KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

BEYİN TÜMÖR TİPLERİNİN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME TABANLI TEKNİKLER İLE SINIFLANDIRILMASI

KAPLAN KAPLAN

KOCAELİ 2020

KOCAELİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

DOKTORA TEZİ

BEYİN TÜMÖR TİPLERİNİN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME TABANLI TEKNİKLER İLE SINIFLANDIRILMASI

KAPLAN KAPLAN

Prof.Dr. Metin ERTUNÇ		
Danışman,	**Kocaeli Üniversitesi**	**.....**
Prof.Dr. Hasan OCAK		
Jüri Üyesi,	**Kocaeli Üniversitesi**	**.....**
Prof.Dr. Serdar KÜÇÜK		
Jüri Üyesi,	**Kocaeli Üniversitesi**	**.....**
Doç.Dr. Yılmaz KAYA		
Jüri Üyesi,	**Siirt Üniversitesi**	**.....**
Doç.Dr. Sezgin KAÇAR		
Jüri Üyesi,	**Sakarya Uygulamalı Bilimler Üniv.**	**.....**

Tezin Savunulduğu Tarih: 09.12.2020

ÖNSÖZ VE TEŞEKKÜR

Beyin tümörleri ölüm oranı en yüksek hastalıklardan bir tanesidir. Bu tez çalışması kapsamında beyin tümör tiplerinden olan glioma ve literatürde çok az çalışılan metastatik beyin tümörlerinin (akciğer metastazı, göğüs metastazı) sınıflandırılması gerçekleştirilmiştir. Çalışma kapsamında kullanılan verilerden metastatik beyin tümörleri Kocaeli Üniversitesi Tıp Fakültesi PACS sisteminden, glioma tip beyin tümör verisi ise Nanfang Hastanesi ve Tianjin Tıp Üniversitesi Genel Hastanesi'nin oluşturduğu online veri setinden alınmıştır. Geliştirilen Yerel İkili Örüntüler tabanlı makine öğrenmesi ve transfer öğrenmesi modelleri ile üç tip tümör çeşidi görüntülerinin sınıflandırma başarıları incelenmiştir.

Bu tezin gerçekleştirilmesinde beni yönlendiren, ilgisini hiç eksik etmeyen danışman hocam Prof. Dr. H. Metin Ertunç'a ve desteklerinden dolayı Dr. Öğr. Üyesi Melih Kuncan'a çok teşekkür ederim. Ayrıca radyolojik verilerin toplanıp hazırlanması aşamasında yardımcı olan Dr. Öğr. Üyesi Burcu Alparslan'a ve Yasin Cuşkun'a teşekkürü bir borç bilirim.

Ayrıca hayatım boyunca desteklerini esirgemeyen ve beni bugünlere getiren aileme sonsuz teşekkürlerimi sunarım.

Aralık – 2020 Kaplan KAPLAN

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR i
İÇİNDEKİLER ii
ŞEKİLLER DİZİNİ iv
TABLOLAR DİZİNİ vi
SİMGELER VE KISALTMALAR DİZİNİ vii
ÖZET viii
GİRİŞ 1
1. GENEL BİLGİLER 3
2. BEYİN TÜMÖRLERİ VE TIBBİ GÖRÜNTÜLEME TEKNİKLERİ 13
2.1. Beyin Anatomik Yapısı 13
2.2. Beyin Tümörleri 14
2.2.1. Birincil (primer) beyin tümörleri 16
2.2.2. Metastatik (sekonder) beyin tümörleri 16
2.3.1. Manyetik rezonans görüntüleme 19
2.3.2. Manyetik rezonans görüntüleme tarihçesi 21
2.3.3. Manyetik rezonans görüntüleme temel prensipleri 22
2.3.4. Manyetik rezonans görüntülerinde kullanılan sekanslar 23
2.3.4.1. T1-ağırlıklı sekans 24
2.3.4.2. T2-ağırlıklı sekans 24
2.3.4.3. T2*-ağırlıklı sekans 25
2.3.4.4. Proton ağırlıklı sekans 25
2.3.4.5. Difüzyon MRG 25
2.3.4.6. T1rho sekans 26
2.3.4.7. FLAIR sekans 26
2.3.4.8. Fonksiyonel MRG 26
2.3.4.9. Manyetik rezonans perfüzyon 27
3. TEORİK BİLGİLER 28
3.1. Veri Seti 28
3.2. İmge Pekiştirme (Gama Düzeltmesi) 29
3.3. Yerel İkili Örüntüler 29
3.3.1. Komşuluklarına göre yerel ikili örüntüler 30
3.3.2. Açılara dayalı yerel ikili örüntüler 33
3.4. Makine Öğrenmesi Yöntemleri 35
3.4.1. k-en yakın komşuluk 36
3.4.2. Rastgele orman 38
3.4.3. Destek vektör makineleri 41
3.4.4. Lojistik regresyon 44
3.4.5. Yapay sinir ağları 48
3.5. Derin Öğrenme 56
3.5.1. Evrişimli sinir ağları 57
3.5.2. Aktivasyon fonksiyonları 61
3.5.2.1. Sigmoid fonksiyonu 61

3.5.2.2. Hiperbolik tanjant fonksiyonu 62
3.5.2.3. Relu fonksiyonu 62
3.5.2.4. Sızıntı relu fonksiyonu 63
3.5.2.5. Softmax aktivasyon fonksiyonu 63
3.5.3. Optimizasyon yöntemleri 64
3.5.3.1. Stokastik gradyan inişi 64
3.5.3.2. RMSProp optimizasyon fonksiyonu 65
3.5.3.3. Uyarlanabilir moment tahmini 66
3.5.4. Transfer öğrenme 66
3.5.4.1. Alexnet modeli 68
3.5.4.2. VGG19 modeli 69
3.5.4.3. Resnet101 modeli 69
3.6. Model Performans Kriterleri 71
3.7. k-Katlı Çapraz Geçerlilik Testi 73
4. ÖNERİLEN BEYİN TÜMÖR SINIFLANDIRMA MODELLERİ 74
4.1. Önerilen YİÖ Modeli 77
4.2. Önerilen Transfer Öğrenmesi Modelleri 78
5. DENEYSEL SONUÇLAR 80
5.1. αYİÖ Yöntemine Ait Sonuçlar 80
5.2. dYİÖ Yöntemine Ait Sonuçlar 83
5.3. Klasik YİÖ Sonuçları 86
5.4. Tekdüze (Uniform) Örüntüler için Sonuçlar 88
5.5. Alexnet Modeli ile Elde Edilen Sonuçlar 89
5.6. VGG19 Modeli ile Elde Edilen Sonuçlar 92
5.7. Resnet101 Modeli ile Elde Edilen Sonuçlar 96
5.8. Karşılaştırmalı Sonuçlar 99
6. SONUÇLAR VE ÖNERİLER 104
KAYNAKLAR 107
EKLER 117
KİŞİSEL YAYIN VE ESERLER 120
ÖZGEÇMİŞ 125

