinir ağları, genel ilişkileri modellemek için kullanılan güçlü bir tekniktir. Uzaktan algılama, biyomedikal mühendisliği, örüntü tanıma, üretim alanında ve bunun gibi alanlarda kullanılmaktadır.

Yapay sinir ağları, nöronlardan oluşur. Nöronlar, kendinden önceki nöronların ağırlıklı çıktılarını alır ve belirli bir aktivasyon fonksiyonu aracılığıyla yeni çıktı oluşturur. Şekil 3.12’de nöronun yapısı görülmektedir.



Şekil 3.12. Nöronun yapısı

Önceki katmandan gelen ağırlıklı girdiler ve eşik değeri aracılığıyla toplam fonksiyonu hesaplanır. Eşitlik (3.12)’de toplam fonksiyonu açıklanmaktadır.

$$y_i^l = \left(\sum_k w_{ik}^l \times x^{l-1} \right) + b_i^l \quad (3.12)$$

Eşitlik (3.12)'de y çıktıyı, l katmanı, i nöronun ait olduğu katmandaki indisini, x girdiyi, k girdinin ve ağırlığın indisini, w ağırlığı ve b eşik değerini ifade etmektedir. Toplam fonksiyonundan gelen çıktı aktivasyon fonksiyonundan geçer. Eşitlik (3.13)'te aktivasyon fonksiyonu gösterilmektedir.


$$z_i^l = \sigma(y_i^l) \quad (3.13)$$

Eşitlik (3.13)'te y toplam fonksiyonunun çıktısını, l bulunduğu katmanı, i nöronun indisini, σ sigmoid aktivasyon fonksiyonunu ve z aktivasyon fonksiyonunun çıktısını ifade etmektedir.

Literatürde farklı yapay sinir ağları tipleri bulunmaktadır. Bunlar nöronların birbirine bağlanma şekillerine ve eğitim türlerine göre sınıflandırılır. Çok katmanlı algılayıcı (MLP) en sık kullanılan yapay sinir ağı modeli olarak öne çıkmaktadır (Bakr and Negm, 2012).

Çok katmanlı algılayıcı, ileri beslemeli sinir ağı modelidir. Üç katmandan meydana gelir; giriş katmanı, çıkış katmanı ve gizli katman. Giriş katmanı, işleme yapılması için giriş sinyalini alır. Tahmin ve sınıflandırma işlemleri çıktı katmanında gerçekleştirilir. Giriş ve çıkış katmanı arasında bulunan gizli katman, çok katmanlı algılayıcının hesaplama işlemlerini yaptığı yerdir. İleri beslemeli ağda olduğu gibi çok katmanlı algılayıcılarda, veriler giriş katmanından çıkış katmanına doğru ilerler. Çok katmanlı algılayıcıda nöronlar, geri yayılım öğrenme algoritması ile eğitilir. Çok katmanlı algılayıcılar, sürekli fonksiyonların değerlerine yaklaşmak için tasarlanmıştır ve doğrusal olarak ayıramayan sorunların çözümünde kullanılırlar. Çok katmanlı algılayıcıların başlıca kullanım durumları, örüntü sınıflandırması, tanıma ve tahmindir. Şekil 3.11'de çok katmanlı algılayıcı modeli görülmektedir (Abirami and Chitra, 2020). Eşitlik (3.12)'de toplam fonksiyonu, Eşitlik (3.13)'te aktivasyon fonksiyonu açıklanmaktadır.

Hopfield sinir ağları, oto-ilişkisel bellek uygulayarak sinirsel hesaplama paradigmasını temsil eder. Tekrarlayan veya tamamen birbirine bağlı sinir ağlarıdır. Hopfield sinir ağının N adet hücresi varsa $p = [p_1, p_2, \dots, p_N]$ boyutunda referans deseni yani beklenen çıktı vardır. Nöronların değeri ve referans desenindeki değerler 1 veya -1'dir. Şekil 3.13'te hopfield sinir ağı örneği görülmektedir.



Şekil 3.13. Hopfield Sinir Ağı örneği

Ağın eğitimi yapılmadan önce ağırlıkların değeri belirlenir. Eşitlik (3.14)’te açıklanmaktadır.

$$w_{ij} = \left(\frac{1}{N}\right) \times \sum_{p=1}^M x_i^p \times x_j^p \quad \text{Eğer } i \neq j \text{ ise} \quad (3.14)$$

$$w_{ij} = 0 \quad \text{Eğer } i = j \text{ ise}$$

Ağın eğitim işleminde toplam fonksiyonu devreye girer. Eşitlik (3.15)’te toplam fonksiyonu açıklanmaktadır.

$$T_t(i) = \sum_{j=1}^N x_t(j) \times w_{ij} + b_i \quad (3.15)$$


Eşitlik (3.4)’te T toplam değerini, t iterasyonu, N bağlı hücre sayısını, j ve i ağırlık indisini, x girdiyi ve b eşik değerini ifade etmektedir. Toplam fonksiyonundan sonra işaret fonksiyonu devreye girer. Ağ durağan hale geldiğinde ağın eğitim işlemi tamamlanır. Ağın durağan hale gelmesi enerji fonksiyonunun minimum haline gelmesi demektir. Enerji fonksiyonu Eşitlik (3.16)’da açıklanmaktadır.

$$E(t) = \left(\frac{1}{2}\right) \times \sum_{i=1}^N \sum_{j=1}^N w_{ij} \times x_i(t) \times x_j(t) - \sum_{i=1}^N b_i \times x_i(t) \quad (3.16)$$

Hopfield sinir ağları optimizasyon problemlerinin çözümü için uygulanmaktadır. Tıbbi görüntü işlemede, görüntü restorasyonunda, görüntü bölütleme ve sınır saptamada uygulanırlar (Meyer-Baese and Schmid, 2014).

Radyal temel fonksiyonu (RBF) sinir ağları, temel yapay sinir ağları mimarisinin bir varyasyonudur. RBF modelinde üç katman bulunur; girdi katmanı, doğrusal olmayan RBF aktivasyonu içeren gizli katman ve çıkış katmanı. Doğrusal

olmayan RBF aktivasyonunun kullanmasının amacı, sinir çok sayıda sisteminin yerel olarak ayarlanmış alıcı alanlara sahip nöronlardan oluşmasıdır. Şekil 3.14'te örnek RBF sinir ağı görülmektedir.



Şekil 3.14. RBF sinir ağı


RBF ağları üç aşamada eğitilir. İlk adım, gizli katmandaki RBF nöronları için merkez vektörleri seçilir. RBF merkezleri, danışmanlı öğrenme aracılığıyla bir dizi veriden rastgele seçilebilir veya danışmansız öğrenme aracılığıyla k-ortalama kümeleme yöntemi kullanılarak tanımlanabilir. Sonraki adımda, tahmin edilen ve hedef değerlerin çıkarılmasından kaynaklanan hedef değer tahmini ve hata teriminin bulunması için nokta çarpımı ve amaç fonksiyonu kullanarak ağırlıkları katmanların çıktılarıyla ilişkilendirilen doğrusal modeli bulmayı içerir. Üçüncü adımda, geri yayılım yapılarak tüm RBF ağ parametrelerinin güncellenir (Pantazi et al, 2020).

3.3.2 Destek Vektör Makinesi

Destek vektör makinesi, özellikleri birbirinden ayırır. Aynı özellikler bir düzlemde, başka özellikler başka bir düzlemde bir araya gelir. Destek vektör makinesi, özellikleri birbirinden ayırmak için düzlem, çizgiler ve hiper düzlemleri kullanır. Bir boyutlu verilerin sınıflandırılması için çizgi, iki boyutlu verilerin sınıflandırılması için düzlem ve üç boyutlu verilerin sınıflandırılması için hiper düzlemler kullanılır. İnsan daha yüksek boyutları algılayamaz, ancak bilgisayarlar bu konuda yardımcı olabilir (Bhargava et al, 2020). Destek Vektör Makineleri ve Kernel yöntemleri, doğal ve etkili bir şekilde birlikte çalışmaktadırlar. Destek vektör

makineleri, yüksek boyutlu özellik uzaylarında tahmin edicileri öğrenmek için kernel kullanır (Zoppis et al, 2019).

Destek vektör makineleri, en yaygın makine öğrenimi algoritmalarından biridir. 1960'larda geliştirildiğinden beri, muazzam miktarda çalışmada kullanılmıştır (Gudivada et al, 2016). Destek vektör makineleri, son yıllardaki en başarılı makine öğrenimi tekniklerinden birisidir ve mühendislikle ilgili birçok çalışmada başarıyla uygulanmaktadır (Glohami and Fakhari, 2017). Şekil 3.15'te destek vektör makinesi örneği görülmektedir.



Şekil 3.15. Destek vektör makinesi örneği

Destek vektör makinelerinin avantajları şunlardır. Destek vektör makineleri, maksimum marjlı sınıflandırıcılardır. Metin sınıflandırmada oldukça etkililerdir. Destek vektör makineleri, az eğitim verisi ile iyi sınıflandırma sonuçları sağlayabilir (Garg et al, 2013).

Destek vektör makinelerinde çok sınıflı problemlerin çözümünde bire karşı bir ve bire karşı hepsi olarak iki çözüm bulunmaktadır. Bire karşı bir destek vektör makinesi yaklaşımının amacı, $(m^2-m)/2$ adet destek vektör makinesinin eğitimini sağlamaktır, burada m sınıf sayısıdır. Destek vektör makineleri, etiketlenmemiş örneklerin iki sınıftan birine ait olup olmadığını tespit etmek için çalışır. Asıl çıktının belirlenmesi için ikili sınıflandırmalardan gelen sonuçlar birleştirilir. Bire karşı hepsi yaklaşımında, destek vektör makineleri etiketlenmemiş örneklerin herhangi bir sınıfa


ait olup olmadığını tespit etmek için m adet destek vektör makinesi içerir. Sınıfa özgü destek vektör makinesi, örneğin sınıfını belirleyen pozitif sonuç döndürür. Birden çok sınıfa özgü destek vektör makinesi olumlu sonuç verirse, bire karşı bir yaklaşımı Eşitlik bozma amacıyla kullanılır. Çok sınıflı destek vektör makinesi yaklaşımları, çeşitli problemlerde yaygın olarak kullanılmaktadır (Kumar et al, 2020).

3.3.2.1 Lineer Destek Vektör Makinesi

Destek vektör makinesinde ilk olarak aralık hesaplanır. Aralığın maksimize edilebilmesi için, hiper düzlem bölünür. Bu durum Eşitlik (3.17)'de açıklanmaktadır.

$$v^T \times x + d = 0 \quad (3.17)$$

Eşitlik (3.17)'de v hiper düzlemin yönünü belirten vektör, v^T v vektörünün transpozu, x girdiyi ve d hiper düzlem ile orijin arasındaki yer değiştirmeyi belirtmektedir. Şekil 3.16'da lineer destek vektör makinesi görülmektedir.



Şekil 3.16. Lineer destek vektör makinesi

Hiperdüzlemin verileri sınıflandırması Eşitlik (3.18)'de açıklanmaktadır.

$$\begin{aligned} v^T \times x_1 \cdot t &\geq +1, y_i = +1 \\ v^T \times x_1 \cdot t &\leq -1, y_i = -1 \end{aligned} \quad (3.18)$$

Eşitlik (3.18)'de v hiperdüzlemin yönünü belirten vektör, v^T v vektörünün transpozu, x girdiyi, d hiperdüzlem ile orijin arasındaki yer değiştirmeyi ve y sınıf etiketini belirtmektedir. Eşitlik (3.18)'in her iki tarafı da y_i ile çarpıldığında, $y_i \times (w^T \times x_i + d) \geq 1$ eşitliği elde edilir. $y_i \times (w^T \times x_i + d) = 1$ denklemini sağlayan örneğe (x_i, y_i) destek vektörleri denir. Eğitim aşamasında, örneklerden uygun v ve d elde


edilir (Mao vd, 2022). Eşitlik (3.19)'da elde edilen destek vektör makinesi açıklanmaktadır.

$$f(x) = \text{sign}(w^T \times x + d) = \text{sign}(\sum_{i=1}^m a_i \times y_i \times x_i^T \times x + d) \quad (3.19)$$

Eşitlik (3.19)'da sign işaret fonksiyonunu, v hiper düzlemin yönünü belirten vektör, v^T v vektörünün transpozunu, x girdiyi, d hiper düzlem ile orijin arasındaki yer değiştirmeyi ve y sınıf etiketini belirtmektedir.

3.3.2.2 Lineer Olmayan Destek Vektör Makinesi

Doğrusal olmayan destek vektör makinelerinde, veriler hiper düzlem aracılığıyla doğrudan sınıflandırılmamaktadır. Eşlenen verilerin doğrusal olarak ayrılabilmesi için veriler orijinal uzaydan daha yüksek boyutlu uzaya eşlenir. Şekil 3.17'de lineer olmayan destek vektör makinesi görülmektedir.



Şekil 3.17. Lineer olmayan destek vektör makinesi

Lineer olmayan destek vektör makinesinin eğitimi Eşitlik (3.20)'de açıklanmaktadır.

$$f(x) = \text{sign}(\sum_{i=1}^m a_i \times y_i \times k(x_i, x_i) + d) \quad (3.20)$$


Eşitlik (3.20)'de $k(x_i, x_j)$ öznitelik uzayına veri eşlemenin iç çarpım hesaplamasını, elde edilen sonucu fonksiyon değerine dönüştürmek için kullanılan kernel fonksiyonudur. Çeşitli kernel fonksiyonları vardır. En yaygın olarak polinomik kernel fonksiyonu, gauss kernel fonksiyonu ve sigmoid kernel fonksiyonu kullanılmaktadır (Mao et al, 2022). Eşitlik (3.21)'de polinomik kernel fonksiyonu, Eşitlik (3.22)'de gauss kernel fonksiyonu ve Eşitlik (3.23)'te sigmoid kernel fonksiyonu açıklanmaktadır.,

$$k(x_i, x_j) = (x_i \times x_j + 1)^p \quad (3.21)$$

$$k(x_i, x_j) = \exp\left(\frac{-|x_i - x_j|^2}{2\sigma^2}\right) \quad (3.22)$$

$$k(x_i, x_j) = \tanh(\beta \times x_i \times x_j + \theta), \beta > 0, \theta > 0 \quad (3.23)$$

Eşitlik (3.21)'de p kernel parametresidir. Eşitlik (3.22)'de σ veriler arasındaki karakteristik uzunluk ölçeğini tanımlayan hiperparametredir. Eşitlik (3.23)'te β ve θ kernel parametreleridir. Şekil 3.18'de kernel işlemi görülmektedir.



Şekil 3.18. Kernel İşlemi

3.3.3 Naive Bayes

Naive Bayes algoritması Bayes kuralına dayanmaktadır. Y kararı için özniteliklerin ($X_1, \dots, X_n$) koşullu olarak birbirinden bağımsız olduğu kabul edilir. Bu durumun sonucunda $P(X|Y)$ 'in gösterimi basitleştirilir ve eğitim verilerinden tahmin etme sorunu çözülür (Kumar and Rath, 2016). Bayes teoremi Eşitlik (3.24)'te açıklanmaktadır.

$$P(A|B) = p(B|A) \times \frac{P(A)}{P(B)} \quad (3.24)$$

Eşitlik (3.24)'te $P(A)$ A için önsel olasılığı, $P(B)$ B için önsel olasılığı, $P(A|B)$ terimi verilmiş B için A'nın koşullu olasılığını ve $P(B|A)$ terimi verilmiş A için B'nin koşullu olasılığını ifade etmektedir.

Naive Bayes, basit ve güçlü bir algoritmadır. Model, eğitim verilerinden hesaplama yaparken iki farklı yöntem kullanır. Her sınıfın olasılığı ve her x değeri için verilen sınıfların koşullu olasılığı hesaplanır. Hesaplama işleminden sonra modelde, Bayes teoremi kullanılarak yeni veriler için tahminler yapılır. Veriler gerçek değerli olduğunda, olasılıkların tahmini için yaygın olarak Gauss dağılımı kullanılır. Naive Bayes, girdi değişkenlerini bağımsız olduğunu varsaymaktadır. Bu

yüzden ‘naive’ olarak adlandırılmaktadır. Naive Bayes modelinin işleyişi şu şekildedir.

O nesnesi eğitim veri setidir ve O nesnesiyle ilişkili sınıf etiketleri vardır. O nesnesi, n-boyutlu bir öznitelik vektörü ile temsil edilmektedir. $O = (o_1, o_2, \dots, o_n)$, sırasıyla $A_1, A_2, A_3, \dots, A_n$ özniteliklerine sahiptir. m adet sınıf olduğu varsayıldığında, O öznitelik vektörünün $(C_1, C_2, \dots, C_m)$ sınıflarından birine ait olması gerekir. Naive Bayes sınıflandırıcısı, O’nun en yüksek sonsal olasılığa sahip sınıfa ait olduğunu tahmin eder. O özellik vektörünün C_i sınıfına ancak ve ancak $1 \leq j \leq m, j \neq i$ için $P(C_i|O) > P(C_j|O)$ ise ait olduğunu belirtir. Bayes Teoremi Eşitlik (3.25)’te açıklanmaktadır.

$$P(C_i|O) = P(O|C_i) \times \frac{P(C_i)}{P(O)} \quad (3.25)$$

$P(O)$ tüm sınıflar için sabittir, bu yüzden sadece $P(O|C_i) \times P(C_i)$ maksimize edilmelidir. Eğer sınıfın önceki olasılıkları bilinmiyorsa, sınıfların eşit derecede olması, yani $P(C_1) = P(C_2) = \dots = P(C_m)$ olduğu varsayılır. Bundan dolayı $P(O|C_i)$ maksimize edilir. Aksi takdirde, $P(O|C_i) \times P(C_i)$ maksimize edilir. $P(O|C_i)$ ’nin sınıflandırma hesaplamasının azaltılması için, sınıf bağımsızlığı varsayımı yapılır. Yani sınıf etiketi verildiğinde öznitelik değerlerinin birbirinden koşullu olarak bağımsız olduğu varsayılır. Eşitlik (3.26)’da hesaplama açıklanmaktadır.

$$P(O|C_i) = P(o_1|C_i) \times \dots \times P(o_n|C_i) \quad (3.26)$$

O’nun sınıf etiketini tahmini için, C_i sınıfları için $P(O|C_i) \times P(C_i)$ değerlendirilir. Naive Bayes sınıflandırıcısı, O öznitelik vektörünün sınıf etiketini ancak ve ancak Eşitlik (3.27) durumunda C_i olduğunu tahmin eder (Shobha and Rangaswamy, 2018).

$$P(O|C_i)P(C_i) > P(O|C_j)P(C_j), 1 \leq j \leq m, i \neq j \quad (3.27)$$

En yüksek sonsal sınıf tahmini, Naive Bayes modelindeki parametrelerin tahmini için kullanılmaktadır. Gauss Naive Bayes, özelliklerin Gauss olma olasılığını varsayar ve bu şekilde sınıflandırma işlemini yerine getirir. Eşitlik (3.28)’de gauss naive bayes yöntemi açıklanmaktadır.

$$P(x_i, y) = \left(\frac{1}{2\pi\sigma_y^2} \right) \exp \left(-\frac{(x_i - \mu_y)^2}{2\pi\sigma_y^2} \right) \quad (3.28)$$


Eşitlik (3.28)'de σ_y ve μ_y parametreleri maksimum olabilirlik yöntemiyle tahmin edilebilmektedir. Basit olması ve daha karmaşık yöntemlere kıyasla hızlı olmasından dolayı gauss naive bayes yöntemi, biyoinformatikte yaygın olarak uygulanmaktadır (Lou et al, 2014).