ŞEKİLLER DİZİNİ

Şekil 2.1. Beyin genel anatomik yapısı 13
Şekil 2.2. AANS tarafından beyin tümörünün sınıflandırılması 15
Şekil 2.3. Açık MRG cihazı 19
Şekil 2.4. Kapalı MRG cihazı 20
Şekil 2.5. Sırasıyla çekilmiş aksiyel, sagittal ve koronal görüntüler 20
Şekil 2.6. İlk MR makinesi 22
Şekil 2.7. İlk MR görüntüsü 22
Şekil 2.8. K uzayından görüntü elde edilmesi 23
Şekil 2.9. MRG'de TE ve TR sinyallerinin değişimi 24
Şekil 2.10. (a) T1-ağırlıklı, (b) T2-ağırlıklı, (c) T2*-ağırlıklı, (d) Proton ağırlıklı, (e) Difüzyon MRG (f) FLAIR, (g) Fonksiyonel MRG (h) Perfüzyon MRG 27
Şekil 3.1. (a) Glioma, (b) akciğer, (c) meme metastazı tümör görüntüleri 28
Şekil 3.2. YİÖ etiketlerinin oluşturulması 30
Şekil 3.3. Komşuluklarına göre dYİÖ elde edilmesine bir örnek 31
Şekil 3.4. Açı tabanlı YİÖ 34
Şekil 3.5. Makine öğrenmesi uygulama şeması 36
Şekil 3.6. k-NN sınıflandırma algoritması 38
Şekil 3.7. X veri seti için örnek bir RO yapısı 40
Şekil 3.8. Optimum hiperdüzlem ve destek vektörleri 42
Şekil 3.9. Lojistik regresyon modeli 47
Şekil 3.10. Biyolojik sinir hücresinin genel yapısı 50
Şekil 3.11. YSA katmanları 50
Şekil 3.12. Bazı transfer fonksiyonları 52
Şekil 3.13. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki 56
Şekil 3.14. CNN model örneği 57
Şekil 3.15. Evrişim (convolution, konvolüsyon) işlemi 58
Şekil 3.16. Piksel doldurma (padding) işlemi 59
Şekil 3.17. Adım kaydırma işlemi 59
Şekil 3.18. Ortaklama işlemi 60
Şekil 3.19. Çeşitli aktivasyon fonksiyonları 63
Şekil 3.20. Evrişimli sinir ağları ve transfer öğrenme 67
Şekil 3.21. Imagenet sınıflandırma doğrulukları 68
Şekil 3.22. Alexnet mimarisi 70
Şekil 3.23. VGG19 mimarisi 70
Şekil 3.24. Resnet101 mimarisi 70
Şekil 3.25. 5 katlı çapraz geçerlilik testi 73
Şekil 4.1. Glioma görüntüleri için örnek gama düzeltmesi uygulaması 76
Şekil 4.2. Akciğer metastazı görüntüsü gama düzeltmesi uygulaması 77
Şekil 4.3. Önerilen YİÖ sınıflandırma sistemi 77
Şekil 4.4. Transfer öğrenmesi sınıflandırma şeması 79
Şekil 5.1. αYİÖ yönteminin farklı α değerlerine göre oluşturduğu görüntüler 81

Şekil 5.2. αYİÖ yönteminde farklı α değerleri ile oluşan histogramlar 82
Şekil 5.3. dYİÖ yönteminin farklı d değerlerine göre oluşturduğu görüntüler 84
Şekil 5.4. dYİÖ yönteminde farklı d ile oluşan histogramlar 85
Şekil 5.5. Orjinal ve YİÖ görüntüleri 86
Şekil 5.6. YİÖ görüntülerine ait histogramlar 87
Şekil 5.7. Alexnet modeli eğitim süreci 89
Şekil 5.8. Alexnet eğitim doğruluk ve hata grafiği 90
Şekil 5.9. Alexnet için ROC eğrileri 91
Şekil 5.10. Örnek sınıflandırma sonuçları 92
Şekil 5.11. VGG19 modeli eğitim süreci 93
Şekil 5.12. VGG19 eğitim doğruluk ve hata grafiği 93
Şekil 5.13. VGG19 için ROC eğrileri 95
Şekil 5.14. Örnek sınıflandırma sonuçları 95
Şekil 5.15. Resnet101 modeli eğitim süreci 96
Şekil 5.16. Resnet101 eğitim doğruluğu ve hatası 97
Şekil 5.17. Resnet101 için ROC eğrileri 98
Şekil 5.18. Örnek sınıflandırma sonuçları 99

TABLOLAR DİZİNİ

Tablo 2.1. Beyin bölümleri ve işlevleri 14
Tablo 2.2. Tıbbi görüntüleme yöntemleri 18
Tablo 3.1. Karışıklık matrisi 71
Tablo 4.1. Metastatik tip görüntülerin grupları ve hasta sayıları 75
Tablo 4.2. Örnek bazı hastalar için MR görüntü sayısı ve boyutu 76
Tablo 4.3. Sınıflandırma için kullanılacak hasta grupları ve özellikleri 76
Tablo 5.1. αYİÖ öznitelikler ile elde edilen başarı sonuçları (%) 81
Tablo 5.2. DVM ve $\alpha YİÖ_{\alpha=45}$ ile elde edilen karışıklık matrisi 83
Tablo 5.3. DVM ve $\alpha YİÖ_{\alpha=45}$ için performans ölçütleri 83
Tablo 5.4. dYİÖ öznitelikler ile elde edilen başarı sonuçları(%) 84
Tablo 5.5. YSA ve $dYİÖ_{d=1}$ ile elde edilen karışıklık matrisi 86
Tablo 5.6. YSA ve $dYİÖ_{d=1}$ ile elde edilen performans ölçütleri 86
Tablo 5.7. YİÖ öznitelikler ile elde edilen başarı oranları (%) 87
Tablo 5.8. DVM ile YİÖ için elde edilen karışıklık matrisi 87
Tablo 5.9. YİÖ öznitelikler ile gözlenen performans ölçütleri 88
Tablo 5.10. Tekdüze örüntülere ait başarı oranları 88
Tablo 5.11. Denemeler sonucu elde edilen doğruluk ortalaması 90
Tablo 5.12. Alexnet mimarisi ile elde edilen karışıklık matrisi 90
Tablo 5.13. Alexnet için performans ölçütleri 91
Tablo 5.14. Denemeler sonucu elde edilen doğruluk ortalaması 94
Tablo 5.15. VGG19 mimarisi ile elde edilen karışıklık matrisi 94
Tablo 5.16. VGG19 için performans ölçütleri 94
Tablo 5.17. Denemeler sonucu elde edilen doğruluk ortalaması 97
Tablo 5.18. Resnet101 mimarisi ile elde edilen karışıklık matrisi 97
Tablo 5.19. Resnet101 için performans ölçütleri 98
Tablo 5.20. Karşılaştırmalı model doğrulukları 99
Tablo 5.21. Karşılaştırmalı literatür sonuçları 100

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

ANN	:	Artificial Neural Network (Yapay Sinir Ağları)
AUC	:	Area Under The Curve (Eğrinin Altındaki Alan)
BRATS	:	Brain Tumor Segmantation (Beyin Tümörü Segmentasyonu)
BT	:	Bilgisayarlı Tomografi
CNN	:	Convolutional Neural Network (Evrişimli Sinir Ağları)
CT	:	Computed Tomography (Bilgisayarlı Tomografi)
DICOM	:	Digital Imaging and Communications in Medicine (Tıpta Dijital Görüntüleme ve İletişim)
DVM	:	Destek Vektör Makineleri
DTG	:	Difüzyon Tensör Görüntüleme
DWT	:	Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
GLCM	:	Gray Level Co-Occurance Matrix (Gri Seviye Eş Oluşum Matrisi)
HOG	:	Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı)
k-NN	:	k-Nearest Neighbor (k en yakın komşuluk)
LBP	:	Local Binary Pattens (Yerel İkili Örüntüler)
LDA	:	Linear Discriminant Analysis (Doğrusal Ayrımcılık Analizi)
LR	:	Logistic Regression (Lojistik Regresyon)
MR	:	Manyetik Rezonans
MR-A	:	Manyetik Rezonans Anjiyografi
MRG	:	Manyetik Rezonans Görüntüleme
NB	:	Naive Bayes (Naif Bayes)
P	:	Precision (Hassasiyet)
PACS	:	Picture Archiving and Communication System (Görüntü Saklama ve İletişim Sistemi)
PCA	:	Principal Component Analysis (Temel Bileşen Analizi)
PET	:	Pozitron Emisyon Tomografi
R	:	Recall (Kesinlik)
Relu	:	Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
RF	:	Random Forest (Rastgele Orman)
RF	:	Radio Frequency (Radyo Frekansı)
ROC	:	Reciever Operator Characteristics Curve (İşlem Karakteristik Eğrisi)
SVM	:	Support Vector Machines (Destek Vektör Makineleri)
T	:	Tesla
TE	:	Time of Echo (Yankı Zamanı)
TR	:	Time of Repetition (Tekrarlama Zamanı)
YİÖ	:	Yerel İkili Örüntüler
YSA	:	Yapay Sinir Ağları

BEYİN TÜMÖR TİPLERİNİN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME TABANLI TEKNİKLER İLE SINIFLANDIRILMASI

ÖZET

Beyin tümör tipi sınıflandırması, iyileşme sürecinin hızlanması ve tedavi planlanması açısından oldukça önemlidir. Diğer taraftan radyologların tecrübesi ve dikkati, beyin tümörlerinin manuel teşhisinde önemli rol oynamaktadır. Uzmanlara yardımcı olmak ve teşhislerin doğruluğunu arttırmak için birçok beyin tümör sınıflandırma modelleri geliştirilmiştir. Bu tez çalışması kapsamında glioma, akciğer metastazı ve meme metastazı sınıflandırılması gerçekleştirilmiştir. Literatürde gliomalar ile ilgili çok sayıda çalışma bulunurken, akciğer ve meme metastazı ile ilgili çalışma yok denecek kadar azdır. Sınıflandırma işlemi için, ilk olarak, Yerel İkili Örüntüler (YİÖ), komşuluklarına göre YİÖ (dYİÖ) ve açılara dayalı YİÖ (αYİÖ) tabanlı öznitelik çıkarma yöntemleri geliştirilmiştir. YİÖ tabanlı öznitelik çıkarım yöntemlerinde farklı mesafe (d) değerleri (1, 2, 3 ve 4) ve farklı açı (α) değerleri (0, 45, 90 ve 135) ise farklı örüntüler elde etmek için seçilmiştir. dYİÖ, αYİÖ ve YİÖ yöntemleri ile elde edilen öznitelikler, Destek Vektör Makineleri (DVM), k-en yakın komşuluk (k-NN), Lojistik Regresyon (LR), Yapay Sinir Ağları (YSA), Rastgele Orman (RO) modelleri kullanılarak sınıflandırılmıştır. Öte yandan, sınıflandırma için önceden eğitilmiş Alexnet, VGG19 ve Resnet101 derin öğrenme modelleri kullanılmıştır. Önerilen yöntemleri test etmek için metastatik tümörler Kocaeli Üniversitesi Radyoloji Bölümü'nden, gliomalar ise Nanfang ve Tianjin Hastanesi'nin oluşturduğu online veri setinden elde edilmiştir. Makine öğrenmesi teknikleri arasında en yüksek başarı %93,54 olarak $dYİÖ_{d=1}$ örüntüleri ve YSA modeli ile elde edilirken, derin öğrenme modelleri arasında en yüksek başarı %94,66 olarak VGG19 ve Resnet101 modelleri ile sağlanmıştır.

Anahtar Kelimeler: Beyin Tümörleri, Derin Öğrenme, Makine Öğrenmesi, Sınıflandırma, Yerel İkili Örüntüler.

THE CLASSIFICATION OF BRAIN TUMOR TYPES USING MACHINE LEARNING AND DEEP LEARNING BASED TECHNIQUES

ABSTRACT

Classification of brain tumor types is very important in terms of accelerating the healing process and planning treatment. The experience and attention of the radiologists plays crucial role in diagnosing the brain tumor manually. Many brain tumor classification models have been developed to assist experts and increase the accuracy of diagnoses. Within the scope of this thesis study, the classification of glioma, lung metastasis and breast metastasis were carried out. While there are many studies about gliomas, there are almost no studies on lung and breast metastasis in the literature. For the classification process, firstly, feature extraction methods, such as Local Binary Patterns (LBP), LBP based on neighborhoods (dLBP), LBP based on angles (αLBP) were developed. Different distance (d) values (1, 2, 3, and 4) and different angle (α) values (0, 45, 90, and 135) were selected to obtain several patterns in the LBP based feature extraction methods. The features obtained by dLBP, αLBP and LBP methods were classified using Support Vector Machines (SVM), k-nearest neighborhood (k-NN), Logistic Regression (LR), Artificial Neural Networks (ANN), Random Forest (RF) models. Secondly, pre-trained Alexnet, VGG19 and Resnet101 deep learning models were used for classification. To test the proposed methods, metastatic tumors were obtained from Kocaeli University Radiology Department, and gliomas were obtained from the online dataset of Nanfang and Tianjin Hospital. While $dY\dot{I}\ddot{O}_{d=1}$ patterns and ANN model performed the highest success rate as 93.54% among machine learning techniques, VGG19 and Resnet101 models yielded the highest success rate as 94.66% within deep learning models.

Keywords: Brain Tumors, Deep Learning, Machine Learning, Classification, Local Binary Patterns.

GİRİŞ

Beyin tümörleri beyindeki hücrelerin anormal ve kontrolsüz bir şekilde çoğalmasından kaynaklanan dokulardan oluşmaktadır. Tümörler beyin içerisinde büyüyerek anormal nörolojik semptomlara neden olur. Beyin tümörleri, birincil (primer) ve ikincil (sekonder) metastatik tip beyin tümörleri olmak üzere ikiye ayrılmaktadır. Birincil tümörler beyin hücrelerinde oluşurken, metastatik tümörler vücudun başka bir organında oluşan tümörün beyne sıçraması ile oluşmaktadır. Beyin tümörlerinin erken tanısı tedavi olanaklarını artırmakta ve hastaların tedavi sürecini hızlandırmaktadır. Beyin tümörlerinin teşhisinde insan dokularının anatomisi hakkında zengin bilgi sağladığı ve yaygın olarak bulunabildiği için Manyetik Rezonans Görüntüleme (MRG) standart bir teknik olarak kabul edilmektedir. Klinik olarak büyük miktarda MRG verilerinin uzman radyologlar tarafından incelenmesi hem zaman gerektiren hem de zor bir iştir. Teşhisin doğruluğu uzman doktorun tecrübesi ve dikkatine bağlı olarak değişmektedir. Bu yüzden hem teşhis doğruluğunu arttırmak hem de uzman doktorlara yardımcı olabilmek amacıyla beyin tümörlerinin sınıflandırılması ve segmentasyonunda kullanılmak üzere araştırmacılar birçok model önermişlerdir.