3.3.4 K En Yakın Komşu

K en yakın komşu algoritması, sınıflandırma amacıyla kullanılan parametrik olmayan algoritmadır. Amacı, verilerin özellikleri tarafından tanımlanan alanda düzenlenmesidir. Algoritmaya yeni veri girişi yapıldığında, yeni verinin sınıfının belirlenmesi için en yakın k adet verinin sınıfları karşılaştırılır. Karşılaştırma sonrasında yeni veri, k adet veri içinden en çok hangi sınıfın verilerine yakınsa o sınıfa ait olur (Chanal et al, 2022).

K en yakın komşu algoritması yaklaşık yarım asır boyunca birçok araştırma problemlerinde kullanılmıştır. Bu algoritmanın temel ilkesi, veri seti içindeki örnek bir verinin benzer özellikler paylaşan diğer verilere yakın yerde bulunmasıdır. Veri hakkındaki ek bilgi, ona en yakın komşuların gözlemlenmesiyle elde edilebilir. Bu sebepten dolayı bu algoritma, sınıflandırma tekniği olarak kullanılabilir.

K en yakın komşu algoritması, metin sınıflandırma, zaman serisi veri madenciliği, DNA ve RNA dizilerini tanıma, hastalık tanısı, toplantı tahminleri, internet bilgi filtresi ve görüntü anlama gibi gerçek dünya problemlerinde kullanılmaktadır (Chaudhry et al, 2007). Şekil 3.19'da k en yakın komşu algoritması örneği görülmektedir.



Şekil 3.19. K en yakın komşu örneği

Şekil 3.19'da ● bilinmeyen veriyi, ▲ ve ■ iki farklı sınıfı temsil etmektedir. $k = 3$ olduğunda ●, ▲ sınıfına, $k=5$ olduğunda ise ■ sınıfına ait olmaktadır.

K en yakın komşu algoritması “bellek tabanlı öğrenici” olarak da bilinmektedir. Algoritma, gözlemlediği verilerin konumunu hatırlar ve yeni veriler için tahminlerde bulunur. Bu yöntemin pratik uygulanabilmesi için bazı ek önemli hususları bulunmaktadır. Tahmini yapılan veriler arasındaki mesafenin hesaplanma tekniğine, tahmin yapılırken kaç tane komşunun dikkate alındığına ve birden fazla en yakın komşu göz önüne alındığında son tahminin nasıl yapılacağına dikkat edilmelidir (Winters-Miner et al, 2015).

K en yakın komşu sınıflandırmasının avantajı basit olmasıdır. Kullanıcı, komşu sayısını ve kullanılacak uzaklık ölçüsünü belirler. Uzaklık ölçüm yöntemleri arasında yaygın olarak Öklid mesafesi kullanılır (Neath and Johnson, 2010). Öklid mesafesi Eşitlik (3.29)’da açıklanmaktadır.


$$D = \sqrt{(x_1 - y_1)^2 + \dots + (x_n - y_n)^2} \quad (3.29)$$

K en yakın komşu algoritması şu şekilde çalışır. K sayısı belirlenir. K kaç tane komşu veriye bakılacağını ifade eder. Seçilen uzaklık fonksiyonu aracılığıyla veri setine katılacak verinin diğer verilere olan uzaklığına tek tek bakılır. En yakın k adet komşu veriye bakılır. Yeni veri, çoğunluk sağlayan sınıfa göre etiketlenir (Abu Alfeilat et al, 2019).

3.3.5 Evrişimsel Sinir Ağları


Evrişimsel sinir ağları, ileri beslemeli sinir ağlarından biridir. Görüntü tanıma alanında kullanımı yaygındır. Evrişimsel sinir ağlarında girdi verileri çok boyutlu diziler şeklindedir. Çok sayıda etiketli veri için iyi çalışır. Evrişimsel sinir ağları, giriş görüntüsünü bölüm bölüm çıkarır. Giriş görüntüsüne alıcı alan denir. Alıcı alan, nöronlara ağırlıklar atar. Bu şekilde nöronların önemi birbirinden ayırt edebilir (Nisha ve Meeral, 2021).

Evrişimsel sinir ağları, giriş ve çıkış katmanlarının yanında çok sayıda gizli katmana da sahiptir. Evrişimsel sinir ağlarının gizli katmanları çok sayıda evrişimsel katmandan meydana gelmektedir. ReLU aktivasyon fonksiyonu; havuzlama katmanları ve tam bağlantılı katmanlar gibi işlemler tarafından takip edilen etkinleştirme işlevidir. Geri yayılım, hata dağılımı ve ağırlık güncelleştirme işlemlerinde kullanılır. Şekil 3.20’de evrişimsel sinir ağı örneği görülmektedir.




Şekil 3.20. Evrişimsel sinir ağı örneği

LeCun ve arkadaşları, 1989'da dönüm noktası niteliğinde bir çalışma yapmışlardır. El yazısı sayılarının görüntüleri doğrudan evrişimsel çekirdek katsayılarını öğrenmesi için geri yayılım işlemi kullanılmıştır. Bu çalışma ile öğrenme otomatik hale getirilmiştir ve otomatik modelin performansı, manuel modelin katsayı ayarından daha iyidir. Çeşitli görüntü tanıma problemlerinin çözümünde kullanışlıdır. Bu yaklaşım sayesinde, modern bilgisayarlarda görünün temeli atılmıştır. LeCun ve arkadaşları tarafından geliştirilmiş olan LeNet-5 evrişimsel sinir ağı modeli 1998 yılında, piksel görüntülerini sayısallaştırarak, çekler üzerinde elle yazılmış sayıları tanımak için kullanılmıştır (Ren vd, 2021). Şekil 3.21'de LeNet-5 mimarisi görülmektedir.




Şekil 3.21. LeNet-5 mimarisi (Tra vd, 2017)

Krizhevesky ve arkadaşları 2012 yılında, LeNet mimarisinden daha derin ve daha geniş evrişimsel sinir ağı modeli olan AlexNet'i geliştirdiler ve 2012 yılında ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesi (ILSVRC) olarak adlandırılan yarışmayı kazanmışlardır. Bu mimari ile diğer geleneksel makine öğrenimi ve bilgisayarla görme yaklaşımlarına karşı bu yarışmada üstünlük sağlamışlardır. AlexNet ile makine öğrenimi ve bilgisayarla görü alanında önemli bir adım atılmıştır, bu noktadan sonra derin öğrenmeye olan ilgi hızla artmıştır. Şekil 3.22'de AlexNet mimarisi görülmektedir.



Şekil 3.22. AlexNet mimarisi (Khvostikov vd, 2018)


Görsel Geometri Grubu (VGG), 2014 yılında ILSVRC yarışmasında ikinci oldu. Çalışmalarının amacı, evrişimsel sinir ağlarında daha iyi tanıma veya sınıflandırma doğruluğu elde edilebilmesi için ağdaki derinliğin kritik bir bileşen olduğunu kanıtlamaktır. VGGNET mimarisi, ReLU aktivasyon fonksiyonunu kullanan iki evrişimsel katmandan meydana gelir. Aktivasyon fonksiyonundan sonra, tek maksimum havuzlama katmanı ve ReLU aktivasyon fonksiyonunu kullanan tam bağlantılı katman bulunmaktadır. Modelin son katmanında, sınıflandırma işlemi için Softmax katmanı bulunmaktadır. Şekil 3.23’de VGGNET mimarisi görülmektedir.



Şekil 3.23.VGGNET mimarisi (Sovrirajan vd, 2023)

Google çalışanı Christian Szegedy tarafından geliştirilen GoogLeNet, 2014 yılında ILSVRC yarışmasını kazanmıştır. GoogLeNet, geleneksel evrişimsel sinir ağlarına kıyasla hesaplama karmaşıklığını azaltmak için geliştirilmiştir. Bu yöntemde amaç, farklı çekirdek boyutları aracılığıyla meydana getirilen değişken alıcı alanlara


sahip olan başlangıç katmanlarını eklemektir. Bu alıcı alanlar sayesinde, özellik haritasında seyrek korelasyon modellerini yakalayan işlemler oluşturulmuştur. Şekil 3.24'te başlangıç katmanının yapısı görülmektedir.



Şekil 3.24. Başlangıç katmanının yapısı

He tarafından geliştirilen Residual Network mimarisi, ResNet, 2015'teki ILSVRC yarışmasını kazanmıştır. Bu mimarinin amacı, kendinden önceki mimarilerin sahip olduğu kaybolan gradyan probleminin önüne geçilmesidir, bu yüzden ultra derin ağ olarak geliştirilmiştir (Alom vd, 2018).

Evrişimsel sinir ağları üç katmandan meydana gelmektedir. Evrişimsel katmanda, özellik haritaları oluşturulur. Özellik haritasında, gerçek görüntünün benzersiz özellikleri vurgulanır. Evrişimsel katman, diğer sinir ağı katmanlarından farklı çalışır. Evrişimsel katmanda, bağlantı ağırlıkları ve ağırlıklı toplam yerine görüntüleri dönüştüren evrişimsel filtreler kullanılır. Görüntünün evrişim filtre ile işlenmesi sonucu özellik haritası ortaya çıkar. Şekil 3.25'te evrişimsel katmanın yapısı ve işlevi görülmektedir.



Şekil 3.25. Evrişimsel katman ve işlevi

Evrişimsel katmanda, evrişimsel filtrelerin sayısı kadar özellik haritası oluşturulur. Evrişimsel katmanda dört adet evrişimsel filtre varsa, dört adet özellik haritası oluşturulur. Evrişimsel katmandaki evrişimsel filtreler iki boyutlu matrislerdir. Genellikle 5x5 veya 3x3 matris şeklinde oluşturulur, son zamanlarda 1x1 evrişimsel filtreleri de kullanılmaktadır. Evrişimsel filtre matrisindeki değerler eğitim süreciyle belirlenir. Evrişimsel filtre matrisindeki değerler eğitim sürecince sürekli güncellenir. Bu süreç, diğer sinir ağlarındaki ağırlık güncellenmesine benzemektedir. Eşitlik (3.30)'da özellik haritasındaki matris hücrelerinin hesaplaması anlatılmıştır.

$$z = \sum_{i=1}^N \sum_{j=1}^N x_{ij}y_{ij} \quad (3.30)$$

Eşitlik (3.30)'da z özellik haritasının matrisindeki bir hücreyi, x gerçek görüntünün hücrelerini, y evrişimsel filtredeki hücreyi, i ve j indisleri belirtmektedir.

Evrişimsel filtre tarafından oluşturulan özellik haritası, katman çıktısı verilmeden önce aktivasyon fonksiyonuyla işlenir. Genellikle ReLU aktivasyon fonksiyonu kullanılır ancak sigmoid ve hiperbolik tanjant aktivasyon fonksiyonları da kullanılabilir.

Havuzlama katmanı, görüntünün boyutunu küçültür. Görüntünün belirli bir alanında bulunan komşu pikselleri tek bir değerde birleştirir. Havuzlama, görüntü işleme şemalarında kullanılan bir tekniktir. Havuzlama işleminin gerçekleşebilmesi için havuzlanan piksellerin seçilme şekli ve temsili değerin ayarlanma metodunun belirlenmesi gerekir. Komşu pikseller genel olarak kare matris halinde seçilmektedir ve birleştirilen piksel sayısı her problem için farklılık göstermektedir. Temsili değer genellikle seçilen piksellerin ortalaması veya maksimumu olacak şekilde belirlenir (Kim, 2017).

Ortalama havuzlama tekniğinde kare piksel içindeki değerlerin ortalaması alınır. Eşitlik (3.31)'de ortalama havuzlama hesaplaması açıklanmaktadır.

$$y = \sum_{i=1}^N \sum_{j=1}^N x_{ij} = x_{ij} \quad (3.31)$$

Eşitlik (3.31)'de y çıktıyı, x kare matristeki veriyi, i ve j indisi temsil etmektedir. Şekil 3.26'da ortalama havuzlama tekniği görülmektedir.



Şekil 3.26. Ortalama havuzlama tekniği

Maksimum havuzlama tekniğinde kare piksel içindeki değerlerin en büyüğü alınır. Şekil 3.27’de maksimum havuzlama tekniği görülmektedir.



Şekil 3.27. Maksimum havuzlama tekniği

3.4 Optimizasyon Algoritmaları

3.4.1 Dereceli Azalma Algoritması

Dereceli azalma algoritması, bir fonksiyonun minimumunun bulunması için kullanılan bir optimizasyon yöntemidir. Geri yayılım esnasında, hatanın en aza indirgenmesi için ağırlıklar ve eşik değerleri yinelemeli olarak güncellenir. Dereceli azalma optimizasyonunda, ağırlıkların güncellemesi için tüm eğitim örnekleri kullanılır. Aktivasyon fonksiyonu türevlenebildiği sürece, dereceli azalma algoritması, sinir ağlarına uygulanabilir. (Andrearczyk and Whelan, 2017; MacLennan, 2001).

Stokastik dereceli azalma algoritması, ağırlıkları ve eşik değerini hata gradyanına göre güncellemektedir. Öncelikle ağ üzerinden örnek veri geçirilir, hata hesaplanır, gradyanlar hesaplanır ve ağırlıklar güncellenir. Standart optimizasyon protokolü ile uyumlu çalışmaktadır. Makine öğrenimi tekniklerinde, belirsizliğin azaltılması amacıyla çok sayıda eğitim verisini dikkate almak sağlam bir yaklaşımdır. Tüm eğitim verilerinde birleşik hata hesaplanır ve bu şekilde ağırlık güncellenmesi için gradyan hesaplanır. Tek veriyle ağırlık güncellenmesi düzensiz olabilir, toplu veriler üzerinde birleşik hataya karşılık gelen gradyan, ağırlığı çok

daha uygun yönde güncelleyebilir. Buna toplu dereceli azalma denir (Santosh et al, 2022).

Eşitlik (3.32)'de tanımlanan maliyet fonksiyonunda, h modelin tahmin fonksiyonu, m x parametrelerinin sayısı, y gerçek çıktı değeri, x girdi değeri ve θ rastgele seçilen değer olarak tanımlanmaktadır.

$$J(\theta_0, \theta_1) = \left(\frac{1}{2m}\right) \sum_{i=1}^m (h_{\theta}(x_i) - y_i) \quad (3.32)$$

λ öğrenme katsayısı olmak üzere Eşitlik (3.33) ve Eşitlik (3.34)'te kuralların güncellenmesi, Eşitlik (3.35) ve Eşitlik (3.36) ile maliyet fonksiyonunun kısmi türevi hesaplanmaktadır.

$$\theta_0 = \theta_0 - \lambda(\partial J(\theta_0, \theta_1) / \partial \theta_0) \quad (3.33)$$

$$\theta_1 = \theta_1 - \lambda(\partial J(\theta_0, \theta_1) / \partial \theta_1) \quad (3.34)$$

$$\frac{\partial J(\theta_0, \theta_1)}{\partial \theta_0} = \frac{\sum_{i=1}^m (h_{\theta}(x_i) - y_i)}{m} \quad (3.35)$$

$$\frac{\partial J(\theta_0, \theta_1)}{\partial \theta_1} = \frac{\sum_{i=1}^m (h_{\theta}(x_i) - y_i)x_i}{m} \quad (3.36)$$

3.4.1.1 Dereceli Azalma Algoritmasının Yapay Sinir Ağlarına Uygulanması

Dereceli azalma algoritması, yapay sinir ağlarına uygulandığında geri yayılım işlemi gerçekleşir. Geri yayılım yöntemi adını işlemlerinden almıştır. Nöronların ağırlıkları ve eşik değerleri önce çıktı katmanında, sonra gizli katmanlarda düzeltilir. Ağırlık düzeltme sırasının neden bu şekilde olduğu basittir. Yapay sinir ağlarının yaptığı hata sadece çıktı katmanında anlaşılır. Geri yayılım işleminin ilk aşaması Eşitlik (3.37) ve Eşitlik (3.38)'de açıklanmaktadır.

$$d_i = y_i - t_i \quad (3.37)$$

$$\delta_i = y_i(1 - y_i)d_i \quad (3.38)$$

Eşitlik (3.37)'de d hata farkını, y beklenen çıktıyı ve t tahmin edilen değeri belirtmektedir. Eşitlik (3.38)'de δ deltayı, y beklenen çıktıyı ve d hata farkını temsil etmektedir. Çıkış katmanındaki ağırlıklar ve eşik değerleri güncellenir, sinyaller çıkış katmanına geçerken hataların eşit dağıldığı varsayılır. Ağırlık güncelleştirmesi

Eşitlik (3.39) ve Eşitlik (3.40)'ta eşik değeri güncelleştirmesi Eşitlik (3.41) ve Eşitlik (3.42)'de açıklanmaktadır.

$$\Delta w_{jm}^l(x) = \lambda \delta_n t_j^l + \alpha \Delta w_{jm}^l(x-1) \quad (3.39)$$

$$w_{jm}^l(x) = w_{jm}^l(x-1) + \Delta w_{jm}^l(x) \quad (3.40)$$

$$\Delta b_{jm}^l(x) = \lambda \delta_n t_j^l + \alpha \Delta b_{jm}^l(x-1) \quad (3.41)$$

$$b_{jm}^l(x) = b_{jm}^l(x-1) + \Delta b_{jm}^l(x) \quad (3.42)$$

Eşitlik (3.39) ve Eşitlik (3.40)'ta w ağırlığı, x girdiyi, λ öğrenme katsayısını j ve m ağırlık vektörü indisini, l katmanı, t tahmin edilen değeri, δ delta değerini, α momentum katsayısını temsil etmektedir. Eşitlik (3.41) ve Eşitlik (3.42)'da b eşik değerini, m eşik değeri vektörünü, l katmanı, x girdiyi, λ öğrenme katsayısını, δ deltayı ve α momentum katsayısını temsil etmektedir. Gizli katmanda delta hesaplaması çıkış katmanından farklıdır. Ağırlık değişimi hesaplaması Eşitlik (3.39) ve Eşitlik (3.40)'taki gibi, eşik değeri değişimi hesaplaması ise Eşitlik (3.41) ve Eşitlik (3.42)'deki gibidir. Gizli katmandaki delta hesaplaması Eşitlik (3.43)'te açıklanmaktadır.

$$\delta_j^l = y_j^l(1 - y_j^l)\Sigma(\delta_m w_{jm}^l) \quad (3.43)$$

Eşitlik (3.43)'te δ deltayı, j ve m ağırlık vektörünün indisini, l katmanı ve y çıktıyı temsil etmektedir. Geri yayılım işlemi bitince epok tamamlanmış olur. İstenilen yöntemle hata hesaplaması yapılır (Zupan, 1994).