Bu tez çalışması kapsamında ise glioma, akciğer ve meme metastazı beyin tümör tiplerinin sınıflandırılması gerçekleştirilmiştir. Çalışma kapsamında kullanılan verilerden metastatik tip beyin tümörleri Kocaeli Üniversitesi Tıp Fakültesi Radyoloji Bölümü'nden, glioma tip beyin tümörleri ise Nanfang Hastanesi ve Tianjin Tıp Üniversitesi Genel Hastanesi'nde toplanan online olarak sunulan veritabanından alınmıştır.

Tez çalışmasının birinci bölümünde beyinde oluşan tümörler hakkında genel bilgiler verilmiş ve daha sonra güncel literatürden seçilen beyin tümör tipleri sınıflandırılması ile ilgili çalışmalar detaylı olarak incelenmiştir. Ayrıca tezin literatüre vereceği katkı sunulmuştur.

İkinci bölümde beynin genel anotomik yapısı ve beyin tümörleri açıklanmıştır. Daha sonra tıbbi görüntüleme tekniklerinden beyin tümör tanısında en çok tercih edilen manyetik rezonans görüntülemenin tarihçesi, çalışma mantığı ve oluşan görüntülerin özellikleri ve sekansları incelenmiştir.

Üçüncü bölümde ise makine öğrenmesi yöntemlerinden başlanarak derin öğrenme teorik altyapısı anlatılmıştır. Tez çalışması kapsamında kullanılan özellik çıkarma yöntemi açıklanmıştır. Daha sonra transfer öğrenme modelleri incelenmiştir.

Dördüncü bölümde tez çalışması kapsamında kullanılan verisetlerinin elde edilmesi, görüntülerin ön işlemlerden geçirilmesi ve önerilen sınıflandırma modelleri hakkında bilgi verilmiştir.

Beşinci bölümde tez çalışması kapsamında beyin tümör sınıflarının sınıflandırılmasından elde edilen deneysel sonuçlar verilmiştir.

Altıncı bölümde ise tez çalışması kapsamında elde edilen sonuçlar hakkında bilgi verilmiştir. Ayrıca çalışmanın geliştirilmesi ile ilgili öneriler ve iyileştirmeler sunulmuştur.

1. GENEL BİLGİLER

Beyin tümörü, beyni veya kafatasını çevreleyen dokuların beynin içinde oluşturduğu ve insan yaşamını doğrudan etkileyen bir kitle oluşumdur. Bu kitleler iyi huylu veya kötü huylu olabilirler. Beyin tümörleri beyinde düzensiz bir şekilde büyüyerek beyin zarı etrafına baskı uygularlar. Basıncın etkisi ile beyinde vücudu kontrolünü etkileyen çeşitli bozukluklara neden olur. İnsanlarda bu tür belirtilerin başında baş dönmesi, baş ağrısı, bayılma nöbetleri, felç vb. durumlar görülmektedir. İyi huylu tümörlerin aksine, kötü huylu tümörler düzensiz bir şekilde büyür ve çevre dokulara zarar verir. Beyin tümörünün tedavisinde genellikle cerrahi yöntemler tercih edilmektedir. Ancak ameliyatla alınacak tümör hayati bir alanda ise ilaç, radyasyon vb. farklı tedavi yöntemleri tercih edilmektedir [1]. Başlangıç kökenlerine bağlı olarak beyin tümörleri, primer (birincil) beyin tümörleri veya metastatik beyin tümörleri olarak ikiye ayrılmaktadır. Birincil hücrelerde, hücrelerin kökeni beyin dokusu hücrelerinden oluşmaktadır. Metastatik beyin tümörlerinde ise hücreler vücudun başka bir organında kanserli yapıya dönüşür ve beyne yayılır [2].

Erken tümör teşhisi, tedavi olanaklarının artırılmasında önemli bir rol oynar. Tek Foton Emisyonlu Bilgisayarlı Tomografi (Single-Photon Emission Computed Tomography, SPECT), Pozitron Emisyon Tomografisi (Positron Emission Tomography, PET), Bilgisayarlı Tomografi (Computed Tomography, CT), Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging, MRI) ve Manyetik Rezonans Spektroskopi (Magnetic Resonance Spectroscopy, MRS) gibi beyin görüntüleme teknikleri tanıya yardımcı olmak için beyin tümörünün yeri, boyutu, şekli ve türü hakkında bilgi sağlamaktadır. MR, insan dokularının anatomisi hakkında zengin bilgi sağlar ve yaygın olarak bulunabilmesi ve yumuşak doku kontrastı nedeniyle standart bir teknik olarak kabul edilmektedir. MRI, insan dokularının görüntülerini üretmek için güçlü bir manyetik alana sahip radyo frekansı sinyallerini kullanan invazif olmayan bir tıbbi görüntüleme tekniğidir. Farklı MRI sekanslarının görüntüleri, görüntü edinimi sırasında uyarma ve tekrarlama sürelerini değiştirerek

oluşturulmaktadır. Bu farklı MRI sekansları, farklı tipte doku kontrast görüntüleri üretir, böylece değerli yapısal bilgiler sayesinde alt bölgeler ile birlikte tümörlerin teşhisini, sınıflandırılmasını ve segmentasyonunu kolaylaştırmaktadır [3].

Beyin tümörlerinin zamanında teşhisi ve doğru sınıflandırılması hasta sağlığı, tedavi planlaması açısından oldukça önemlidir. Ayrıca beyin tümör tipinin doğru bir şekilde sınıflandırılması radyologlar açısından zaman alıcı ve süreç isteyen bir iştir. Bu yüzden tedavi planlaması sürecini uzatmakta ve hasta sağlığını tehlikeye sokmaktadır. Günümüzde bilgisayar destekli otomatik teşhis yöntemleri oldukça popular hale gelmiştir. Yapay zekâ ve makine öğrenmesi teknikleri bu alanda da oldukça önemli hale gelmiştir ve beyin tümör tipi sınıflandırılmasında kullanılmaktadır. Bu sistemlerin sağlamlaştırılması ve doğrulukların artırılması doğru teşhis açısından oldukça önemlidir [4].

Bilgisayarlı görme alanında beyin tümörü sınıflandırılması literatürde yaygın olarak uzun zamandır çalışılan ve güncelliğini yitirmemiş bir konudur. Araştırmacılar beyin tümörü sınıflandırması için farklı birçok model önermişlerdir. Görüntülerin sınıflandırılmasında olduğu gibi, beyin tümörü sınıflandırılmasında da en yüksek performansı elde etmek için özniteliklerin ve sınıflandırıcıların doğru seçimi hayati öneme sahiptir [5]. Cheng ve ark. önerdikleri yöntemde, yoğunluk histogramı, gri seviye birlikte oluşma matrisi (Gray Level Co-Occurence Matrix, GLCM) ve kelime torbası (Bag of Words, BoW) modeli olmak üzere üç farklı özellik çıkarma yönteminin etkinliğini beyin tümör sınıflandırması problemi üzerinde test etmişlerdir. Sınıflandırıcı olarak Destek Vektör Makineleri (DVM), k-en yakın komşuluk (k-Nearest Neighbors, k-NN), k-means yöntemlerini kullanmışlardır. BoW ile çıkarılan öznitelikleri DVM sınıflandırıcı kullanarak %91,14 doğruluk elde etmişlerdir [6]. Ismael ve Abdel-Qader MRI görüntülerinde beyin tümörlerinin sınıflandırılması için istatistiksel özellikleri ve sinir ağı algoritmalarını birleştiren bir model sunmuşlardır. 2D Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform, DWT) ve 2D Gabor filtre tekniklerinin bir kombinasyonunu kullanarak özellik seçimi ve geri yayılma sinir ağı sınıflandırıcısı (Back Propagation Neural Network, BPNN) ile üç tip (Meningioma, Glioma ve Hipofiz tümörü) beyin tümör tipinin sınıflandırılmasını gerçekleştirmişlerdir. %95,66'lık bir doğruluk elde ettiklerini söylemişlerdir [7].

Gumaei ve ark. beyin tümörü sınıflandırma yaklaşımı geliştirmek için düzenlenmiş aşırı öğrenme makinesi (Regularized Extreme Learning Machine, RELM) ile hibrit bir özellik çıkarma yöntemi önermişlerdir. Hibrit PCA-NGIST adını verdikleri, L2 normu kullanarak normalleştirildikten sonra Temel bileşenler Analizi (Principal Component Analysis, PCA) yöntemini normalleştirilmiş GIST (Normalized GIST, NGIST) tanımlayıcı ile birleştiren özellik çıkarma yöntemini kullanmışlardır. RELM sınıflandırıcı ile %94,233 başarı oranı elde etmişlerdir [8]. Thejaswini ve ark. beyin tümör sınıflandırılması için ilk önce Uyarlanabilir Düzenlenmiş Çekirdek Tabanlı Bulanık C-Ortalama Kümeleme (Adaptive Regularized Kernel based Fuzzy C-Means Clustering, ARKFCM) yöntemi ile segmentasyon yapmışlardır. Segmentasyon sonrası birinci derece ve ikinci derece istatistiksel özellikler çıkarmışlardır. Tümörün varlığını ve tam konumunu tespit etmek için enerji, entropi, homojenlik, kontrast ve korelasyon gibi birinci dereceden istatistik özelliklerin yanı sıra eksantriklik, çevre ve alan gibi bölge özelliklerine dayalı ikinci derece istatistik özellik çıkarmışlardır. Çıkardıkları öznitelikleri kullanılarak DVM modeli ile %91,4 başarı ile elde etmişlerdir [9]. Yin ve ark. beyin tümör sınıflandırması için önerdikleri yöntem arka plan kaldırma, özellik çıkarma ve çok katmanlı algılayıcı sinir ağına dayalı sınıflandırma olmak üzere üç aşamadan oluşmaktadır. Öznitelik olarak doku, istatistiksel ve geometrik öznitelikler kullanmışlardır. Özniteliklerin ve sınıflandırma aşamalarının optimum seçiminde kaos teorisine ve lojistik haritalama tekniğine dayanan gelişmiş bir balina optimizasyon algoritması (Improved Whale Optimization Algorithm, IWOA) modeli kullanmışlardır. Önerdikleri yöntem ile geleneksel sınıflandırıcılardan daha yüksek %87 doğru tespit oranı (Correct Detection Rate, CDR) bulmuşlardır [10].

Araştırmacılar beyin metastazları ve farklı tip beyin tümörünü kullanarak birçok çalışma gerçekleştirmişlerdir. Sachdeva ve ark. T1-ağırlıklı MR görüntülerinden astrositom (Astrocytoma, AS), glioblastoma multiforme (GBM), genellikle çocuk ve gençlerde görülen medulloblastoma (MED), beyin zarı tümörü (Meningioma, MEN), metastatik tümör (Metastatic, MET) ve normal bölgeler (Normal Regions, NR) tip beyin tümörlerinin sınıflandırılmasını gerçekleştirmişlerdir. İlk önce yoğunluk ve doku özniteliklerini çıkararak temel bileşenler analizi ile öznitelik seçimi gerçekleştirmişlerdir. Yapay sinir ağları (YSA) kullanarak %91 başarı elde etmişlerdir [11]. Zacharaki ve ark. metastatik tümörler, meningiomalar, derece II gliomalar,

derece III gliomalar ve GBM'leri sınıflandırmaya çalışmışlardır. Çalışmaları öznitelik çıkarma, öznitelik seçme ve sınıflandırma olmak üzere üç aşamadan oluşmaktadır. İlk önce hasta yaşı, tümör şekil özellikleri, bazı ilgi alanlarındaki (Region of Insterest, ROI) görüntü yoğunluğu özellikleri ve Gabor doku özelliklerini öznitelik olarak kullanmışlardır. Sıralamaya Dayalı Kriter (Ranking-Based Criterion) kullanarak özniteliklerin baskın olanlarını seçmişlerdir. Sınıflandırma aşamasında doğrusal ayrımcılık analizi (Linear Discriminant Analysis, LDA), k-en yakın komşuluk ve DVM modellerini kullanarak sırasıyla %81,1, %81,1, %91,2 doğruluk elde etmişlerdir [12]. Skogen ve ark. MRI doku analizi yöntemini kullanarak ile hem katı tümörün hem de peritümoral ödemin heterojenliğini ele alarak beyin metastazı (MET) ve glioblastomayı (GBM) sınıflandırma çalışmışlardır. Çalışmada T1, T2 ağırlıklı ve FLAIR sekanslarını kullanmışlardır. Sınıflandır işlemini Mann Whitney testi kullanarak gerçekleştirmişlerdir. Testte önemli bir farka sahip olan parametreler, İşlem Karakteristik Eğrisi (Receiver Operating Characteristics Curve, ROC) ölçütü ile değerlendirilmiştir. Tümörün katı kısmının heterojenliğini ölçmek, GBM ve MET arasında önemli bir fark göstermemesine rağmen GBM peritümöral ödemin heterojenliği, MET'i çevreleyen ödemden önemli ölçüde daha yüksek olduğunu ve bunları %80 hassasiyet (sensitivity) ve %90 özgüllük (specificity) ile ayırt ettiklerini belirtmişlerdir [13]. Larroza ve ark. doku özelliklerini kullanarak beyin metastazı ile radyasyon nekrozu sınıflandırmak için kendilerine özgü DVM tabanlı bir model önermişlerdir. Çalışmada T1 ağırlıklı ve FLAIR sekans görüntülerini kullanmışlardır. Doku özellikleri olarak histogram, mutlak gradyan, eş-oluşum matrisi, çalışma uzunluğu matrisi, otoregresif model, dalgacık dönüşümünü kullanmışlardır. Özyinelemeli özellik eleme (Recursive Feature Elimination, RFE) yöntemi ile sağlam öznitelikleri ayırt etmişlerdir. Daha sonra DVM yöntemi ile birinci veri setinde %0,94±0,07 (ortalama doğruluk, standart sapma) ve ikinci veri setinde %0,93±0,02'lik başarı elde ettiklerini belirtmişlerdir [14]. Artzi ve ark. glioblastoma ve beyin metastazı (göğüs, akciğer ve diğer beyin metastazları) tip tümörleri sınıflandırmak için bir model geliştirmişlerdir. Hastaların klinik bilgileri, tümör konumu, birinci ve ikinci derece istatistiksel öznitelikler, morfolojik öznitelikler, dalgacık özellikleri ve özellik çantası kullanarak öznitelikleri elde etmişlerdir. Sınıflandırıcı olarak DVM modelini tercih etmişlerdir. Test veri setinde glioblastom ve beyin metastazı sınıflandırılması

için en iyi sonuçlar, ortalama doğruluk=0,85, hassasiyet=0,86, özgüllük=0,85 ve AUC=0,96 olarak DVM sınıflandırıcı kullanılarak elde edilmiştir. Glioblastoma ve beyin metastazı alt tipleri (göğüs, akciğer ve diğer beyin metastazları) arasındaki sınıflandırma sonucunda ortalama doğruluk=0,85, 0,89, 0,75, 0,90; hassasiyet=1,00, 0,60, 0,57, 0,11; özgüllük=0,76, 0,92, 0,87, 0,99 ve AUC=0,98, 0,81, 0,83, 0,57 değerlerini elde ettiklerini belirtmişlerdir [15].