3.4.2 Adam Algoritması

Adam algoritması, az bellek ve birinci dereceden gradyanları gerektiren optimizasyon algoritmasıdır. Adam ismi adaptif momentumdan gelmektedir. Bu metot, AdaGrad ve RMSProp algoritmalarının birleşiminden meydana gelmektedir. Adam algoritmasının avantajları arasında, bellekte az yer kaplaması, ayrık gradyanlarla iyi çalışabilmesi ve sabit hedef gerektirmemesi gösterilebilir (Kingma and Ba, 2014).

Adam algoritması; α , β_1 , β_2 ve ϵ parametrelerine sahiptir. α öğrenme katsayısını, β_1 gradyanların toplamının bozulma oranını, β_2 önceki gradyanların toplamının karesini, ϵ ise ağırlık güncellemesi yapılırken 0'a bölünme hatasına

engel olunması için kullanılan parametredir. Eşitlik (3.44)'te gradyan toplamı, Eşitlik (3.45)'te gradyanların toplamının karesi açıklanmaktadır.

$$m_t = \beta_1 \times m_{t-1} + (1 - \beta_1) \times \left[\frac{\delta L}{\partial w_t} \right] \quad (3.44)$$

$$v_t = \beta_2 \times v_{t-1} + (1 - \beta_2) \times \left[\frac{\delta L}{\partial w_t} \right]^2 \quad (3.45)$$

AdaGrad ve RMSProp optimizasyon algoritmalarında yerel minimuma takılma durumu mevcuttur. Bu durumun aşılması için Adam algoritmasında eşik düzeltme uygulanmaktadır (Fei et al, 2020; Kingma and Ba, 2014). Eşitlik (3.46) ve Eşitlik (3.47)'de eşik düzeltme açıklanmaktadır.

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.46)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.47)$$

Ağırlık güncelleme Eşitlik (3.48)'de açıklanmaktadır.

$$w_{t+1} = w_t - \hat{m}_t \times \left(\frac{\alpha}{\sqrt{\hat{v}_t} + \epsilon} \right) \quad (3.48)$$

3.4.3 Levenberg-Marquardt Algoritması

Levenberg-Marquardt algoritması, özellik çıkarımı için kullanılan algoritmadır. Optimum sonuca ulaşabilmek için Gauss-Newton ve dereceli azalma algoritmalarının birinden faydalanmaktadır. Bu güncelleme tekniği duruma göre değişmektedir. Levenberg-Marquardt tekniği yapılan çalışmalara göre dereceli azalma yönteminden önemli derecede yüksek sonuçlar vermektedir. Levenberg-Marquardt algoritmasının dezavantajları, yüksek derecede bellek ve zaman tüketimi ve uygulanmasının biyolojik olarak mümkün olmayışıdır (Kumaraswamy, 2021; Wilson and Mantooth, 2013).

$$\Delta w = (J^T \times J + \mu \times I)^{-1} \times J^T \times e \quad (3.49)$$

$$\mu(t) = \begin{cases} \mu(t-1) \times k & E(t) > E(t-1) \\ \frac{\mu(t-1)}{k} & E(t) \leq E(t-1) \end{cases} \quad (3.50)$$

Eşitlik (3.49)'da verilen ağırlık güncelleme işleminde w ağırlığı, J ($P \times M$) $\times N$ boyutundaki Jacobian matrisini, μ Marquardt parametresini ve e ($P \times M$) $\times 1$ boyutundaki hata matrisini temsil etmektedir. Hatalar ortalama kare hatası yöntemiyle hesap edilmektedir. Marquardt parametresinin büyüklüğüne göre optimizasyon algoritması belirlenmektedir. Eğer Marquardt parametresi çok büyükse dereceli azalma algoritması, çok küçükse Gauss-Newton algoritması kullanılır. Uyarlamalı yapı, Eşitlik (3.50)'de k sabit sayıyı, E uygunluk değerini göstermektedir (Çavuşlu vd, 2016).

3.4.4 Ölçeklendirilmiş Eşlenik Gradyan Algoritması

Ölçeklendirilmiş eşlenik gradyan, ikinci dereceden gradyan danışmanlı öğrenme yöntemidir. Ölçekli eşlenik gradyan algoritmasında, diğer eşlenik gradyan algoritmalarının aksine, her iterasyonda satır arama yöntemi uygulanmamaktadır. Bunun yerine güven bölgesi adımını kullanmaktadır. Bu durum modelin maliyetini azaltmaktadır. Güven adımı yönteminde, model fonksiyonunun güvenli olacağı mesafe her adımda güncellenmektedir. Model adımı mesafe içindeyse kullanılır, aksi durumda sınırdaki model fonksiyonu için yaklaşık minimum değer kullanılır (Babani et al., 2016; Cetişli and Barkana, 2009).

Ölçeklendirilmiş eşlenik gradyan algoritmasının her iterasyonunda ikinci dereceden bilgilerin belirlenebilmesi amacıyla iki parametrenin birinci dereceden gradyanı hesaplanır. Bundan dolayı, en dik iniş yönteminden iki kat daha hızlıdır (Cetişli and Barkana, 2009).

Eşitlik (3.51)'de s Hessian matris yaklaşımını, E toplam hata fonksiyonunu, E' hata fonksiyonunun gradyanını, λ ve σ Hessian matrisi ölçek parametreleri olarak açıklamaktadır. Eşitlik (3.52)'de eşlenik gradyan katsayısı ve Eşitlik (3.53)'te araştırma doğrultusu yönü hesabı verilmiştir (Baghirli, 2015).


$$s_k = \frac{E'(w_k + \sigma_k p_k) - E'(w_k)}{\sigma_k} + \lambda_k p_k \quad (3.51)$$

$$\beta_k = \frac{(|g_{k+1}|^2 - g_{k+1}^T g_k)}{g_k^T g_k} \quad (3.52)$$

$$p_{k+1} = -g_{k+1} + \beta_k p_k \quad (3.53)$$

3.5 Önerilen Mimari

Şekil 3.28’de bu tez çalışmasında kullanılan mimariye ait blok şema verilmiştir.



Şekil 3.28. Önerilen Mimari Yapısı

Kaggle Chest CT-Scan veri setindeki görüntüler, standart bir boyutta olmadığından görüntüler 80 x 40 boyutuna indirgenmiştir. Bu işlem sayesinde görüntü boyutları standartlaştırılmış olup aynı zamanda bu işlemle görüntü boyutu küçüldüğünden eğitim işleminin daha hızlı biçimde gerçekleşmesi amaçlanmıştır. Derin öğrenme modelleri, görüntülerin işlenmesi sırasında otomatik olarak öznetelik çıkarabilen bir yapıya sahiptir. Bu nedenle, görüntülerin derin öğrenme modellerinde işlenmesi için öznetelik çıkarma işlemi ayrıca yapılması gerekli değildir.

Görüntülerin makine öğrenimi ve yapay sinir ağları modellerinde işlenmesi sırasında, bu modeller otomatik olarak öznelik çıkarımı yapamadığından öznelik çıkarma işlemi yapılması gereklidir. Görüntülerin öznelik çıkarımı işlemi için öncelikle 3 seviyede Daubechies-1 filtresi kullanılarak dalgacık dönüşümü uygulanır. Dalgacık dönüşümünden sonra veriler, makine öğrenimi ve yapay sinir ağları modellerinin iki boyutlu verileri işleyememesi nedeniyle tek boyuta indirgenir. Ardından, veriler 0-1 normalizasyonu işleminden geçirilir. Bu işlemler sonrasında, veriler modellere gönderilerek sınıflandırma işlemi yapılır.

3.6 Başarı Metrikleri

3.6.1 Karmaşıklık Matrisi

Karmaşıklık matrisi veya hata matrisi, makine öğrenimi veya derin öğrenme modellerinden yararlanılan sınıflandırma problemlerinde kullanılan performans metriğidir. İki veya daha fazla sınıfta kullanılabilir. Tahmini ve gerçek değer bulunan, dört farklı kombinasyonu bulunmaktadır. Şekil 3.29'da karmaşıklık matrisinin yapısı görülmektedir.

		TAHMİN	
		P	N
GERÇEK	P	DP	YN
	N	YP	DN

Şekil 3.29. Karmaşıklık matrisi

Şekil 3.34'teki karmaşıklık matrisinde DP doğru pozitif, YN yanlış negatif, YP yanlış pozitif ve DN doğru negatif ifade etmektedir. Doğru pozitif, tahminin pozitif ve gerçek değer pozitif olduğunu, yanlış negatif tahminin negatif ama gerçek değer pozitif olduğunu, yanlış pozitif tahminin pozitif ama gerçek değer negatif olduğunu, doğru negatif tahminin negatif ve gerçek değer negatif olduğunu ifade etmektedir (Marom el al., 2010).

3.6.2 Doğruluk Oranı

Bütün sınıflara ait değerlerin, kaçının doğru tahmin edildiğini ifade etmektedir. Olabildiğince yüksek olmalıdır (Story and Congalton, 1986). Eşitlik (3.54)'te doğruluk oranı hesaplaması açıklanmaktadır.

$$\text{Doğruluk Oranı} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.54)$$

3.6.3 Kesinlik

Sınıflardan biri için yapılan tahminin ne kadarının doğru olduğunu ifade eden metriktir. Olabildiğince yüksek olmalıdır (Sokolova and Lapalme, 2009). Eşitlik (3.55)'te kesinlik hesaplaması açıklanmaktadır.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (3.55)$$

3.6.4 Duyarlılık

Bir sınıfa ait verilerin ne kadarının doğru olduğunu ifade eden metriktir. Olabildiğince yüksek olmalıdır (Sokolova and Lapalme, 2009). Eşitlik (3.56)'da duyarlılık hesaplaması açıklanmaktadır.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3.56)$$

3.6.5 F1 Puanı

Modelin duyarlılığı ve kesinliğinin dengesiz olduğu durumlarda F1 puanından yararlanılmaktadır. Duyarlılığın ve kesinliğin harmonik ortalamasıyla hesaplanmaktadır. Aritmetik ortalama yerine harmonik ortalamanın kullanılmasının sebebi dengesiz durumlarda modelin iyi olmadığının gösterilmek istenmesidir (Chicco and Jurman, 2020). Eşitlik (3.57)'de F1 puanı hesaplaması açıklanmaktadır.

$$\text{F1 Puanı} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.57)$$

3.6.6 Cohen'in Kappa Katsayısı

Cohen'in kappa katsayısı, puanlayıcılar arasındaki güvenilirliği belirlemede kullanılmaktadır. Sınıflandırma işlemlerinde iki puanlayıcı arasındaki uyumun derecesinin belirlenmesi amacıyla geliştirilmiştir. Avantajları arasında, kolay hesaplanması, pratik yorumlanması ve şansla beklenen uyum düzeyini temel

almasıdır. Eşitlik (3.58)'de Cohen'in kappa katsayısının hesaplaması açıklanmaktadır.

$$\kappa = \frac{\bar{P} - \bar{P}_e}{1 - \bar{P}_e} \quad (3.58)$$

Eşitlik (3.58)'de κ Kappa istatistiğini $\bar{P}$ gözlenen uyumluluk oranını, $\bar{P}_e$ şansla uyumluluk oranını ifade etmektedir. Kappa istatistiğinin değer aralığı -1 ile +1'dir. Kappa istatistiğinin yorumlanmasında Tablo 3.2'deki uyum düzeyleri metriği kullanılmaktadır (Bıkmaz Bilgen ve Doğan, 2017).

Tablo 3.2:Kappa istatistiğinin yorumlanması

κ	Uyum Gücü
< 0	Zayıf
0-0,2	Önemsiz
0,21-0,4	Düşük
0,41-0,6	Orta
0,61-0,8	Önemli
0,81-1,00	Çok yüksek

3.6.7 Ortalama Kare Hatası

Ortalama kare hatası, modelin yaptığı tahminin gerçek değerden farkını ölçmektedir. Farkların karesinin ortalaması alınmaktadır. Bu şekilde büyük hataların ağırlıklandırılması daha yüksek olmaktadır (Gupta et al., 2009). Eşitlik (3.59)'da ortalama kare hatanın hesaplanması açıklanmaktadır.

$$OKH = \sum_{i=1}^n \frac{(t_i - y_i)^2}{n} \quad (3.59)$$

Eşitlik (3.59)'da n eleman sayısını, i indisi, t tahmin değerini ve y gerçek değeri ifade etmektedir.

3.6.8 Karekök Ortalama Kare Hatası

Karekök ortalama kare hatası, ortalama kare hatasının karekökünü alan hata metriğidir. Bu şekilde ortalama kare hatasındaki büyük hataların fazla ağırlıklandırılması sorunu ortadan kalkmaktadır (Chai and Draxler, 2014). Eşitlik (3.60)'ta karekök ortalama kare hatasının hesaplanması açıklanmaktadır.

$$KOKH = \sqrt{\frac{\sum_{i=1}^n (t_i - y_i)^2}{n}} \quad (3.60)$$

Eşitlik (3.60)'de n eleman sayısını, i indisi, t tahmin değerini ve y gerçek değeri ifade etmektedir.

3.6.9 Ortalama Mutlak Hata

Ortalama mutlak hata, modeldeki hata farkının mutlak değerinin ortalamasını alan hata metriğidir. Hatalarda herhangi bir ağırlıklandırma uygulanmamaktadır (Chai and Draxler, 2014). Eşitlik (3.61)'de ortalama mutlak hatanın hesaplanması açıklanmaktadır.

$$OMH = \frac{\sum_{i=1}^n |t_i - y_i|}{n} \quad (3.61)$$

Eşitlik (3.61)'de n eleman sayısını, i indisi, t tahmin değerini ve y gerçek değeri ifade etmektedir.

3.6.10 Çapraz Entropi

Çapraz entropi, modele verilen örneklerin tahmini olasılık dağılımı ile gerçek olasılık dağılımı arasındaki farkı ölçmektedir. 0'a ne kadar yakınsa tahminler o kadar doğru demektir. Genellikle sınıflandırma işlemlerinde kullanılmaktadır. Bir modelin tahminlerinin nasıl dağıldığını göstermektedir. Model tahmini gerçek değerden yüksekse çapraz entropi değeri de yüksek olur. Ters durumda çapraz entropi değeri düşük olur (De Boer et al., 2005). Eşitlik (3.62)'de çapraz entropi hesaplaması açıklanmaktadır.


$$H(p, q) = - \sum_{i=1}^n p(x_i) \log(q(x_i)) \quad (3.62)$$

Eşitlik (3.62)'de n eleman sayısını, i indisi, p gerçek olasılık dağılımını ve q tahmini olasılık dağılımını ifade etmektedir.

4. BULGULAR

4.1 Verilerin Hazırlanması

Veri seti bilgisayarlı tomografi görüntülerinden oluşmaktadır. Veriler Kaggle Chest CT-Scan veri setinden elde edilmiştir. Görüntülerin boyutu standart olmadığından görüntüler 80×40 boyutuna indirgenmiştir, bu şekilde verinin boyutu standartlaştırılmıştır ayrıca modellerin daha hızlı çalışması da amaçlanmıştır. Daha iyi sonuçlar elde edilebilmesi amacıyla görüntülere veri arttırımı işlemi uygulanmıştır. Görüntüler 15 derece sağa ve sola döndürülmüştür ayrıca görüntülerin parlaklığı artırılıp azaltılmıştır. Görüntülerin dalgacık dönüşümünden geçebilmesi için görüntüler gri seviyesine dönüştürülmüştür. Gri seviyesine dönüştürülen görüntüler Daubechies-1 dalgacık dönüşümünden geçirilerek özellik çıkarımı işlemi uygulanmıştır. Özellik çıkarımı işleminden sonra verilere 0-1 normalizasyonu uygulanmıştır. Elde edilen özellik vektörü iki boyutlu olduğundan makine öğrenimi modellerine doğrudan uygulanamamaktadır. Bundan dolayı veriler tek boyuta indirgenmiştir. İndirgenen verilere k-katmanlı çapraz doğrulama işlemi uygulanmıştır. Veri seti beş eşit parçaya bölünmüştür. Bütün verilerin test verisi olarak kullanılabilmesi amacıyla bu yaklaşım kullanılmıştır. Tek boyuta indirgenen veriler makine öğrenimi modellerine ve yapay sinir ağına verilmiştir. Kullanılan yapının öbek çizgisi Şekil 4.1’de görülmektedir.