Lukas ve ark. menenjiyomlar, glioblastomlar, derece II astrositomalar ve metastaz tip beyin tümörünün ayırt edilmesi için çeşitli sınıflandırma tekniklerini kullanmışlardır. Yazarlar doğrusal sınıflandırıcı olarak LDA, DVM, doğrusal çekirdek içeren en küçük kareler DVM (Least least squares SVM, LS-SVM) ve doğrusal olmayan teknik olarak ise radyal temel işlevli (Radial Basis Function, RBF) çekirdek tabanlı LS-SVM tekniğini kullanmışlardır. Ortalama doğruluk %83,5726±3,5058 standart sapma ile en yüksek doğruluğu LS-SVM RBF yöntemi ile elde ettiklerini belirtmişlerdir [16]. Qian ve ark. beyin metastazlarından (MET) glioblastomu (GBM) ayırmak için en optimal radyomiks makine öğrenimi sınıflandırıcıyı belirlemeye çalışmışlardır. PyRadiomics arayüzü ile radyomiks öznitelikleri elde etmişlerdir. Birinci derece istatistiksel öznitelikler, şekil tanımlayıcıları ve doku özellikleri (gri seviye eş oluşum matrisi, gri seviye çalışma uzunluğu matrisi ve gri seviye boyutu bölge matrisi) elde etmişlerdir. Öznitelikleri elde ettikten sonra Adaboost Sınıflandırıcı, k-NN, çok katmanlı algılayıcı (Multi-Layer Perceptron, MLP), karar ağacı (Decision Tree, DT), naif bayes (Naive Bayes, NB), rastgele orman (Random Forest, RF) ve DVM modelleri kullanarak sınıflandırma işlemini gerçekleştirmişlerdir. En yüksek doğruluğu %83 olarak DVM modeli ile elde etmişlerdir [17]. Mohsen ve ark. glioblastoma, sarcoma, metastazik tümörlerin sınıflandırması amacı ile bir model sunmuşlardır. İlk önce bulanık C-ortalamalar (Fuzzy C-means) ve k-ortalama (k-Means) metodları ile görüntüleri segmente ettikten sonra GLCM ve ayrık dalgacık dönüşümü (Discrete Wavelet Transform, DWT) kullanarak öznitelikleri seçmişlerdir. Bu özniteliklerden temel bileşen analizi ile baskın öznitelikleri seçmiş ve daha sonra DVM ile sınıflandırma %93,94 doğruluk elde ettiklerini belirtmişlerdir [18].

Yerel İkili Örüntüler (YİÖ) günümüzde güncelliğini koruyan ve görüntülerden özellik çıkartmada sıklıkla başvurulan bir yöntemdir. Sriramakrishnan ve ark. BRATS (Brain

Tumor Segmentation) veri setini kullanarak çok sekanslı MRI beyin tümörü tespiti ve segmentasyonu için YİÖ tabanlı bir yöntem geliştirmişlerdir. İlk aşamada MR görüntü kesitlerini normal veya tümörlü olarak sınıflandırmak için Haralick özellik bloklarını ve DVM modeli kullanmışlardır. İkinci adımda, ilk aşamada tanımlanan kesitlerden tümör bölgesini çıkarmak için bulanık c ortalamalar algoritması kullanmışlardır. En son olarak ise tümör alt yapılarını histogram kutularının olasılık yoğunluk değerine göre segmentlere ayırmak için yeni bir olasılıksal yerel üçlü desenler (Probabilistic Local Ternary Patterns, PLTP) tekniği kullanmışlardır. Sonuç olarak önerdikleri yöntem ile %97,49 başarı oranı ile beyin tümörünü sınıflandırmışlardır [19]. Abbasi ve Tajeripour üç boyutlu görüntülerde beyin tümörü tespiti için otomatik bir yöntem önermişlerdir. Görüntülerin ilk önce bias alanı düzeltmesi ve histogram eşitlemesi kullanarak ön işlemden geçirmişlerdir. Daha sonra görüntülerden üç ortogonal düzlemde yerel ikili desen (Local Binary Pattern in Three Orthogonal Planes, LBP-TOP) ve yönelim gradyanlarının histogramı (Histogram Orientation Gradient in Three Orthogonal Planes, HOG-TOP) ve gri seviyesi özniteliklerini çıkartmışlardır. Rastgele Orman modeli ile tümörlü bölgeleri segmente ederek başarılı bir şekilde tümörü sınıflandırmışlardır [20]. Thirumurugan ve Shanthakumar, beyin görüntülerini sınıflandırmak için Uyarlanabilir Nöro-Bulanık Çıkarım Sistemleri (Adaptive-network-based fuzzy inference system, ANFIS) kullanmışlardır. Yerel İkili Örüntüler (Local Binary Patterni, LBP) kullanarak segment edilmiş beyin dokularından öznitelikler çıkarmışlardır. Oluşturdukları model ile %99,6 başarı oranı elde ettiklerini belirtmişlerdir [21]. Khalil ve ark. beyin tümörlerini normal veya anormal olarak iki sınıfa ayırmışlardır. İki farklı veri seti üzerinde GLCM, YİÖ ve Yönlendirilmiş Gradyan Histogramı (Histogram of Oriented Gradient, HOG) olmak üzere üç özellik çıkarma tekniğini kullanarak öznitelik çıkarmışlardır. Her teknik ile elde edilen özellik vektörlerini k-NN modeli kullanarak sınıflandırmışlardır. Sınıflandırıcıların doğruluğunu artırmak için füzyon operatörler (toplam, ortalama, minimum, maksimum, medyan) kullanmışlardır. İlk veri seti üzerinde gerçekleştirdikleri deneyde GLCM, LBP ve HOG öznitelik çıkarımları ile sırasıyla %98,49, %94,46, %100 doğruluk elde etmişlerdir. İkinci veri seti ile sırasıyla %95,00, %94,37, %99,37 başarı elde ettiklerini HOG özelliklerinin diğer özelliklere göre daha karakteristik özellikleri çıkardığını vurgulamışlardır [22]. Gupta ve ekibi beyin tümör derecesini

sınıflandırmak için Ayrık Dalgacık Dönüşümünü (Discrete Wavelet Transform, DWT) ve YİÖ tekniklerini birleştirerek (DWT-LBP), değişik çözünürlüklerdeki segmentli tümör bölgelerinden doku özniteliklerini çıkartmak için kullanmışlardır. Daha sonra çarpıklık (skewness), basıklık (kurtosis) ve entropiden oluşan istatistiksel doku özelliklerini DWT-LBP dönüştürülmüş görüntülerden hesaplamışlardır. Aynı zamanda geometrik özelliklerinden tümör yüzeyi, sınırları ve iskeletinden oluşan fraktal boyut ölçülerini ve hacim, çevre tabanlı dışbükeylik ölçümleride öznitelik olarak ele almışlardır. Bu öznitelikleri Naif Bayes (Naive Bayes, NB), DVM, k-NN, LDA yöntemleri ile sınıflandırmışlardır. En yüksek doğruluğu DWT-LBP+fraktal boyut ölçüleri ve NB kullanarak %96 olarak hesaplamışlardır [23].