Şekil 4.1. Veri hazırlama yapısının öbek çizgisi

4.2 Öznitelik Çıkarımı

Makine öğrenmesi ve yapay sinir ağı modellerine veri verilmeden önce öznitelik çıkarımı işlemleri uygulanmaktadır. Görüntüler standart boyutta olmadığından dolayı 80 x 40 boyutuna indirgenmiştir. Yöntem olarak 3.seviye dalgacık dönüşümü, dönüşüm algoritması olarak Daubechies-1 algoritması uygulanmıştır. Dalgacık dönüşümünde dört farklı görüntü meydana gelmektedir. Yaklaşım görüntüsü, yatay detaylı görüntü, dikey detaylı görüntü ve çapraz detaylı görüntü oluşmaktadır. Oluşan bütün görüntülerin boyutları eşittir. 80 x 40’lık akciğer

tomografisi görüntüsüne 1.seviye dalgacık dönüşümü uygulandığında görüntüler 40 x 20 boyutuna indirgenir. Yaklaşım görüntüsüne bir seviye daha dalgacık dönüşümü uygulandığında 2.seviye dalgacık dönüşümü uygulanmış olur ve görüntü 20 x 10 boyutuna indirgenir. Bir seviye daha uygulandığında 3.seviye dalgacık dönüşümü uygulanmış olur ve görüntünün boyutu 10 x 5'e indirgenmiş olur. İndirgenen görüntü iki boyutludur. Makine öğrenimi ve yapay sinir ağı modellerinin eğitilebilmesi için veriler tek boyuta indirgenir. Şekil 4.2'de öznetelik çıkarımı açıklanmaktadır.



Şekil 4.2. Öznetelik Çıkarımı

4.3 Naive Bayes Modeli ile Sınıflandırma

Tablo 4.1: Naive Bayes Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
NB(Test)	1	%53,50	%53,43	%54,92	%53,95	0,374
	2	%60,00	%61,21	%63,30	%60,17	0,472
	3	%47,00	%47,24	%49,71	%47,47	0,297
	4	%52,50	%52,28	%55,39	%52,65	0,370
	5	%41,50	%44,63	%44,69	%43,03	0,228
	Ortalama	%50,90	%51,76	%53,60	%51,45	0,348


Naive Bayes modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.1’de görülmektedir. En düşük başarı parça 3’te, en yüksek başarı parça 2’de elde edildiği görülmektedir ancak detaylı bir şekilde incelendiğinde doğruluk metriklerinin oldukça düşük olduğu gözlemlenmektedir. Aynı şekilde parçaların ortalama değerleri de oldukça düşüktür.

Tablo 4.2: Naive Bayes Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
NB(Eğitim)	1	%53,37	%53,70	%55,88	%53,84	0,380
	2	%53,62	%54,37	%56,73	%53,88	0,387
	3	%53,25	%53,81	%55,86	%54,06	0,377
	4	%51,00	%51,67	%53,65	%51,55	0,350
	5	%53,62	%54,20	%56,35	%54,30	0,384
	Ortalama	%52,97	%53,55	%55,69	%53,53	0,376


Naive Bayes modelinin artırılmamış eğitim verileri üzerindeki başarısı Tablo 4.2’de görülmektedir. En düşük başarı parça 4’te, en yüksek başarı parça 2 ve 5’te elde edildiği görülmektedir ancak detaylı bir şekilde incelendiğinde doğruluk metriklerinin oldukça düşük olduğu gözlemlenmektedir. Aynı şekilde parçaların ortalama değerleri de oldukça düşüktür.

Şekil 4.3’teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı skuamöz hücreli karsinom sınıfında ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Yapılan yanlış sınıflandırmaların toplamı, doğru sınıflandırmadan fazladır. En iyi sınıflandırma işleme normal sınıfında gerçekleşmiştir ancak bu sınıfta da yanlış sınıflandırma miktarı oldukça büyüktür.



Şekil 4.3. Naive Bayes Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.4'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı skuamöz hücreli karsinom sınıfında ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Yapılan yanlış sınıflandırmaların toplamı, doğru sınıflandırmadan fazladır. En iyi sınıflandırma işleme normal sınıfında gerçekleşmiştir ancak bu sınıfta da yanlış sınıflandırma miktarı oldukça büyüktür.



Şekil 4.4. Naive Bayes Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Naive Bayes modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.3'te görülmektedir. En düşük başarı parça 1'de, en yüksek başarı parça 4'te elde edildiği görülmektedir ancak detaylı bir şekilde incelendiğinde doğruluk metriklerinin oldukça düşük olduğu gözlemlenmektedir. Aynı şekilde parçaların ortalama değerleri de oldukça düşüktür.

Tablo 4.3: Naive Bayes Modelinin Artırılmış Test Verileri Üzerindeki Başarısı


Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
Naive Bayes(Test)	1	%48,39	%49,44	%50,11	%49,77	0,312
	2	%50,50	%50,97	%52,05	%51,43	0,340
	3	%50,94	%51,01	%52,42	%51,70	0,346
	4	%51,61	%52,18	%53,35	%52,75	0,352
	5	%49,77	%49,89	%51,53	%50,69	0,329
	Ortalama	%50,24	%50,69	%51,89	%51,28	0,335

Naive Bayes modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.4'te görülmektedir. En düşük başarı parça 1 ve parça 3'te, en yüksek başarı parça 2'de elde edildiği görülmektedir ancak detaylı bir şekilde incelendiğinde doğruluk metriklerinin oldukça düşük olduğu gözlemlenmektedir. Aynı şekilde parçaların ortalama değerleri de oldukça düşüktür.

Tablo 4.4: Naive Bayes Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı


Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
Naive Bayes(Eğitim)	1	%50,52	%50,96	%52,18	%51,56	0,339
	2	%51,27	%51,69	%53,14	%52,40	0,351
	3	%50,86	%51,35	%52,59	%51,96	0,343
	4	%50,66	%50,88	%52,23	%51,54	0,341
	5	%50,41	%50,61	%52,11	%51,46	0,337
	Ortalama	%50,74	%51,09	%52,45	%51,76	0,342

Şekil 4.5'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı skuamöz hücreli karsinom sınıfında ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Yapılan yanlış sınıflandırmaların toplamı, doğru sınıflandırmadan fazladır. En iyi sınıflandırma işleme normal sınıfında gerçekleşmiştir ancak bu sınıfta da yanlış sınıflandırma miktarı oldukça büyüktür.



Şekil 4.5. Naive Bayes Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.6'daki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı skuamöz hücreli karsinom sınıfında ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Yanlış sınıflandırmaların toplamı, doğru sınıflandırmadan azdır ancak oldukça büyük miktardadır. En iyi sınıflandırma işleme normal sınıfında gerçekleşmiştir ancak bu sınıfta da yanlış sınıflandırma miktarı oldukça büyüktür.



Şekil 4.6. Naive Bayes Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Naive Bayes güçlü bir sınıflandırıcıdır ancak Kaggle Chest CT-Scan veri setiyle uyumlu olmadığı görülmektedir. Eğitim verilerinde dahi yeterli başarı oranına ulaşamamaktadır. Bundan dolayı Naive Bayes sınıflandırıcısı, bu sınıflandırma işlemi için uygun değildir.

4.4 K En Yakın Komşu Modeli ile Sınıflandırma

K en yakın komşu modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.5'te görülmektedir. En düşük başarı parça 3'te, en yüksek başarı parça 5'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %70'in üzerindedir ancak bu oranlar yeterli değildir.

Tablo 4.5: K En Yakın Komşu Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
KNN(Test)	1	%73,50	%77,81	%70,84	%71,05	0,632
	2	%78,00	%80,21	%76,57	%77,31	0,697
	3	%73,00	%75,07	%72,40	%72,34	0,630
	4	%78,50	%79,43	%77,57	%77,28	0,706
	5	%81,00	%82,74	%79,51	%80,04	0,739
	Ortalama	%76,80	%79,05	%75,38	%75,60	0,681


K en yakın komşu modelinin artırılmamış eğitim verileri üzerindeki başarısı Tablo 4.6'da görülmektedir. En düşük başarı parça 5'te, en yüksek başarı parça 2'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %80'in üzerindedir, bu oranlar oldukça yüksektir.

Tablo 4.6: K En Yakın Komşu Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
KNN(Eğitim)	1	%82,75	%85,26	%81,92	%82,79	0,763
	2	%83,25	%84,55	%82,27	%82,72	0,771
	3	%83,00	%84,60	%82,23	%82,78	0,767
	4	%83,12	%85,61	%82,52	%83,31	0,769
	5	%82,12	%84,60	%80,61	%81,22	0,754
	Ortalama	%82,85	%84,92	%81,91	%82,56	0,765


Şekil 4.7'deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı büyük hücreli karsinom sınıfında ve adenokarsinom sınıfında yaptığı

görülmektedir. Parça 1’de diğer parçalara göre kanserli sınıfları normal sınıf olarak tahmini daha fazladır.



Şekil 4.7. K En Yakın Komşu Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.8’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom sınıfında ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Parça 3, 4 ve 5’te diğer parçalara göre kanserli sınıfları normal sınıf olarak tahmini daha fazladır.



Şekil 4.8: K En Yakın Komşu Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

K en yakın komşu modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.7’de görülmektedir. En düşük başarı parça 3, en yüksek başarı parça 5’te elde edilmiştir. Ortalama değerler, kappa hariç %90’ın üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.7: K En Yakın Komşu Modelinin Artırılmış Test Verileri Üzerindeki Başarısı


Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
KNN(Test)	1	%91,16	%91,84	%91,35	%91,59	0,880
	2	%91,38	%92,05	%91,53	%91,78	0,877
	3	%90,11	%90,48	%90,20	%90,33	0,866
	4	%91,38	%91,56	%91,58	%91,56	0,883
	5	%92,00	%92,63	%91,86	%92,24	0,891
	Ortalama	%91,20	%91,40	%91,30	%91,34	0,879

K en yakın komşu modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.8’de görülmektedir. En düşük başarının parça 3’te, en yüksek başarının parça 4’te elde edildiği görülmektedir. Parça 3’ün doğruluk oranı parça 5’ten yüksek olmasına rağmen diğer metriklerde düşük yüzdelere sahip olduğundan en düşük başarıya sahip parça olarak kabul edilmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %90’ın üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.8: K En Yakın Komşu Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı


Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
KNN(Eğitim)	1	%93,83	%94,16	%94,06	%94,10	0,916
	2	%94,15	%94,39	%94,26	%94,32	0,921
	3	%93,70	%94,05	%93,92	%93,98	0,915
	4	%94,00	%94,31	%94,10	%94,20	0,919
	5	%93,38	%94,56	%94,43	%94,49	0,923
	Ortalama	%93,81	%94,26	%94,15	%94,20	0,918

Şekil 4.9'daki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı skuamöz hücreli karsinom sınıfında ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Parça 4'te diğer parçalara göre kanserli sınıfları normal sınıf olarak tahmini daha fazladır.



Şekil 4.10'daki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı skuamöz hücreli karsinom sınıfında ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Parça 4'te diğer parçalara göre kanserli sınıfları normal sınıf

olarak tahmini daha fazladır. Eğitim verilerinde genel olarak sağlıklı akciğer ile adenokarsinomlu akciğer karışmaktadır.



Şekil 4.10. K En Yakın Komşu Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

K en yakın komşu güçlü bir sınıflandırıcıdır ve Kaggle Chest CT-Scan veri setiyle uyumlu olduğu görülmektedir. Modelde $k=10$ olarak alınmıştır. Verilerin ağırlıkları birbirine eşittir. Uzaklık karşılaştırma kaba kuvvet algoritmasıyla yapılmıştır. Eğitim verilerinde ve test verilerinde yeterli başarı oranına ulaşmaktadır. Bundan dolayı k en yakın komşu sınıflandırıcısı, bu sınıflandırma işlemi için uygundur.

4.5 Destek Vektör Makinesi Modeli ile Sınıflandırma

Destek vektör makinesi modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.9’de görülmektedir. En düşük başarı parça 3’te, en yüksek başarı parça 5’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %80’in üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.9: Destek Vektör Makinesi Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
SVM(Test)	1	%83,50	%84,04	%84,39	%84,10	0,776
	2	%82,50	%83,93	%83,89	%83,82	0,762
	3	%78,00	%78,87	%78,58	%78,24	0,701
	4	%87,00	%86,72	%87,76	%87,04	0,824
	5	%85,00	%86,30	%85,69	%85,89	0,796
	Ortalama	%83,20	%83,97	%84,06	%83,82	0,772


Destek vektör makinesi modelinin artırılmamış eğitim verileri üzerindeki başarısı Tablo 4.10’da görülmektedir. En düşük başarı parça 3’te, en yüksek başarı parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %90’a yakındır, bu oldukça yüksek bir orandır.

Tablo 4.10: Destek Vektör Makinesi Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı


Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
SVM(Eğitim)	1	%89,00	%89,47	%89,43	%89,39	0,850
	2	%89,50	%89,73	%90,23	%89,90	0,857
	3	%88,75	%88,91	%89,70	%89,27	0,847
	4	%89,12	%89,46	%89,78	%89,57	0,852
	5	%89,00	%89,40	%89,83	%89,59	0,850
	Ortalama	%89,07	%89,39	%89,79	%89,54	0,851

Şekil 4.11’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır. Parça 2, parça 4 ve parça 5’te hiç karışmamaktadır.

Şekil 4.12’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü hiç karışmamaktadır.



Şekil 4.11. Destek Vektör Makinesi Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri



Şekil 4.12. Destek Vektör Makinesi Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Destek vektör makinesi modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.11’de görülmektedir. En düşük başarı parça 3’te, en yüksek başarı parça 5’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu

görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %90'ın üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.11: Destek Vektör Makinesi Modelinin Artırılmış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
SVM(Test)	1	%92,38	%92,73	%93,15	%92,93	0,897
	2	%91,88	%92,30	%92,65	%92,47	0,890
	3	%91,77	%92,02	%92,31	%92,16	0,889
	4	%92,77	%92,94	%93,59	%93,25	0,902
	5	%93,33	%93,69	%94,00	%93,84	0,910
	Ortalama	%92,42	%92,73	%93,14	%92,14	0,898


Destek vektör makinesi modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.12'de görülmektedir. En düşük başarı parça 1'te, en yüksek başarı parça 2'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %90'ın üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.12: Destek Vektör Makinesi Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı


Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
SVM(Eğitim)	1	%93,61	%93,76	%94,25	%94,00	0,913
	2	%94,00	%94,16	%94,67	%94,41	0,919
	3	%93,84	%94,09	%94,42	%94,25	0,917
	4	%93,79	%94,09	%94,37	%94,22	0,916
	5	%93,91	%94,10	%94,58	%94,33	0,918
	Ortalama	%93,83	%94,04	%94,46	%94,24	0,917

Şekil 4.13'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır. Parça 1 ve parça 5'te hiç karışmamaktadır.

Şekil 4.14'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatanın adenokarsinom sınıfında olduğu görülmektedir. Genellikle kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.



Şekil 4.13. Destek Vektör Makinesi Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri




Şekil 4.14. Destek Vektör Makinesi Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Destek vektör makinesi güçlü bir sınıflandırıcıdır ve Kaggle Chest CT-Scan veri setiyle uyumlu olduğu görülmektedir. Lineer olmayan destek vektör makinesi yöntemi kullanılmıştır. Çekirdek olarak radyal tabanlı fonksiyon kullanılmıştır. Karar

fonksiyonu olarak bire karşı diğerleri uygulanmıştır. Eğitim verilerinde ve test verilerinde yeterli başarı oranına ulaşmaktadır. Bundan dolayı destek vektör makinesi sınıflandırıcısı, bu sınıflandırma işlemi için uygundur.

4.6 Yapay Sinir Ağı Modelleri ile Sınıflandırma

Yapay sinir ağı, üç farklı optimizasyon algoritması ile eğitilmiştir. Bu algoritmalar ölçeklenmiş eşlenik gradyan, Levenberg-Marquardt ve momentumlu dereceli azalma algoritmalarıdır. Momentumlu dereceli azalma algoritmasında öğrenme katsayısı 0.1 diğer algoritmalarda 0.001'dir. Girdi vektörünün boyutu 50, gizli katmanın boyutu 10, çıktı katmanının boyutu 4'tür. Şekil 4.15'te kullanılan yapay sinir ağı modeli görülmektedir.



Şekil 4.15. Kullanılan Yapay Sinir Ağı Modeli

4.6.1 Ölçeklendirilmiş Eşlenik Gradyan ile Sınıflandırma

Ölçeklendirilmiş eşlenik gradyan optimizasyonu ile eğitilmiş yapay sinir ağı modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.13'te görülmektedir. En düşük başarı parça 4'te, en yüksek başarı parça 5'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %80'in üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.13: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
SCG(Test)	1	%84,00	%84,69	%84,51	%84,56	0,781
	2	%85,00	%84,62	%87,33	%85,45	0,797
	3	%81,00	%82,86	%82,40	%82,60	0,743
	4	%79,50	%78,62	%80,96	%79,61	0,717
	5	%85,50	%86,58	%86,77	%86,66	0,802
	Ortalama	%83,00	%83,47	%84,39	%83,78	0,768

Ölçeklendirilmiş eşlenik gradyan optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmamış eğitim verileri üzerindeki başarısı Tablo 4.14'te görülmektedir. En düşük başarı parça 1'de, en yüksek başarı parça 3'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %90'ın üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.14: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
SCG(Eğitim)	1	%91,00	%91,16	%91,31	%91,22	0,878
	2	%91,12	%91,04	%92,26	%91,57	0,879
	3	%93,37	%93,60	%94,05	%93,80	0,910
	4	%92,62	%93,21	%93,25	%93,22	0,900
	5	%92,87	%93,41	%93,25	%93,33	0,903
	Ortalama	%92,20	%92,48	%92,82	%92,63	0,894

Ölçeklendirilmiş eşlenik gradyan optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmamış test verileri üzerindeki hata oranları Tablo 4.15'te görülmektedir. En yüksek hata parça 4'te, en düşük hata parça 2'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.2'nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.15: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Test Verileri Üzerindeki Hata Oranları

Algoritma	Parça	ÇE	OKH	KOKH	OMH
SCG(Test)	1	0,1412	0,0649	0,2548	0,1055
	2	0,1075	0,0548	0,2342	0,1063
	3	0,1178	0,0625	0,2501	0,1123
	4	0,1639	0,0750	0,2740	0,1105
	5	0,1038	0,0562	0,2372	0,0959
	Ortalama	0,1268	0,0627	0,2501	0,1061


Ölçeklendirilmiş eşlenik gradyan optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin artırılmamış eğitim verileri üzerindeki hata oranları Tablo 4.16’da görülmektedir. En yüksek hata parça 2’de, en düşük hata parça 4’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.1’nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.16: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
SCG(Eğitim)	1	0,0584	0,0324	0,1801	0,0746
	2	0,0671	0,0355	0,1885	0,0860
	3	0,0565	0,0288	0,1699	0,0730
	4	0,0490	0,0258	0,1607	0,0567
	5	0,0527	0,0279	0,1671	0,0657
	Ortalama	0,0567	0,0301	0,1733	0,0712

Şekil 4.16’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır. Parça 2, 3 ve 5’te kanserli görüntüler, sağlıklı görüntü olarak sınıflandırılmamaktadır.

Şekil 4.17’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır. Parça 1’de kanserli görüntüler, sağlıklı görüntü olarak sınıflandırılmamaktadır.




Şekil 4.16. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri



Şekil 4.17. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.18 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.18. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmamış Veri Seti Üzerindeki Hata Grafikleri

Ölçeklendirilmiş eşlenik gradyan optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.17’de görülmektedir. En düşük başarı parça 5’te, en yüksek başarı parça 1’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %90’ın üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.17: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
SCG(Test)	1	%95,30	%95,90	%95,22	%95,55	0,936
	2	%93,80	%94,15	%94,05	%94,09	0,916
	3	%93,20	%93,62	%93,77	%93,63	0,909
	4	%94,20	%94,55	%94,57	%94,56	0,921
	5	%93,10	%93,22	%93,69	%93,45	0,907
	Ortalama	%93,92	%94,29	%94,26	%94,27	0,918

Ölçeklendirilmiş eşlenik gradyan optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.18’de görülmektedir. En düşük başarı parça 3’te, en yüksek başarı parça 1’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya

da yansımaktadır. Ortalama değerler, %95'in üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.18: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
SCG(Eğitim)	1	%97,60	%98,00	%97,65	%97,82	0,967
	2	%96,30	%96,55	%96,49	%96,51	0,949
	3	%95,80	%96,22	%96,12	%96,16	0,944
	4	%96,60	%96,65	%96,87	%96,75	0,954
	5	%97,00	%97,05	%97,20	%97,12	0,959
	Ortalama	%96,66	%96,89	%96,87	%96,88	0,955

Ölçeklendirilmiş eşlenik gradyan optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmış test verileri üzerindeki hata oranları Tablo 4.19'da görülmektedir. En yüksek hata parça 2'de, en düşük hata parça 1'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.1'in altındadır, bu oldukça düşük bir orandır.

Tablo 4.19: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Test Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
SCG(Test)	1	0,0528	0,0186	0,1366	0,0326
	2	0,0632	0,0262	0,1618	0,0472
	3	0,0617	0,0288	0,1697	0,0520
	4	0,0557	0,0228	0,1511	0,0437
	5	0,0680	0,0276	0,1664	0,0474
	Ortalama	0,0603	0,0248	0,1571	0,0446

Ölçeklendirilmiş eşlenik gradyan optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmış eğitim verileri üzerindeki hata oranları Tablo 4.20'de görülmektedir. En yüksek hata parça 3'te, en düşük hata parça 1'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.05'in altındadır, bu oldukça düşük bir orandır.

Tablo 4.20: Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Hata Oranı


Algoritma	Parça	ÇE	OKH	KOKH	OMH
SCG(Eğitim)	1	0,0167	0,0086	0,0931	0,0211
	2	0,0298	0,0153	0,1238	0,0333
	3	0,0341	0,0173	0,1318	0,0381
	4	0,0306	0,0142	0,1193	0,0321
	5	0,0289	0,0132	0,1149	0,0302
	Ortalama	0,0280	0,0137	0,1166	0,0310

Şekil 4.19'daki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır. Parça 3'te kanserli görüntüler, sağlıklı görüntü olarak sınıflandırılmamaktadır.




Şekil 4.19. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.20'deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır. Parça 1 ve parça 2'de sağlıklı akciğer tomografi görüntüsü, kanserli görüntü olarak sınıflandırılmamaktadır.



Şekil 4.20. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.21 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.21. Ölçeklendirilmiş Eşlenik Gradyan Algoritmasının Artırılmış Veri Seti Üzerindeki Hata Grafikleri

Ölçeklendirilmiş eşlenik gradyan güçlü bir optimizasyon yöntemidir ve Kaggle Chest CT-Scan veri setiyle uyumlu olduğu görülmektedir. Eğitim verilerinde ve test verilerinde yeterli başarı oranına ulaşmaktadır. Bundan dolayı ölçeklenmiş eşlenik gradyan optimizasyonu, bu sınıflandırma işlemi için uygundur.

4.6.2 Levenberg-Marquardt ile Sınıflandırma

Levenberg-Marquardt optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.21’de görülmektedir. En düşük başarı parça 4’te, en yüksek başarı parça 5’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, genel olarak %80’e yakındır, bu oldukça yüksek bir orandır.

Tablo 4.21: Levenberg-Marquardt Algoritmasının Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
LM(Test)	1	%80,50	%80,50	%80,21	%80,33	0,737
	2	%80,50	%76,42	%76,41	%76,41	0,735
	3	%83,50	%81,99	%83,05	%82,31	0,774
	4	%75,50	%76,06	%76,71	%76,22	0,662
	5	%82,00	%83,65	%87,72	%83,44	0,756
	Ortalama	%80,40	%79,72	%80,82	%79,74	0,733

Levenberg-Marquardt optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmamış eğitim verileri üzerindeki başarısı Tablo 4.22’de görülmektedir. En düşük başarı parça 4’te, en yüksek başarı parça 3’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, genel olarak %90’a yakındır.

Tablo 4.22: Levenberg-Marquardt Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
LM(Eğitim)	1	%89,62	%89,89	%89,93	%89,91	0,859
	2	%88,00	%88,96	%87,90	%88,28	0,838
	3	%92,87	%93,46	%92,98	%93,15	0,904
	4	%82,00	%81,42	%83,63	%82,25	0,754
	5	%86,37	%85,73	%88,30	%86,41	0,815
	Ortalama	%87,77	%87,89	%88,55	%88,00	0,834

Levenberg-Marquardt optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmamış test verileri üzerindeki hata oranları Tablo 4.23'te görülmektedir. En yüksek hata parça 4'te, en düşük hata parça 3'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.2'nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.23: Levenberg-Marquardt Algoritmasının Artırılmamış Test Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
LM(Test)	1	0,1268	0,0743	0,2726	0,1585
	2	0,1241	0,0765	0,2766	0,1696
	3	0,1098	0,0586	0,2422	0,1151
	4	0,1362	0,0887	0,2978	0,2032
	5	0,1161	0,0683	0,2615	0,1524
	Ortalama	0,1226	0,0733	0,2701	0,1598

Levenberg-Marquardt optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmamış eğitim verileri üzerindeki hata oranları Tablo 4.24'te görülmektedir. En yüksek hata parça 4'te, en düşük hata parça 3'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.2'nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.24: Levenberg-Marquardt Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
LM(Eğitim)	1	0,0965	0,0489	0,2212	0,1305
	2	0,1094	0,0538	0,2320	0,1403
	3	0,0816	0,0306	0,1750	0,0797
	4	0,1278	0,0792	0,2815	0,1923
	5	0,1044	0,0556	0,2359	0,1367
	Ortalama	0,1039	0,0536	0,2291	0,1359

Şekil 4.22'deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.




Şekil 4.22. Levenberg-Marquardt Algoritmasının Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.23'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı büyük hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü parça 4 hariç nadiren karışmaktadır.



Şekil 4.23. Levenberg-Marquardt Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.24 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.24. Levenberg-Marquardt Algoritmasının Artırılmamış Veri Seti Üzerindeki Hata Grafikleri

Levenberg-Marquardt optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.25'te görülmektedir. En düşük başarı parça 1'de, en yüksek başarı parça 5'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %95'in üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.25: Levenberg-Marquardt Algoritmasının Artırılmış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
LM(Test)	1	%94,30	%93,89	%94,22	%94,05	0,922
	2	%95,90	%96,02	%96,00	%96,01	0,945
	3	%95,70	%95,50	%95,75	%95,64	0,942
	4	%95,70	%95,60	%95,75	%95,66	0,941
	5	%96,10	%96,30	%96,07	%96,18	0,947
	Ortalama	%95,54	%95,46	%95,56	%95,51	0,939

Levenberg-Marquardt optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.26’da görülmektedir. En düşük başarı parça 4’te, en yüksek başarı parça 5’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %95’in üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.26: Levenberg-Marquardt Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
LM(Eğitim)	1	%97,40	%97,10	%97,52	%97,30	0,965
	2	%97,70	%97,70	%97,72	%97,70	0,968
	3	%97,50	%97,30	%97,54	%97,41	0,966
	4	%97,00	%96,82	%97,02	%96,90	0,960
	5	%98,00	%97,94	%98,00	%97,96	0,973
	Ortalama	%97,52	%97,37	%97,56	%97,45	0,966

Levenberg-Marquardt optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmış test verileri üzerindeki hata oranları Tablo 4.27’de görülmektedir. En yüksek hata parça 1’de, en düşük hata parça 5’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.1’in altındadır, bu oldukça düşük bir orandır.

Tablo 4.27: Levenberg-Marquardt Algoritmasının Artırılmış Test Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
LM(Test)	1	0,0613	0,0264	0,1626	0,0315
	2	0,0512	0,0196	0,1400	0,0247
	3	0,0546	0,0198	0,1409	0,0256
	4	0,0503	0,0189	0,1377	0,0239
	5	0,0494	0,0182	0,1351	0,0244
	Ortalama	0,0534	0,0206	0,1433	0,0260

Levenberg-Marquardt optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmış eğitim verileri üzerindeki hata oranları Tablo 4.28’te görülmektedir. En yüksek hata parça 4’te, en düşük hata parça 5’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.1’in altındadır, bu oldukça düşük bir orandır.

Tablo 4.28: Levenberg-Marquardt Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
LM(Eğitim)	1	0,0268	0,0114	0,1068	0,0152
	2	0,0233	0,0105	0,1025	0,0146
	3	0,0249	0,0111	0,1053	0,0162
	4	0,0297	0,0123	0,1110	0,0165
	5	0,0216	0,0088	0,0940	0,0142
	Ortalama	0,0253	0,0108	0,1039	0,0153

Şekil 4.25'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı büyük hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü bazen karışmaktadır.




Şekil 4.25: Levenberg-Marquardt Algoritmasının Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.26'daki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı büyük hücreli karsinom sınıfında ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü bazen karışmaktadır.



Şekil 4.26: Levenberg-Marquardt Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.27 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.27. Levenberg-Marquardt Algoritmasının Artırılmış Veri Seti Üzerindeki Hata Grafikleri

Levenberg-Marquardt güçlü bir optimizasyon yöntemidir ve Kaggle Chest CT-Scan veri setiyle uyumlu olduğu görülmektedir. Eğitim verilerinde ve test verilerinde yeterli başarı oranına ulaşmaktadır. Bundan dolayı Levenberg-Marquardt optimizasyonu, bu sınıflandırma işlemi için uygundur.

4.6.3 Momentumlu Dereceli Azalma ile Sınıflandırma

Momentumlu dereceli optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.29'da görülmektedir. En düşük başarı parça 2'de, en yüksek başarı parça 3'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, genel olarak %80'e yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.29: Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
GDM(Test)	1	%82,00	%81,29	%83,35	%81,67	0,756
	2	%72,00	%72,66	%75,94	%73,57	0,617
	3	%83,50	%82,82	%85,79	%83,74	0,771
	4	%80,50	%82,18	%81,10	%81,55	0,738
	5	%80,00	%81,50	%80,47	%80,90	0,727
	Ortalama	%79,60	%80,09	%81,33	%80,29	0,722

Momentumlu dereceli optimizasyonu ile eğitilmiş yapay sinir ağları modelinin test verileri üzerindeki başarısı Tablo 4.30'da görülmektedir. En düşük başarı parça 3'te, en yüksek başarı parça 5'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %85'e yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.30: Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
GDM(Eğitim)	1	%82,75	%82,87	%84,55	%83,49	0,764
	2	%86,62	%86,75	%87,70	%87,16	0,818
	3	%84,00	%84,56	%84,92	%84,68	0,783
	4	%82,62	%83,17	%84,28	%83,57	0,763
	5	%85,50	%85,55	%86,60	%85,98	0,803
	Ortalama	%84,30	%84,58	%85,61	%84,98	0,786

Momentumlu dereceli azalma optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin artırılmamış test verileri üzerindeki hata oranları Tablo 4.31’de görülmektedir. En yüksek hata parça 5’te, en düşük hata parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.2’nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.31: Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Test Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
GDM(Test)	1	0,1279	0,0658	0,2566	0,1469
	2	0,1534	0,0870	0,2950	0,1785
	3	0,1248	0,0674	0,2598	0,1500
	4	0,1323	0,0687	0,2622	0,1499
	5	0,1411	0,0751	0,2741	0,1580
	Ortalama	0,1359	0,0728	0,2695	0,1567

Momentumlu dereceli azalma optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin test verileri üzerindeki hata oranları Tablo 4.32’de görülmektedir. En yüksek hata parça 1’de, en düşük hata parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.2’nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.32: Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
GDM(Eğitim)	1	0,1196	0,0649	0,2548	0,1512
	2	0,0997	0,0520	0,2280	0,1310
	3	0,1100	0,0587	0,2424	0,1412
	4	0,1093	0,0608	0,2466	0,1435
	5	0,1035	0,0550	0,2741	0,1351
	Ortalama	0,1084	0,0583	0,2492	0,1404

Şekil 4.28’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.




Şekil 4.28. Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.29'daki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve büyük hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.



Şekil 4.29. Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.30 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.30. Momentumlu Dereceli Azalma Algoritmasının Artırılmamış Veri Seti Üzerindeki Hata Grafikleri

Momentumlu dereceli optimizasyonu ile eğitilmiş yapay sinir ağları modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.33'te görülmektedir. En düşük başarı parça 5'te, en yüksek başarı parça 2'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %75'in altındadır, akciğer kanseri tanısı için bu oldukça düşük bir orandır.

Tablo 4.33: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
GDM(Test)	1	%74,00	%75,42	%74,60	%75,00	0,646
	2	%74,30	%74,72	%74,42	%74,56	0,687
	3	%73,70	%74,62	%74,87	%74,15	0,643
	4	%72,80	%74,00	%74,00	%74,00	0,631
	5	%72,40	%72,80	%72,85	%72,82	0,624
	Ortalama	%73,44	%74,31	%74,15	%74,22	0,646

Momentumlu dereceli azalma optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.34’de görülmektedir. En düşük başarı parça 3’te, en yüksek başarı parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %80’in altındadır, akciğer kanseri tanısı için bu oldukça düşük bir orandır.

Tablo 4.34: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
GDM(Eğitim)	1	%75,00	%75,50	%76,32	%75,90	0,660
	2	%76,10	%76,52	%76,82	%76,66	0,675
	3	%73,60	%74,20	%74,77	%74,48	0,641
	4	%74,50	%75,22	%75,40	%75,30	0,655
	5	%75,10	%75,92	%76,2	%76,08	0,662
	Ortalama	%74,86	%75,47	%75,91	%75,68	0,659

Momentumlu dereceli azalma optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin artırılmış test verileri üzerindeki hata oranları Tablo 4.35’de görülmektedir. En düşük yüksek hata parça 5’te, en düşük hata parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, OKH hariç 0.1’in üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.35: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Test Verileri Üzerindeki Hata Oranları

Algoritma	Parça	ÇE	OKH	KOKH	OMH
GDM(Test)	1	0,1658	0,0912	0,3021	0,1990
	2	0,1647	0,0905	0,3009	0,1975
	3	0,1678	0,0931	0,3032	0,2029
	4	0,1715	0,0955	0,3090	0,2084
	5	0,1730	0,0961	0,3100	0,2041
	Ortalama	0,1686	0,0933	0,3050	0,2024


Momentumlu dereceli azalma optimizasyonu ile eğitilmiş yapay sinir ağıları modelinin artırılmış eğitim verileri üzerindeki hata oranları Tablo 4.36’da görülmektedir. En düşük yüksek hata parça 4’te, en düşük hata parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir

ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, OKH hariç 0.1'in üzerindedir, bu oldukça yüksek bir orandır.

Tablo 4.36: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Eğitim Verileri Üzerindeki Hata Oranları

Algoritma	Parça	ÇE	OKH	KOKH	OMH
GDM(Eğitim)	1	0,1609	0,0888	0,2980	0,1963
	2	0,1582	0,0870	0,2949	0,1975
	3	0,1656	0,0919	0,3032	0,2020
	4	0,1715	0,0903	0,3006	0,2016
	5	0,1605	0,0889	0,2981	0,1968
	Ortalama	0,1633	0,0894	0,2990	0,1988

Şekil 4.31'deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü bazen karışmaktadır.




Şekil 4.31. Momentumlu Dereceli Azalma Algoritmasının Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri


Karmaşıklık Matrisleri

Şekil 4.32'deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında

kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü bazen karışmaktadır.



Şekil 4.32: Momentumlu Dereceli Azalma Algoritmasının Artırılmış Eğitim Verileri Üzerindeki



Şekil 4.33. Momentumlu Dereceli Azalma Algoritmasının Artırılmış Veri Seti Üzerindeki Hata Grafikleri


Şekil 4.30 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak

sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.