Günümüzde derin öğrenme modelleri kullanımı beyin tümör sınıflandırılmasında da sıkça başvurulan yöntem haline gelmiştir. Raja ve Rani bayes bulanık kümelenme temelli segmentasyon yaklaşımına sahip hibrit bir derin otoenkoderi kullanarak bir beyin tümörü sınıflandırması geliştirmişlerdir. Ön işlem olarak gürültü azaltıcı yerel olmayan ortalama filtre kullanmışlardır. Daha sonra beyin tümörlerinin segmentasyonu için Bayes bulanık kümeleme (Bayes Fuzzy Clustering, BFC) yaklaşımı kullanılmıştır. Segmentasyondan sonra, özellik çıkarma işlemi için bilgi-teorik önlemler (Information-Theoretic Measures), saçılma dönüşümü (Scattering Transform, ST) ve dalgacık paketi Tsallis entropisi (Wavelet Packet Tsallis Entropy, WPTE) gibi yöntemler ile öznitelikler çıkarmışlardır. Son olarak, beyin tümör sınıflandırma prosesi için tümör kısmını sınıflandırmak için softmax regresyon tekniği ile derin otoenkoder (Deep Auto Encoder, DAE) bazlı Jaya Optimizasyon Algoritması (JOA) hibrit bir model kullanmışlardır. Sonuç olarak BRATS veri seti ile %98,5 başarı elde etmişlerdir [24]. Arı ve Hanbay önerdikleri yöntemi ön işleme, aşırı öğrenme makinesi yerel alıcı alanları (Extreme Learning Machine Local Receptive Fields, ELM-LRF) tabanlı tümör sınıflandırması ve görüntü işleme tabanlı tümör bölgesi çıkarımı olmak üzere üç aşamada gerçekleştirmişlerdir. İlk başta, olası gürültüyü gidermek için yerel olmayan araçlar ve yerel yumuşatma yöntemleri kullanmışlardır. İkinci aşamada, kraniyal Manyetik Rezonans (MR) görüntüleri ile konvolüsyonel özellikler çıkarmışlar ve daha sonra ELM-LRF sınıflandırıcı kullanarak iyi huylu veya kötü huylu tümörleri sınıflandırmışlardır. Üçüncü aşamada, tümörler segmentlere ayrılmıştır. Deneysel çalışmalarda kraniyal MR görüntülerin sınıflandırma doğruluğu

%97,18 olarak bulmuşlardır [25]. Abiwinanda ve ark. en yaygın üç beyin tümörü tipini, yani Glioma, Menenjiyom ve Hipofiz kaynaklı beyin tümör tiplerini ayırt etmek için bir Konvolüsyon Sinir Ağlarını (Convolutional Neural Networks, CNN) eğitmeye çalışmışlardır. Konvolüsyon özelliklerini kullanarak çıkarılan özellikler ile beyin tümör tiplerini tam bağlantılı katmanlar kullanarak %84,19 doğruluk oranı ile sınıflandırdıklarını belirtmişlerdir [26]. Pashai ve ark. glioma, menenjiyom ve hipofiz kaynaklı beyin tümör tiplerini sınıflandırmak için bir CNN ağını kullanarak MR görüntülerinden konvolüsyonel özellikler çıkarmışlardır. Daha sonra bir çekirdek (kernel) Extreme Learning Machines (KELM) görüntüleri çıkarılan bu özellikleri kullanarak sınıflandırılmıştır. KELM-CNN yapısı ile %93,68 başarı oranı elde etmişlerdir [27]. Sultan vd. farklı beyin tümör tiplerini halka açık iki veri kümesi kullanarak sınıflandırmak için, evrişimli bir sinir ağına dayanan bir derin öğrenme modeli önermişlerdir. Birincisi veri setinde meningioma, glioma ve hipofiz tümörü tip beyin tümörleri varken diğer veri setinde üç glioma derecesi (Derece II, Derece III ve Derece IV) beyin tümör tipi bulunmaktadır. Önerilen ağ yapısı ile iki veri seti için sırasıyla %96,13 ve %98,7'lik doğruluk elde ettiklerini belirtmişlerdir [28]. Paul ve ark. meningioma, glioma ve hipofiz tümörü tiplerini sınıflandırmak için derin öğrenme yöntemlerini kullanmışlardır. CNN yöntemi ile %91,43 başarı elde etmişlerdir [29].

Yazarlar makine öğrenmesinde kullanılan öznitelikleri bu yöntemlerin otomatik elde etmesini bir avantaj olarak görmektedir. Fakat derin öğrenme modellerinin yetkin olarak genelleştirilmiş sonuç vermesi ve ezberleme (overfitting) yapmaması için büyük verilere ihtiyacı vardır. Beyin tümör sınıflandırılmasında kullanılan veriler genellikle sınırlı veri oldukları için genellikle önceden eğitilmiş modeller derin öğrenmesi uygulamalarında tercih edilmektedir. Özyurt ve ark. kötü huylu ve iyi huylu beyin tümörü tiplerini sınıflandırmak için bir model sunmuşlardır. İlk önce nötronofi seti-uzman maksimum bulanık-emin entropi (Neutrosophy Set-Expert Maximum Fuzzy-Sure Entropy, NS-EMFSE) kullanarak görüntüleri bölütlemişlerdir. Alexnet hazır ağ yapısı kullanarak öznitelik matrisini oluşturmuslardır. SVM sınıflandırıcı kullanarak %95,62 başarı oranı elde etmişlerdir [30]. Özyurt ve ekibi diğer bir çalışmasında Squeeze ağ yapısını öznitelikleri elde etmek için kullanmışlardır. ELM (Extreme Machine Learning) sınıflandırıcı ile %98,33 başarı elde etmişlerdir [31]. Toğaçar ve ekibi beyin MR görüntüleri normal ve tümörlü sınıflandırmak için bir