Momentumlu dereceli azalma basit sınıflandırma işlemlerinde güçlü bir optimizasyon yöntemidir ancak görüntü sınıflandırmada yeterince güçlü değildir. Kaggle Chest CT-Scan veri setiyle uyumlu olmadığı görülmektedir. Eğitim verilerinde ve test verilerinde yeterli başarı oranına ulaşamamaktadır. Bundan dolayı dereceli azalma optimizasyonu, bu sınıflandırma işlemi için uygun değildir.

4.7 Evrişimsel Sinir Ağları Modeli ile Sınıflandırma

Evrişimsel sinir ağları, adam optimizasyon algoritmasıyla eğitilmiştir. Üç adet evrişimsel katman, 2 adet ortalama havuzlama katmanı ve bir adet 10 nöronlu oluşan tam bağlantılı katmandan meydana gelmektedir. Öğrenme katsayısı 0,001'dir. Şekil 4.34'te kullanılan evrişimsel sinir ağı modeli görülmektedir.



Şekil 4.34. Kullanılan Evrişimsel Sinir Ağı Modeli

Evrişimsel sinir ağıları modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.37’de görülmektedir. En düşük başarı parça 4’te, en yüksek başarı parça 1’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, genel olarak %90’a yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.37: Evrişimsel Sinir Ağları Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
CNN(Test)	1	%92,50	%93,18	%92,49	%92,78	0,897
	2	%85,50	%86,91	%86,06	%86,26	0,802
	3	%87,00	%86,92	%88,28	%87,47	0,824
	4	%85,00	%85,38	%86,73	%85,73	0,798
	5	%89,50	%90,57	%90,45	%90,50	0,857
	Ortalama	%87,90	%88,59	%88,80	%88,55	0,836

Evrişimsel sinir ağıları modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.38’de görülmektedir. En düşük başarı parça 4’te, en yüksek başarı parça 1’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %95’ten fazladır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.38: Evrişimsel Sinir Ağları Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
CNN(Eğitim)	1	%98,25	%98,39	%98,44	%98,41	0,976
	2	%95,75	%96,01	%96,02	%96,00	0,942
	3	%97,87	%97,92	%97,96	%97,93	0,971
	4	%93,25	%94,03	%94,23	%94,11	0,908
	5	%97,62	%98,04	%97,78	%97,88	0,967
	Ortalama	%96,55	%96,88	%96,89	%96,87	0,953

Evrişimsel sinir ağıları modelinin artırılmamış test verileri üzerindeki hata oranları Tablo 4.39’da görülmektedir. En yüksek hata parça 4’te, en düşük hata parça 1’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH hariç 0.2’nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.39: Evrişimsel Sinir Ağları Modelinin Artırılmamış Test Verileri Hata Oranları

Algoritma	Parça	ÇE	OKH	KOKH	OMH
CNN(Test)	1	0,2579	0,0309	0,1757	0,0716
	2	0,3765	0,0507	0,2253	0,0965
	3	0,3093	0,0431	0,2076	0,0837
	4	0,4082	0,0552	0,2349	0,1167
	5	0,3644	0,0434	0,2082	0,0805
	Ortalama	0,3433	0,0447	0,2103	0,0898


Evrişimsel sinir ağları modelinin artırılmamış eğitim verileri üzerindeki hata oranları Tablo 4.40'ta görülmektedir. En yüksek hata parça 4'te, en düşük hata parça 3'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, KOKH ve ÇE hariç 0.1'nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.40: Evrişimsel Sinir Ağları Modelinin Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
CNN(Eğitim)	1	0,1021	0,0103	0,1014	0,0421
	2	0,1539	0,0180	0,1343	0,0560
	3	0,0954	0,0100	0,1000	0,0346
	4	0,2405	0,0311	0,1765	0,0861
	5	0,1029	0,0108	0,1041	0,0393
	Ortalama	0,1390	0,0160	0,1233	0,0516

Şekil 4.35'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.

Şekil 4.36'daki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.




Şekil 4.35. Evrişimsel Sinir Ağları Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri



Şekil 4.36. Evrişimsel Sinir Ağları Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisi

Şekil 4.37 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak

sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.37. Evrişimsel Sinir Ağları Modelinin Artırılmamış Veri Seti Üzerindeki Hata Grafikleri

Evrişimsel sinir ağları modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.41’de görülmektedir. En düşük başarı parça 2’de, en yüksek başarı parça 1’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, genel olarak %100’e yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.41: Evrişimsel Sinir Ağları Modelinin Artırılmış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
CNN(Test)	1	%99,28	%99,29	%99,36	%99,32	0,990
	2	%97,56	%97,55	%98,05	%97,79	0,967
	3	%98,89	%98,91	%98,97	%98,93	0,985
	4	%98,89	%98,97	%98,91	%98,94	0,985
	5	%98,94	%98,87	%99,03	%98,95	0,986
	Ortalama	%98,71	%98,72	%98,86	%98,78	0,983

Evrişimsel sinir ağları modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.42’te görülmektedir. En düşük başarı parça 2’de, en yüksek başarı parça 5’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, genel olarak %100’e yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.42: Evrişimsel Sinir Ağları Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
CNN(Eğitim)	1	%99,33	%99,40	%99,29	%99,34	0,991
	2	%98,75	%98,65	%98,97	%98,80	0,983
	3	%99,42	%99,43	%99,43	%99,43	0,992
	4	%99,11	%99,12	%99,21	%99,16	0,988
	5	%99,67	%99,63	%99,72	%99,67	0,995
	Ortalama	%99,26	%99,25	%99,32	%99,28	0,990

Evrişimsel sinir ağları modelinin artırılmış test verileri üzerindeki hata oranları Tablo 4.43'te görülmektedir. En yüksek hata parça 2'te, en düşük hata parça 1'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, 0.1'nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.43: Evrişimsel Sinir Ağları Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı


Algoritma	Parça	ÇE	OKH	KOKH	OMH
CNN(Test)	1	0,0260	0,0310	0,0557	0,0101
	2	0,0657	0,0092	0,0959	0,0185
	3	0,0392	0,0050	0,0710	0,0113
	4	0,0353	0,0045	0,0670	0,0353
	5	0,0299	0,0042	0,0646	0,0099
	Ortalama	0,0392	0,0108	0,0708	0,0170

Evrişimsel sinir ağları modelinin artırılmış eğitim verileri üzerindeki hata oranları Tablo 4.44'te görülmektedir. En yüksek hata parça 2'de, en düşük hata parça 1'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, 0.1'nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.44: Evrişimsel Sinir Ağları Modelinin Artırılmış Test Verileri Üzerindeki Hata Oranları

Algoritma	Parça	ÇE	OKH	KOKH	OMH
CNN(Eğitim)	1	0,0199	0,0024	0,0493	0,0074
	2	0,0407	0,0052	0,0719	0,0134
	3	0,0204	0,0024	0,0490	0,0068
	4	0,0282	0,0035	0,0593	0,0104
	5	0,0139	0,0016	0,0395	0,0053
	Ortalama	0,0246	0,0030	0,0538	0,0086


Şekil 4.38'deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.




Şekil 4.38. Evrişimsel Sinir Ağları Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.39'daki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.

Şekil 4.40 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.39. Evrişimsel Sinir Ağları Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri



Şekil 4.40. Evrişimsel Sinir Ağları Modelinin Artırılmış Veri Seti Üzerindeki Hata Grafikleri

Evrişimsel sinir ağları modeli güçlü bir sınıflandırıcıdır ve Kaggle Chest CT-Scan veri setiyle uyumlu olduğu görülmektedir. Eğitim verilerinde ve test verilerinde yeterli başarı oranına ulaşmaktadır. Bundan dolayı ölçeklenmiş eşlenik gradyan optimizasyonu, bu sınıflandırma işlemi için uygundur.

4.8 ResNetRS101 Modeli ile Sınıflandırma

ResNetRS101 modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.45'te görülmektedir. En düşük başarı parça 4'te, en yüksek başarı parça 3'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %90'ın üzerindedir, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.45: ResNetRS101 Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
ResNetRS101(Test)	1	%90,50	%91,08	%90,76	%90,76	0,870
	2	%91,00	%90,69	%91,57	%91,03	0,878
	3	%93,00	%93,23	%92,56	%92,80	0,904
	4	%88,50	%88,83	%88,13	%88,29	0,843
	5	%91,00	%91,89	%90,99	%91,38	0,877
	Ortalama	%90,80	%91,14	%90,80	%90,85	0,874

ResNetRS101 modelinin artırılmamış eğitim verileri üzerindeki başarısı Tablo 4.46'da görülmektedir. En düşük başarı parça 1'de, en yüksek başarı parça 5'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %100'e yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.46: ResNetRS101 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
ResNetRS101 (Eğitim)	1	%99,12	%99,00	%99,11	%99,08	0,988
	2	%99,75	%99,71	%99,71	%99,71	0,996
	3	%99,75	%99,71	%99,71	%99,71	0,996
	4	%99,50	%99,47	%99,44	%99,45	0,993
	5	%99,75	%99,81	%99,71	%99,76	0,996
	Ortalama	%99,57	%99,54	%99,54	%99,54	0,994

ResNetRS101 modelinin artırılmamış test verileri üzerindeki hata oranları Tablo 4.47'de görülmektedir. En yüksek hata parça 4'te, en düşük hata parça 5'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, ÇE hariç 0.2'nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.47: ResNetRS101 Modelinin Artırılmamış Test Verileri Üzerindeki Hata Oranları

Algoritma	Parça	ÇE	OKH	KOKH	OMH
ResNetRS101(Test)	1	0,2991	0,0349	0,1868	0,0593
	2	0,2636	0,0312	0,1767	0,0694
	3	0,2261	0,0249	0,1577	0,0379
	4	0,3680	0,0405	0,2013	0,0795
	5	0,2919	0,0309	0,1758	0,0521
	Ortalama	0,2897	0,0325	0,1797	0,0596


ResNetRS101 modelinin artırılmamış eğitim verileri üzerindeki hata oranları Tablo 4.48’de görülmektedir. En yüksek hata parça 4’te, en düşük hata parça 5’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, ÇE hariç 0.2’nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.48: ResNetRS101 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
ResNetRS101(Eğitim)	1	0,0351	0,0031	0,0554	0,0131
	2	0,0420	0,0020	0,0445	0,0190
	3	0,0136	0,0011	0,0332	0,0053
	4	0,0584	0,0033	0,0572	0,0250
	5	0,0163	0,0008	0,0292	0,0071
	Ortalama	0,0331	0,0021	0,0439	0,0139

Şekil 4.41’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.

Şekil 4.42’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada nadiren hata yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.




Şekil 4.41. ResNetRS101 Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri



Şekil 4.42. ResNetRS101 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.43 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.43. ResNetRS101 Modelinin Artırılmamış Veri Seti Üzerindeki Hata Grafikleri

ResNetRS101 modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.49’da görülmektedir. En düşük başarı parça 5’te, en yüksek başarı parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %100’e yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.49: ResNetRS101 Modelinin Artırılmış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
ResNetRS101(Test)	1	%98,67	%98,48	%98,75	%98,61	0,981
	2	%99,39	%99,36	%99,44	%99,39	0,991
	3	%98,89	%98,98	%98,81	%98,89	0,984
	4	%98,94	%98,97	%98,98	%98,98	0,985
	5	%98,00	%97,88	%98,22	%98,04	0,972
	Ortalama	%98,78	%98,73	%98,84	%98,78	0,983

ResNetRS101 modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.50’de görülmektedir. En düşük başarı parça 5’te, en yüksek başarı parça 3 ve 4’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, %100’e yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.50: ResNetRS101 Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
ResNetRS101 (Eğitim)	1	%99,81	%99,78	%99,70	%99,79	0,997
	2	%99,82	%99,79	%99,83	%99,81	0,997
	3	%99,85	%99,84	%99,81	%99,82	0,998
	4	%99,85	%99,84	%99,85	%99,85	0,998
	5	%99,65	%99,62	%99,60	%99,65	0,995
	Ortalama	%99,80	%99,77	%99,76	%99,78	0,997

ResNetRS101 modelinin artırılmış test verileri üzerindeki hata oranları Tablo 4.51’de görülmektedir. En yüksek hata parça 5’te, en düşük hata parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, 0.1’in altındadır, bu oldukça düşük bir orandır.

Tablo 4.51: ResNetRS101 Modelinin Artırılmış Test Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
ResNetRS101(Test)	1	0,0352	0,0047	0,0688	0,0098
	2	0,0231	0,0027	0,0515	0,0051
	3	0,0450	0,0051	0,0715	0,0081
	4	0,0493	0,0047	0,0686	0,0078
	5	0,0812	0,0079	0,0888	0,0140
	Ortalama	0,0468	0,0050	0,0698	0,0090

ResNetRS101 modelinin artırılmış eğitim verileri üzerindeki hata oranları Tablo 4.52’de görülmektedir. En yüksek hata parça 5’te, en düşük hata parça 3’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, 0.1’in altındadır, bu oldukça düşük bir orandır.

Tablo 4.52: ResNetRS101 Modelinin Artırılmış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
ResNetRS101(Eğitim)	1	0,0082	0,0009	0,0305	0,0030
	2	0,0057	0,0007	0,0271	0,0015
	3	0,0032	0,0004	0,0211	0,0012
	4	0,0045	0,0004	0,0213	0,0011
	5	0,0122	0,0013	0,0366	0,0038
	Ortalama	0,0068	0,0007	0,0273	0,0021

Şekil 4.44'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinomda yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.




Şekil 4.44. ResNetRS101 Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.45'teki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı büyük hücreli karsinom ve skuamöz hücreli karsinomda yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.



Şekil 4.45. ResNetRS101 Modelinin Artırılmış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.46 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.46. ResNetRS101 Modelinin Artırılmış Veri Seti Üzerindeki Hata Grafikleri

ResNetRS101 modeli güçlü bir sınıflandırıcıdır ve Kaggle Chest CT-Scan veri setiyle uyumlu olduğu görülmektedir. Eğitim verilerinde ve test verilerinde yeterli başarı oranına ulaşmaktadır. Bundan dolayı ölçeklenmiş eşlenik gradyan optimizasyonu, bu sınıflandırma işlemi için uygundur.

4.9 VGG16 Modeli ile Karşılaştırma

VGG16 modelinin artırılmamış test verileri üzerindeki başarısı Tablo 4.53'te görülmektedir. En düşük başarı parça 4'te, en yüksek başarı parça 3'te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %80'e yakındır, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.53: VGG16 Modelinin Artırılmamış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
VGG16(Test)	1	%80,50	%81,23	%80,99	%81,08	0,734
	2	%78,00	%80,30	%80,15	%80,21	0,704
	3	%80,00	%81,14	%81,33	%81,20	0,728
	4	%76,00	%75,98	%77,06	%76,45	0,675
	5	%74,00	%76,56	%76,85	%75,80	0,651
	Ortalama	%77,70	%79,04	%79,28	%78,95	0,698

VGG16 modelinin artırılmamış eğitim verileri üzerindeki başarısı Tablo 4.54'te görülmektedir. En düşük başarı parça 5'te, en yüksek başarı parça 1'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %90'ın üzerindedir, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.54: VGG16 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
VGG16(Eğitim)	1	%96,38	%96,42	%90,29	%96,34	0,950
	2	%86,87	%87,56	%88,58	%87,59	0,823
	3	%90,87	%90,71	%91,79	%91,11	0,876
	4	%91,75	%92,47	%92,17	%92,31	0,887
	5	%85,37	%87,40	%87,45	%86,87	0,802
	Ortalama	%90,25	%90,91	%90,06	%90,84	0,868

VGG16 modelinin artırılmamış test verileri üzerindeki hata oranları Tablo 4.55'te görülmektedir. En yüksek hata parça 4'te, en düşük hata parça 2'de elde

edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, ÇE hariç 0.5'nin altındadır, bu oldukça yüksek bir orandır.

Tablo 4.55: VGG16 Modelinin Artırılmamış Test Verileri Üzerindeki Hata Oranları

Algoritma	Parça	ÇE	OKH	KOKH	OMH
VGG16(Test)	1	0,5471	0,0753	0,2744	0,1220
	2	0,5130	0,0725	0,2693	0,1403
	3	0,5880	0,0735	0,2711	0,1437
	4	0,6391	0,0855	0,2924	0,1556
	5	0,5643	0,0818	0,2860	0,1698
	Ortalama	0,5703	0,0777	0,2786	0,1463


VGG16 modelinin artırılmamış eğitim verileri üzerindeki hata oranları Tablo 4.56'da görülmektedir. En yüksek hata parça 4'te, en düşük hata parça 2'de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, ÇE hariç 0.2'nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.56: VGG16 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
VGG16(Eğitim)	1	0,1431	0,0168	0,1297	0,0479
	2	0,0477	0,0477	0,2184	0,1069
	3	0,2753	0,0337	0,1835	0,0893
	4	0,3001	0,0360	0,1898	0,0968
	5	0,4160	0,0565	0,2377	0,1401
	Ortalama	0,2364	0,0381	0,1918	0,0962

Şekil 4.47'deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinomda yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.

Şekil 4.48'deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı adenokarsinom ve skuamöz hücreli karsinomda yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.




Şekil 4.47. VGG16 Modelinin Artırılmamış Test Verileri Üzerindeki Karmaşıklık Matrisleri



Şekil 4.48. VGG16 Modelinin Artırılmamış Eğitim Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.49 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.



Şekil 4.49. VGG16 Modelinin Artırılmamış Veri Seti Üzerindeki Hata Grafikleri

VGG16 modelinin artırılmış test verileri üzerindeki başarısı Tablo 4.57’de görülmektedir. En düşük başarı parça 1’de, en yüksek başarı parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %90’ın üzerindedir, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.57: VGG16 Modelinin Artırılmış Test Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
VGG16(Test)	1	%88,89	%89,45	%89,22	%89,29	0,849
	2	%93,11	%93,63	%93,58	%93,54	0,906
	3	%90,06	%91,06	%90,09	%90,46	0,864
	4	%92,78	%92,79	%93,21	%92,95	0,902
	5	%89,00	%89,92	%89,62	%89,59	0,850
	Ortalama	%90,77	%91,37	%91,14	%91,17	0,874

VGG16 modelinin artırılmış eğitim verileri üzerindeki başarısı Tablo 4.58’de görülmektedir. En düşük başarı parça 1’de, en yüksek başarı parça 4’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama değerler, kappa hariç %90’ın üzerindedir, akciğer kanseri tanısı için bu oldukça yüksek bir orandır.

Tablo 4.58: VGG16 Modelinin Artırılmış Eğitim Verileri Üzerindeki Başarısı

Algoritma	Parça	Doğruluk Oranı	Kesinlik	Duyarlılık	F1 Puanı	Kappa
VGG16(Eğitim)	1	%90,49	%91,15	%90,92	%91,01	0,870
	2	%94,72	%95,14	%95,04	%95,06	0,928
	3	%93,29	%94,08	%93,27	%93,61	0,908
	4	%95,53	%95,58	%95,98	%95,76	0,939
	5	%92,22	%92,97	%92,52	%92,65	0,894
	Ortalama	%93,25	%93,78	%93,55	%93,62	0,908

VGG16 modelinin artırılmış test verileri üzerindeki hata oranları Tablo 4.59’da görülmektedir. En yüksek hata parça 1’de, en düşük hata parça 2’de elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, ÇE hariç 0.2’nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.59: VGG16 Modelinin Artırılmış Test Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
VGG16(Test)	1	0,3065	0,0413	0,2031	0,0852
	2	0,2129	0,0284	0,1685	0,0582
	3	0,2744	0,0358	0,1891	0,0672
	4	0,2544	0,0299	0,1729	0,0580
	5	0,2744	0,0383	0,1957	0,0769
	Ortalama	0,2645	0,0347	0,1859	0,0691

VGG16 modelinin artırılmış test verileri üzerindeki hata oranları Tablo 4.60’ta görülmektedir. En yüksek hata parça 1’de, en düşük hata parça 4’te elde edildiği görülmektedir. Diğer parçaların da istikrarlı biçimde olduğu görülmektedir ve bu durum ortalamaya da yansımaktadır. Ortalama hatalar, 0.2’nin altındadır, bu oldukça düşük bir orandır.

Tablo 4.60: VGG16 Modelinin Artırılmış Eğitim Verileri Üzerindeki Hata Oranları


Algoritma	Parça	ÇE	OKH	KOKH	OMH
VGG16(Eğitim)	1	0,2560	0,0350	0,1870	0,0774
	2	0,1612	0,0206	0,1434	0,0471
	3	0,1830	0,0236	0,1536	0,0511
	4	0,1531	0,0184	0,1356	0,0433
	5	0,2117	0,0286	0,1691	0,0629
	Ortalama	0,1930	0,0252	0,1577	0,0564

Şekil 4.50’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı büyük hücreli karsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.




Şekil 4.50. VGG16 Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisleri

Şekil 4.51’deki karmaşıklık matrisleri incelendiğinde sınıflandırmada en büyük hatayı büyük hücreli karsinom ve skuamöz hücreli karsinom sınıfında yaptığı görülmektedir. Bütün parçalara bakıldığında kanserli akciğerin tomografi görüntüsü ile sağlıklı akciğerin tomografi görüntüsü nadiren karışmaktadır.



Şekil 4.51. VGG16 Modelinin Artırılmış Test Verileri Üzerindeki Karmaşıklık Matrisi

Şekil 4.52 ile verilen hata grafikleri incelendiğinde her parçada eğitim ve test verilerinde hataların azalma hızı giderek düşmekte, hata yaklaşık olarak sabitlenmektedir ve istenen hata sınırlarında modellerin öğreniminin başarılı olduğu görülmektedir.




Şekil 4.52. VGG16 Modelinin Artırılmış Veri Seti Üzerindeki Hata Grafikleri

VGG16 modeli güçlü bir sınıflandırıcıdır ve Kaggle Chest CT-Scan veri setiyle uyumlu olduğu görülmektedir. Eğitim verilerinde ve test verilerinde yeterli başarı oranına ulaşmaktadır. Bundan dolayı ölçeklenmiş eşlenik gradyan optimizasyonu, bu sınıflandırma işlemi için uygundur.

4.10 Bulguların Karşılaştırılması

Şekil 4.53'te kullanılan yapay zekâ algoritmalarının karşılaştırılması görülmektedir.



Şekil 4.53: Yapay zekâ algoritmalarının karşılaştırılması

Yapay zekâ algoritmaları, F1 puanı ve kappa puanına göre karşılaştırılmıştır. Test verisi parçalarının ortalamaları alınmıştır. Doğruluk oranı dahil edilmemiştir çünkü doğruluk oranının tek başına bir anlamı yoktur. Özellikle biyomedikal görüntü üzerindeki sınıflandırmada tek başına anlam ifade etmemektedir. Şekil 4.18'e bakıldığında en başarısız algoritmanın Naive Bayes olduğu görülmektedir. En başarılı algoritmanın ise evrimsel sinir ağları ve ResNetRS101 modeli olduğu görülmektedir.

5. SONUÇ VE TARTIŞMA

Akciğer kanseri, ölüm riski en yüksek kanser türlerinden biridir. Bu kanser türünde, tümörler küçük hücreli ve küçük hücreli olmayan olmak üzere iki gruba ayrılmaktadır. Küçük hücreli olmayan tümörler ise adenokarsinom, büyük hücreli karsinom ve skuamöz hücreli karsinom alt gruplarına ayrılır.

Günümüzde akciğer kanserinin laboratuvar yöntemleriyle tanısı konulabilmektedir. Ancak bu yöntemler, hem zaman hem de maddi açıdan oldukça maliyetli olduğu için bilgisayar destekli tanı sistemleri büyük önem kazanmaktadır. Bu sistemlerde yapay zeka teknolojilerinin kullanımıyla, tanı konma süreci daha hızlı ve daha az maliyetli hale getirilebilir. Akciğer kanseri tanısı için en iyi yapay zeka yönteminin belirlenmesi oldukça önemlidir. Bu yöntemlerin geliştirilmesi ve kullanımı, akciğer kanseri tanısı ve tedavisinde önemli bir adım olarak değerlendirilmektedir.

Bu tez çalışmasında, Kaggle Chest CT-Scan veri seti kullanılmıştır. Ancak, veri setindeki görüntüler standart bir boyutta değildir. Bu nedenle, görüntüler 80×40 boyutuna indirgenmiştir. Ayrıca, indirgenen görüntüler gri seviyesine dönüştürülmüştür. Daha sonra, dönüştürülen görüntülere 3. seviye dalgacık dönüşümü uygulanmış ve 0-1 normalizasyonu yapılmıştır. Bu ön işlemlerden geçirilmiş veri kümesi, Naive Bayes, k en yakın komşu, destek vektör makinesi, yapay sinir ağları, evrişimsel sinir ağları, VGG16 ve ResNet101 modellerine uygulanmıştır.

Bu çalışmanın sonuçlarına göre, bir makine öğrenmesi modelinin başarısı, birçok farklı metrik kullanılarak değerlendirilebilir. Bu metriklerden ikisi, sınıflandırma görevleri için yaygın olarak kullanılan F1 puanı ve kappa puanıdır.

Bu çalışmada, farklı makine öğrenmesi modellerinin performansları karşılaştırılmış ve en başarısız modelin, Naive Bayes olduğu bulunmuştur. Bu model, %51,28 F1 puanı ve 0,335 kappa puanı elde etmiştir. Naive Bayes'ten sonra en başarısız model ise, momentumlu dereceli azalma algoritması ile optimize edilen yapay sinir ağı modelidir ve %74,22 F1 puanı ve 0,646 kappa puanı elde etmiştir.

En başarılı iki model ise, %98,78 F1 puanı ve 0,983 kappa puanı ile ResNet101 modeli ve evrişimsel sinir ağı modelleridir. Bu sonuçlardan sınıflandırma görevleri için ResNet101 modeli ve evrişimsel sinir ağı modellerinin diğer modellere göre daha iyi başarılı olduğu görülmektedir.

Bu tez çalışmasında literatürdeki çalışmalardan farklı olarak akciğer kanseri verisi hem derin öğrenme hem de makine öğrenmesi yöntemlerinden seçilen birçok farklı mimari modele uygulanmış ve sonuçlar modellerin başarımı açısından karşılaştırılmıştır. Yine bu çalışmada farklı olarak sadece kişinin akciğer kanseri olup olmadığına bakılmamış ayrıca kanser hücresinin cinsi de tespit edilmiştir. Çalışmadaki doğruluk oranı, literatürdeki benzer çalışmalar kadar başarılı olup akciğer kanseri tanısında yapay zeka teknolojilerinin kullanılmasının etkili bir yöntem olduğunu göstermektedir.

Bu çalışmanın ileri safhalarında, yeni bir veri seti oluşturulabilir ve küçük hücreli tümörler de dahil edilebilir. Bu çalışma, derin öğrenme yöntemleri ve hibrit yöntemler gibi diğer makine öğrenmesi yöntemlerini de karşılaştırabilir. Daha fazla araştırma yapılması, bu sistemlerin daha da geliştirilmesine yardımcı olabilir ve akciğer kanseri tanısında doğruluk oranlarını artırabilir.

KAYNAKÇA

- Abdullah, D. M., Abdulazeez, A. M., and Sallow, A. B. (2021). Lung cancer prediction and classification based on correlation selection method using machine learning techniques. *Qubahan Academic Journal*, 1(2), 141-149.
- Abirami, S., and Chitra, P. (2020). "Energy-efficient edge based real-time healthcare support system." In *Advances in computers* (Vol. 117, No. 1, pp. 339-368). Elsevier.
- Abu Alfeilat, H. A., Hassanat, A. B. A., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., Eyal Salman, H. S., and Prasath, V. B. S. (2019). Effects of distance measure choice on k-nearest neighbor Classifier Performance: A Review. *Big Data*, 7(4), 221–248.
- Agarap, A. F. (2018). Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*.
- Agnes, S. A., and Anitha, J. (2021). "Classification of Lung nodules using Convolutional long short-term Neural Network." *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)* (pp. 1349-1353). IEEE.
- Agnes, S. A., and Anitha, J. (2020). "Automatic 2D lung nodule patch classification using deep neural networks." *2020 Fourth International Conference on Inventive Systems and Control (ICISC)* (pp. 500-504). IEEE.
- Alakwaa, W., Nassef, M., and Badr, A. (2017). Lung cancer detection and classification with 3D Convolutional Neural Network (3D-CNN). *International Journal of Advanced Computer Science and Applications*, 8(8).
- Ali, I., Muzammil, M., Haq, I. U., Khaliq, A. A., and Abdullah, S. (2021). Deep Feature Selection and Decision Level Fusion for Lungs Nodule Classification. *IEEE Access*, 9, 18962–18973.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., and Asari, V. K. (2018). The history began from alexnet: A comprehensive survey on deep learning approaches. *arXiv preprint arXiv:1803.01164*.
- ALzubi, J. A., Bharathikannan, B., Tanwar, S., Manikandan, R., Khanna, A., and Thaventhiran, C. (2019). Boosted neural network ensemble classification for lung cancer disease diagnosis. *Applied Soft Computing*, 80, 579–591.
- Al-Huseiny, M.S., and Sajit, A.S. (2021). Transfer learning with GoogLeNet for detection of lung cancer. *Indonesian Journal of Electrical Engineering and Computer Science*, 22, 1078-1086.
- Andrearczyk, V., and Whelan, P. F. (2017). Deep learning in texture analysis and its application to tissue image classification. In *Biomedical texture analysis* (pp. 95-129). Academic Press.
- Armoogum, S., and Li, X. (2019). Big data analytics and deep learning in bioinformatics with hadoop. In *Deep learning and parallel computing environment for bioengineering systems* (pp. 17-36). Academic Press.
- Arul, V. H. (2021). Deep learning methods for data classification. In *Artificial Intelligence in Data Mining* (pp. 87-108). Academic Press.
- Asuntha, A., and Srinivasan, A. (2020). Deep learning for lung Cancer detection and classification. *Multimedia Tools and Applications*, 79(11-12), 7731–7762.
- Babani, L., Jadhav, S., and Chaudhari, B. (2016). "Scaled conjugate gradient based adaptive ANN control for SVM-DTC induction motor drive." In *IFIP International Conference on Artificial Intelligence Applications and Innovations* (pp. 384-395). Springer, Cham.

- Baghirli, O. (2015). Comparison of Lavenberg-Marquardt, scaled conjugate gradient and Bayesian regularization backpropagation algorithms for multistep ahead wind speed forecasting using multilayer perceptron feedforward neural network.
- Bakr, M. H., and Negm, M. H. (2012). Modeling and design of high-frequency structures using artificial neural networks and space mapping. In *Advances in Imaging and Electron Physics* (Vol. 174, pp. 223-260). Elsevier.
- Bebas, E., Borowska, M., Derlatka, M., Oczeretko, E., Hladuński, M., Szumowski, P., and Mojsak, M. (2021). Machine-learning-based classification of the histological subtype of non-small-cell lung cancer using MRI texture analysis. *Biomedical Signal Processing and Control*, 66, 102446.
- Bhargava, D., Vyas, S., and Bansal, A. (2020). Comparative analysis of classification techniques for brain magnetic resonance imaging images. In *Advances in Computational Techniques for Biomedical Image Analysis* (pp. 133-144). Academic Press.
- Bhatia, S., Sinha, Y., and Goel, L. (2019). Lung cancer detection: a deep learning approach. In *Soft Computing for Problem Solving* (pp. 699-705). Springer, Singapore.
- Bıkmaz Bilgen, Ö. ve Doğan, N. (2017). Puanlayıcılar Arası Güvenirlik Belirleme Tekniklerinin Karşılaştırılması. *Journal of Measurement and Evaluation in Education and Psychology*, 8 (1) , 63-78 .
- Cetişli, B., and Barkana, A. (2009). Speeding up the scaled conjugate gradient algorithm and its application in neuro-fuzzy classifier training. *Soft Computing*, 14(4), 365–378.
- Chai, T., and Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), 1247-1250.
- Chaudhry, Q., Chrétien, J., Craciun, M., Guo, G., Lemke, F., Müller, J.-A., Neagu, D., Piclin, N., Pintore, M., and Trundle, P. (2007). Algorithms for (Q)SAR model building. *Quantitative Structure-Activity Relationships (QSAR) for Pesticide Regulatory Purposes*, 111–147.
- Chen, Y., Wang, Y., Hu, F., and Wang, D. (2020). A Lung Dense Deep Convolution Neural Network for Robust Lung Parenchyma Segmentation. *IEEE Access*, 8, 93527–93547.
- Chicco, D., and Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*, 21, 1-13.
- Çavuşlu, M. A. , Becerikli, Y. ve Karakuzu, C. (2016). Levenberg-Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5 (1).
- De Boer, P. T., Kroese, D. P., Mannor, S., and Rubinstein, R. Y. (2005). A tutorial on the cross-entropy method. *Annals of operations research*, 134, 19-67.
- Dukart, J. (2015). Basic concepts of image classification algorithms applied to study neurodegenerative diseases. In *Brain mapping: An encyclopedic reference* (pp. 641-646). Elsevier.
- Edgar, T. W., and Manz, D. O. (2017). Machine learning. *Research Methods for Cyber Security*, 153–173.
- El Bouchefry, K., and de Souza, R. S. (2020). Learning in big data: Introduction to machine learning. In *Knowledge discovery in big data from astronomy and earth observation* (pp. 225-249). Elsevier.

- Elnakib, A., M. Amer, H. and E.Z. Abou-Chadi, F. (2020). Early Lung Cancer Detection using Deep Learning Optimization. *International Association of Online Engineering*.
- Fei, Z., Wu, Z., Xiao, Y., Ma, J., and He, W. (2020). A new short-arc fitting method with high precision using Adam Optimization algorithm. *Optik*, 212, 164788.
- Garg, A., Upadhyaya, S., and Kwiat, K. (2013). "A user behavior monitoring and profiling scheme for masquerade detection." In *Handbook of Statistics* (Vol. 31, pp. 353-379). Elsevier.
- Gholami, R., and Fakhari, N. (2017). Support vector machine: principles, parameters, and applications. In *Handbook of neural computation* (pp. 515-535). Academic Press.
- Graves, A., and Schmidhuber, J. (2005). "Framewise phoneme classification with bidirectional LSTM networks." In *Proceedings. 2005 IEEE International Joint Conference on Neural Networks, 2005.* (Vol. 4, pp. 2047-2052). IEEE.
- Gudivada, V. N., Irfan, M. T., Fathi, E., and Rao, D. L. (2016). "Cognitive analytics: Going beyond big data analytics and machine learning." In *Handbook of statistics* (Vol. 35, pp. 169-205). Elsevier.
- Guo, J. (2013). Backpropagation through time. Unpubl. ms., *Harbin Institute of Technology*, 40, 1-6.
- Gupta, H. V., Kling, H., Yilmaz, K. K., and Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of hydrology*, 377(1-2), 80-91.
- Hany, M. (2020). *Chest CT-scan images dataset*. Kaggle. Erişim: 28 Mart 2023, <https://www.kaggle.com/datasets/mohamedhanyyy/chest-ctscan-images>
- Huang, X., Lei, Q., Xie, T., Zhang, Y., Hu, Z., and Zhou, Q. (2020). Deep Transfer Convolutional Neural Network and Extreme Learning Machine for lung nodule diagnosis on CT images. *Knowledge-Based Systems*, 204, 106230.
- Imran, M., and Alsuhaibani, S. A. (2019). A neuro-fuzzy inference model for diabetic retinopathy classification. In *Intelligent Data Analysis for Biomedical Applications* (pp. 147-172). Academic Press.
- Iwasaki, Y. (2000). Large cell carcinoma. *Nihon rinsho. Japanese journal of clinical medicine*. 58. 1127-31.
- Jain, R., Chotani, A., and Anuradha, G. (2021). Disease diagnosis using machine learning: A comparative study. In *Data Analytics in Biomedical Engineering and Healthcare* (pp. 145-161). Academic Press.
- Jawarkar, J., Solanki, N., Vaishnav, M., Vichare, H., and Degadwala, S. (2021). Multistage lung cancer detection and prediction using deep learning. *Int J Sci Res Sci Eng Technol*, 54-60.
- Jeevana, V., and Charan, B.S. (2021). Lung Cancer Prediction Using Chest X-Rays. *International Journal of Scientific Research in Science and Technology*.
- Kalali, A., Richerson, S., Ouzunova, E., Westphal, R., and Miller, B. (2019). "Digital biomarkers in clinical drug development." In *Handbook of Behavioral Neuroscience* (Vol. 29, pp. 229-238). Elsevier.
- Karaçavuş, S., Kayaaltı, Ö., Yılmaz, B., İçer, S., Kaya, E., ve Ayyıldız, O., (2014). "PET/BT Görüntülerinden Doku Analizi Yöntemiyle Elde Edilen Parametrelerin Küçük Hücreli Dışı Akciğer Kanseri Evrelemesinde Kullanılması. Biyomedikal Görüntü İşleme ve Yapay Zeka Uygulamaları." *Tıp Teknolojileri Ulusal Kongresi. Kapadokya*.

- Khvostikov, A., Aderghal, K., Benois-Pineau, J., Krylov, A., & Catheline, G. (2018). 3D CNN-based classification using sMRI and MD-DTI images for Alzheimer disease studies. *arXiv preprint arXiv:1801.05968*.
- Kim, P. (2017). Convolutional Neural Network. *MATLAB Deep Learning*, 121–147.
- Kingma, D. P., and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kumar, A., Bi, L., Kim, J., and Feng, D. D. (2020). “Machine learning in medical imaging.” In *Biomedical Information Technology* (pp. 167-196). Academic Press.
- Kumar, M., and Rath, S. (2016). Feature selection and classification of microarray data using machine learning techniques. In *Emerging Trends in Applications and Infrastructures for Computational Biology, Bioinformatics, and Systems Biology* (pp. 213-242). Elsevier.
- Kumaraswamy, B. (2021). Neural networks for data classification. In *Artificial Intelligence in Data Mining* (pp. 109-131). Academic Press.
- Lei, Y., Shan, H., and Zhang, J. (2021, June). “Meta ordinal weighting net for improving lung nodule classification.” In *ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1210-1214). IEEE.
- Li, M., Ma, X., Chen, C., Yuan, Y., Zhang, S., Yan, Z. and Ma, M. (2021). Research on the auxiliary classification and diagnosis of lung cancer subtypes based on histopathological images. *IEEE Access*, 9, 53687-53707.
- Li, Z., Li, H., Jiang, X., Chen, B., Zhang, Y., and Du, G. (2018). “Efficient fpga implementation of softmax function for DNN applications.” In *2018 12th IEEE International Conference on Anti-counterfeiting, Security, and Identification (ASID)* (pp. 212-216). IEEE.
- Liu, H. (2020). Rail Transit Channel Robot Systems. *Robot Systems for Rail Transit Applications*, 283–328.
- Liu, X., Hou, F., Qin, H., and Hao, A. (2018). Multi-view multi-scale CNNs for lung nodule type classification from CT images. *Pattern Recognition*, 77, 262–275.
- Lou, W., Wang, X., Chen, F., Chen, Y., Jiang, B., and Zhang, H. (2014). Sequence based prediction of DNA-binding proteins based on hybrid feature selection using random forest and Gaussian Naïve Bayes. *PLoS ONE*, 9(1).
- MacLennan, B. J. (2001). Connectionist approaches. *International Encyclopedia of the Social & Behavioral Sciences*, 2568–2573.
- Madan, B., Panchal, A., and Chavan, D. (2019). “Lung cancer detection using deep learning.” In *2nd International Conference on Advances in Science & Technology (ICAST)*.
- Malhotra, A., Sankaran, A., Mittal, A., Vatsa, M., and Singh, R. (2017). Fingerphoto authentication using smartphone camera captured under varying environmental conditions. In *Human recognition in unconstrained environments* (pp. 119-144). Academic Press.
- Marom, N. D., Rokach, L., and Shmilovici, A. (2010, November). “Using the confusion matrix for improving ensemble classifiers.” In *2010 IEEE 26-th Convention of Electrical and Electronics Engineers in Israel* (pp. 000555-000559). IEEE.
- Mao, Q., Chen, Y., Duan, P., Zhang, B., Hong, Z., and Wang, B. (2022). Privacy-preserving classification scheme based on support vector machine. *IEEE Systems Journal*, 1–11.

- Meyer-Baese, A., Schmid, V., and Schmid, V. B. T. P. R. (2014). Foundations of neural networks. *Pattern Recognition and Signal Analysis in Medical Imaging; Elsevier: Amsterdam, The Netherlands*.
- Moitra, D., and Kr. Mandal, R. (2020). Classification of non-small cell lung cancer using one-dimensional convolutional neural network. *Expert Systems with Applications*, 159, 113564.
- Na, J., Zhou, W., Yin, M., Hu, Y., and Ma, X. (2022). GNA13 promotes the proliferation and migration of lung squamous cell carcinoma cells through regulating the PI3K/akt signaling pathway. *Tissue and Cell*, 76, 101795.
- Nanglia, P., Kumar, S., Mahajan, A. N., Singh, P., and Rathee, D. (2021). A hybrid algorithm for lung cancer classification using SVM and Neural Networks. *ICT Express*, 7(3), 335–341.
- Narayanan, B. N., Hardie, R. C., and Kebede, T. M. (2018). “Performance Analysis of Feature Selection Techniques for Support Vector Machine and its Application for Lung Nodule Detection.” *NAECON 2018- IEEE National Aerospace and Electronics Conference*.
- Nasrullah, N., Sang, J., Alam, M. S., Mateen, M., Cai, B., and Hu, H. (2019). Automated Lung nodule detection and classification using Deep Learning combined with multiple strategies. *Sensors*, 19(17), 3722.
- Nasser, I. M., and Abu-Naser, S. S. (2019). Lung cancer detection using artificial neural network. *International Journal of Engineering and Information Systems (IJEAIS)*, 3(3), 17-23.
- Neath, R. C., and Johnson, M. S. (2010). Discrimination and classification. *International Encyclopedia of Education*, 135–141.
- Numan, N., Abuelenin, S., and Rashad, M. (2016). Prediction of Lung Cancer Using Artificial Neural Network. *International Journal of Intelligent Computing and Information Sciences*, 16(2), 1-19.
- Ren, G., Cao, Y., Wen, S., Huang, T., and Zeng, Z. (2018). A modified Elman Neural Network with a new learning rate scheme. *Neurocomputing*, 286, 11–18.
- Öner, İ. V. , Yeşilyurt, M. K. ve Yılmaz, E. Ç. (2017). Wavelet Analiz Tekniği ve Uygulama Alanları. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 7 (1) , 42-56.
- Pantazi, X. E., Moshou, D., and Bochtis, D. (2020). Artificial intelligence in agriculture. *Intelligent Data Mining and Fusion Systems in Agriculture*, 17–101.
- Patra, R. (2020). “Prediction of lung cancer using machine learning classifier.” In *International Conference on Computing Science, Communication and Security* (pp. 132-142). Springer, Singapore.
- Peng, W., Chen, J., He, R., Tang, Y., Jiang, J., and Li, Y. (2022). ID2 inhibits lung adenocarcinoma cell malignant behaviors by inhibiting the activation of the PI3K/AKT/mTOR signaling pathway. *Tissue and Cell*, 79, 101950.
- Radhika, P. R., Nair, R. A., and Veena, G. (2019). “A comparative study of lung cancer detection using machine learning algorithms.” In *2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)* (pp. 1-4). IEEE.
- Rao, P., Pereira, N. A., and Srinivasan, R. (2016). “Convolutional neural networks for lung cancer screening in computed tomography (CT) scans.” In *2016 2nd international conference on contemporary computing and informatics (IC3I)* (pp. 489-493). IEEE.
- Rehman, A., Kashif, M., Abunadi, I., and Ayesha, N. (2021). “Lung cancer detection and classification from chest CT scans using machine learning techniques.” In *2021 1st*

- International Conference on Artificial Intelligence and Data Analytics (CAIDA)* (pp. 101-104). IEEE.
- Ren, J., Green, M., and Huang, X. (2021). From traditional to deep learning: Fault diagnosis for autonomous vehicles. In *Learning Control* (pp. 205-219). Elsevier.
- Roshan, S., Srivathsan, G., Deepak, K., and Chandrakala, S. (2020). Violence detection in automated video surveillance: Recent trends and comparative studies. *The Cognitive Approach in Cloud Computing and Internet of Things Technologies for Surveillance Tracking Systems*, 157–171.
- Sairamya, N. J., Susmitha, L., George, S. T., and Subathra, M. S. P. (2019). Hybrid approach for classification of electroencephalographic signals using time–frequency images with wavelets and texture features. In *Intelligent Data Analysis for Biomedical Applications* (pp. 253-273). Academic Press.
- Saleh, A. Y., Chin, C. K., Penshie, V., and Al-Absi, H. R. H. (2021). Lung cancer medical images classification using hybrid CNN-SVM. *International Journal of Advances in Intelligent Informatics*, 7(2), 151-162.
- Sangamithraa, P. B., and Govindaraju, S. (2016). “Lung tumour detection and classification using EK-Mean clustering.” In *2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)* (pp. 2201-2206). IEEE.
- Santosh, K. C., Das, N., and Ghosh, S. (2022). Deep learning: A Review. *Deep Learning Models for Medical Imaging*, 29–63.
- Schmidt, F., Kohlbrenner, D., Malesevic, S., Huang, A., Klein, S. D., Puhan, M. A., and Kohler, M. (2023). Mapping the landscape of Lung Cancer Breath Analysis: A scoping review (ELCABA). *Lung Cancer*, 175, 131–140.
- Sengupta, A., Naresh, G., Mishra, A., Parashar, D., and Narad, P. (2021). Proteome analysis using machine learning approaches and its applications to diseases. *Advances in Protein Chemistry and Structural Biology*, 127, 161-216.
- Serj, M. F., Lavi, B., Hoff, G., and Valls, D. P. (2018). A deep convolutional neural network for lung cancer diagnostic. *arXiv preprint arXiv:1804.08170*.
- Singh, G. A. P., and Gupta, P. K. (2019). Performance analysis of various machine learning-based approaches for detection and classification of lung cancer in humans. *Neural Computing and Applications*, 31(10), 6863-6877.
- Shakeel, P. M., Burhanuddin, M. A., and Desa, M. I. (2019). Lung cancer detection from CT image using improved profuse clustering and deep learning instantaneously trained neural networks. *Measurement*, 145, 702-712.
- 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.
- Shen, W., Zhou, M., Yang, F., Yang, C., and Tian, J. (2015, June). “Multi-scale convolutional neural networks for lung nodule classification.” In *International conference on information processing in medical imaging* (pp. 588-599). Springer, Cham.
- Shobha, G., and Rangaswamy, S. (2018). Machine learning. *Handbook of Statistics*, 197–228.
- Song, Q. Z., Zhao, L., Luo, X. K., and Dou, X. C. (2017). Using deep learning for classification of lung nodules on computed tomography images. *Journal of Healthcare Engineering*, 2017, 1–7.

- Sokolova, M., and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.
- Story, M., and Congalton, R. G. (1986). Accuracy assessment: a user's perspective. *Photogrammetric Engineering and remote sensing*, 52(3), 397-399.
- Subasi, A. (2020). Machine learning techniques. *Practical Machine Learning for Data Analysis Using Python*, 91–202.
- Subramanian, R. Raja, Mourya, Ravella, Prudhvi, V, Reddy, Teja, Reddy, B and Amara, Srikar. (2020). Lung Cancer Prediction Using Deep Learning Framework. *International Journal of Control and Automation*. 13(3). 154-160.
- Suk, H. I. (2017). An introduction to neural networks and deep learning. In *Deep Learning for Medical Image Analysis* (pp. 3-24). Academic Press.
- Sun, W., Zheng, B., and Qian, W. (2016). "Computer aided lung cancer diagnosis with deep learning algorithms." In *Medical imaging 2016: computer-aided diagnosis* (Vol. 9785, pp. 241-248). SPIE.
- Surendar, P. (2021). Diagnosis of lung cancer using hybrid deep neural network with adaptive sine cosine crow search algorithm. *Journal of Computational Science*, 53, 101374.
- Talabis, M. R. M., McPherson, R., Miyamoto, I., Martin, J. L., and Kaye, D. (2015). Analytics Defined. *Information Security Analytics*, 1–12.
- Tekade, R., & Rajeswari, K. (2018). "Lung cancer detection and classification using deep learning." In *2018 fourth international conference on computing communication control and automation (ICCUBEA)* (pp. 1-5). IEEE.
- Temurtaş, F. , Öztekin, M. , Yazdani, M. , Yörük, Y. E. , Aydemir, F. , Yonar, D. , Taşaltın, C. , Gürol, İ. , Ebeoğlu, M. A. , Salih, B. , Köksal, D. ve Emri, K. A. S. (2019). AKCİĞER KANSERİ TANISI İÇİN YENİ BİR YÖNTEM . *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 1 (1) , 35-48 .
- Tharsanee, R. M., Soundariya, R. S., Kumar, A. S., Karthiga, M., and Sountharajan, S. (2021). Deep convolutional neural network–based image classification for COVID-19 diagnosis. In *Data Science for COVID-19* (pp. 117-145). Academic Press.
- THONG, L. T., CHOU, H. S., CHEW, H. S., and LAU, Y. (2023). Diagnostic test accuracy of artificial intelligence-based imaging for lung cancer screening: A systematic review and meta-analysis. *Lung Cancer*, 176, 4–13.
- Tiwari, L., Raja, R., Awasthi, V., Miri, R., Sinha, G. R., Alkinani, M. H., and Polat, K. (2021). Detection of lung nodule and cancer using novel Mask-3 FCM and TWEDLNN algorithms. *Measurement*, 172, 108882.
- Tra, V., Kim, J., Khan, S. A., & Kim, J. M. (2017). Bearing fault diagnosis under variable speed using convolutional neural networks and the stochastic diagonal levenberg-marquardt algorithm. *Sensors*, 17(12), 2834.
- Toğaçar, M., Ergen, B., and Cömert, Z. (2020). Detection of lung cancer on chest CT images using minimum redundancy maximum relevance feature selection method with convolutional neural networks. *Biocybernetics and Biomedical Engineering*, 40(1), 23–39.
- Tuena, C., Chiappini, M., Repetto, C., and Riva, G. (2022). Artificial Intelligence in clinical psychology. *Comprehensive Clinical Psychology*, 10–27.
- Vas, M., and Dessai, A. (2017). "Lung cancer detection system using lung CT image processing." In *2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA)* (pp. 1-5). IEEE.

- Wang, L., Zhang, Z., Zhang, X., Zhou, X., Wang, P., and Zheng, Y. (2021). "A Deep-forest based approach for detecting fraudulent online transaction." In *Advances in Computers* (Vol. 120, pp. 1-38). Elsevier.
- Wang, Z., Fu, Y., and Huang, T. S. (2019). *Deep Learning Through Sparse and Low-Rank Modeling*. Academic Press.
- Wilson, P., & Mantooth, H. A. (2013). Model-based optimization techniques. *Model-based engineering for complex electronic systems, 2013*, 347-367.
- Winters-Miner, L. A., Bolding, P., Hill, T., Nisbet, B., Goldstein, M., Hilbe, J. M., Walton, N., Miner, G., Rastunkov, V., and Stout, D. (2015). Prediction in medicine – the data mining algorithms of Predictive Analytics. *Practical Predictive Analytics and Decisioning Systems for Medicine*, 239–259.
- Wistuba, I. I., and Gazdar, A. F. (2006). *LUNG CANCER PRENEOPLASIA. Annual Review of Pathology: Mechanisms of Disease*, 1(1), 331–348.
- Wu, C.-F., Wu, C.-Y., Lin, C.-F., Liu, Y.-W., Lin, T.-C., Liao, H.-J., and Chang, G.-R. (2022). The anticancer effects of cyanidin 3-O-glucoside combined with 5-fluorouracil on lung large-cell carcinoma in nude mice. *Biomedicine & Pharmacotherapy*, 151, 113128.
- Yektaei, H., and Manthouri, M. (2020). Diagnosis of Lung Cancer using Multiscale Convolutional Neural Network. *Biomedical Engineering: Applications, Basis and Communications*, 32(05), 2050030.
- Zhang, D. (2019). Wavelet Transform. *Lecture Notes in Physics*, 35–44.
- Zhang, H., Shan, G., Jin, X., Yu, X., Bi, G. S., Feng, M., Wang, H., Lin, M., Zhan, C., Wang, Q., and Li, M. (2022). ARNTL2 is an indicator of poor prognosis, promotes epithelial-to-mesenchymal transition and inhibits ferroptosis in lung adenocarcinoma. *Translational Oncology*, 26, 101562.
- Zhang, Q., Wang, H., Yoon, S. W., Won, D., and Srihari, K. (2019). Lung Nodule Diagnosis on 3D Computed Tomography Images Using Deep Convolutional Neural Networks. *Procedia Manufacturing*, 39, 363–370.
- Zhang, Y., Ding, Y., Qiu, B., Zhang, Y., and Li, X. (2017). Signum-function array activated ZNN with easier circuit implementation and finite-time convergence for linear systems solving. *Information Processing Letters*, 124, 30–34.
- Zoppis, I., Mauri, G., and Dondi, R. (2019). Kernel methods: Support Vector Machines. *Encyclopedia of Bioinformatics and Computational Biology*, 503–510.
- Zupan, J. (1994). Introduction to artificial neural network (ANN) methods: what they are and how to use them. *Acta Chimica Slovenica*, 41, 327-327.

ÖZ GEÇMİŞ

Sarp ÇOBAN, Samsun Anadolu Lisesi’ni bitirdikten sonra Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünden 28.01.2019 tarihinde mezun oldu. 2019 yılında Samsun Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalı Tezli Bilgisayar Mühendisliği programına başladı. 2022 yılından bu yana Samsun Üniversitesi Mühendislik Fakültesi Yazılım Mühendisliği bölümünde Araştırma Görevlisi olarak çalışmaktadır.

İletişim Bilgileri

ORCID ID : 0000-0002-1078-3227

Yayınlar:

1. Çoban, S., ve Kayhan, G. (2021). Akciğer Kanseri Tehşisinde Yapay Zeka Algoritmalarının Karşılaştırılması. *6. Uluslararası Akademik Araştırmalar Kongresi* (s. 92-101). Asos Yayınevi.