çalışma yapmışlardır. BrainMRnet ismini verdikleri AlexNet, GoogleNet, VGG-16 hazır ağlarından oluşan bir mimari önermişlerdir. Bu hazır ağlar ile MR görüntülerinden öznitelikler çıkarıp tam bağlantılı katmanlar ile sınıflandırmışlardır. Sınıflandırma sonucu %96,05 başarı oranı elde ettiklerini belirtmişlerdir [32]. Toğaçar ve ekibi diğer çalışmasında aynı veri seti üzerinden Alexnet ve VGG16 mimari ile öznitelikleri elde etmişlerdir. Geliştirdikleri modelde hiper kolon yöntemi ile önceki katmanlardaki baskın özniteliklerideson katmanda değerlendirmişlerdir. Yinelemeli özellik eleme (Recursive feature elimination, RFE) ile niteliksiz öznitelikleri elemişlerdir ve DVM ile sınıflandırma sonucunda %96,77 başarı elde ettiklerini belirtmişlerdir [33]. Sert vd. beyin tümörlerinden özellikleri çıkarmak için ResNet mimarisini kullanmışlardır. İyi huylu ve kötü huylu tümör tiplerini sınıflandırmak için DVM modelinden yararlanarak %95 doğruluk oranıyla gerçekleştirdiler [34]. Mehrotra ve ark. iyi ve kötü huylu beyin tümörlerini AlexNet, GoogleNet ve SqueezeNet mimarileri ile sınıflandırmışlardır. SqueezeNet ile %99,04 başarı oranı elde etmişlerdir [35]. Kaur ve Gandhi beyin tümörlerini normal ve anormal olarak sınıflandırmışlardır. Sınıflandırma da aynı tip tümör çeşidinden oluşan üç veri seti ve Alexnet, GoogLeNet, VGG16, VGG19, Resnet50, Resnet101, Inceptionv3, InceptionResNetV2 mimarilerini kullanmışlardır. Alexnet ile üç veri seti için sırasıyla %100, %94, %95,92 en yüksek başarı oranlarını elde ettiklerini belirtmişlerdir [36]. Talo ve ark. normal ve anormal beyin MR görüntülerini otomatik olarak sınıflandırmak için derin transfer öğrenmeyi kullanan bir yaklaşım önermişlerdir. ResNet34 modelini eğitmek için veri artırma, optimal öğrenme hızı belirleme ve ince ayarlama gibi mevcut derin öğrenme tekniklerini kullanmışlardır. Çalışmalarında %100 başarı elde ettiklerini vurgulamışlardır [37].

Glioma, menenjiyom ve hipofiz kaynaklı beyin tümör tiplerini içeren figshare sitesinden indirilebilen veri seti üzerinde birçok transfer öğrenmesi çalışması gerçekleştirmiştir [38]. Chelghoum ve ark. [39] VGG16 ile %98,71, Deepak ve Amer [40] Googlenet ile %98, Rehman ve ark. [41] VGG19 ile %98,69, Swati ve ark. [42] VGG19 ile %94,82, Ghosal ve ark. [43] Squeeze ve Excitation Network (SENet) ile %93,83 ve Sajjad ve ark. [44] VGG19 ile %94,58 doğruluk oranı elde ettiklerini belirtmişlerdir. Bu çalışmalardan da görüldüğü gibi insan faktörü ile değerlendirilen beyin tümör tiplerinin daha objektif, güvenilir ve tekrarlanabilir otomatik bir bilgisayar

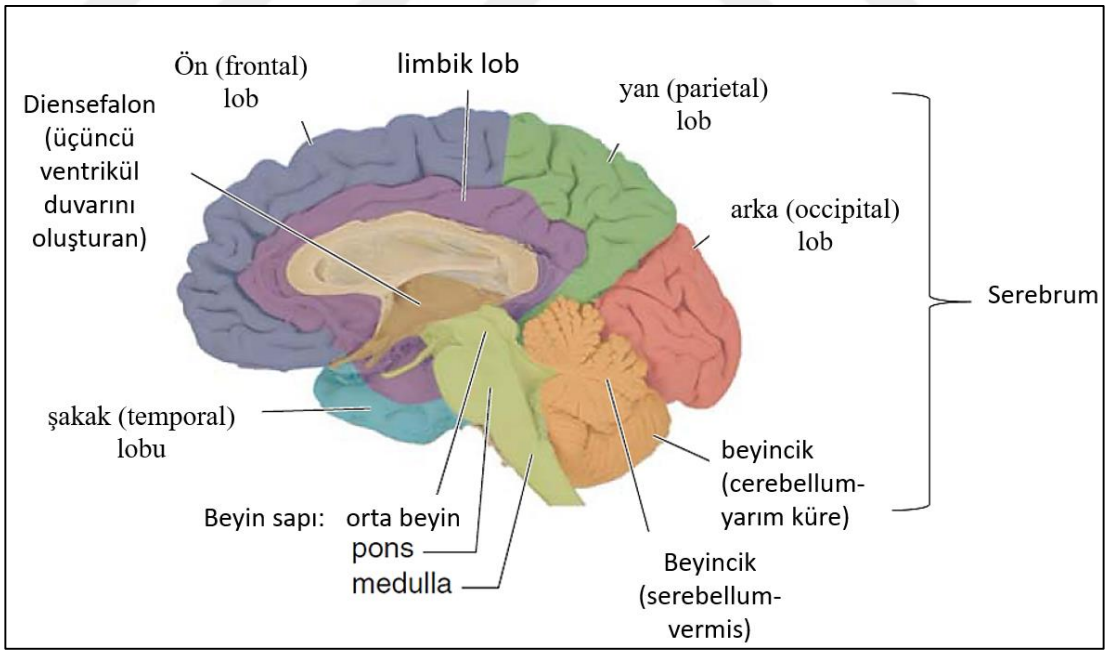
analiz aracı ile değerlendirilmesi meydana gelebilecek hataları en aza indirerek radyolojik tanısal doğruluğu arttırmaktadır.

Bu çalışmada ise sıklıkla karşılaşılan beyin tümör tipleri olan glioma ve literatürde çok az çalışılan akciğer ve meme metastazı kaynaklı beyin tümörü sınıflandırılması için ilk önce üç farklı öznitelik çıkarım (YİÖ, dYİÖ ve αYİÖ) yaklaşımı kullanılmıştır. Veri setindeki görüntülerinden dYİÖ, αYİÖ ve klasik YİÖ ile elde edilen öznitelik matrisleri ve k-en yakın komşuluk, DVM, Logistik Regresyon (Logistic Regression, LR), YSA, Rastgele Orman sınıflandırma modelleri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Aynı veriler daha sonra önceden eğitilmiş derin öğrenme modelleri (Alexnet, VGG19, Resnet101) ile sınıflandırılmıştır. Değerlendirmeler sonucu elde edilen performans ölçütleri karşılaştırmalı olarak verilmiştir. Çalışmada kullanılan modeller glioma ve metastatik tümör ayrımını net olarak gerçekleştirirken, literatürde çok az çalışılan metastatik tip beyin tümörlerinin sınıflandırılmasında etkin ve geçerli sonuçlar vermiştir.

2. BEYİN TÜMÖRLERİ VE TIBBİ GÖRÜNTÜLEME TEKNİKLERİ

2.1. Beyin Anatomik Yapısı

Beyin, insan vücudundaki en büyük ve en karmaşık organlardan biridir. İnsan beyni, insan sinir sisteminin merkezi organıdır ve omurilik ile birlikte merkezi sinir sistemini oluşturur. Vücudun hayat fonksiyonlarını kontrol eden, dışardan gelen bilgileri yorumlayan, zihinsel ve ruhsal düşünceleri bünyesinde barındıran yaklaşık 1,2-1,4 kg ağırlığında bir organdır. Sinaps adı verilen trilyonlarca bağlantıyla iletişim kuran 100 milyardan fazla sinirden oluşmaktadır. Beyin Şekil 2.1'deki gibi serebrum, beyin sapı (brainstem) ve beyincik (cerebellum) oluşur. Vücudun faaliyetlerinin çoğunu kontrol eder, duyu organlarından aldığı bilgileri işler, bütünleştirir ve koordine eder ve vücudun geri kalanına gönderilen talimatlarla ilgili kararlar verir. Beyin kafatası kemiklerinin içinde bulunur ve bunlar tarafından korunmaktadır [45].



Şekil 2.1. Beyin genel anatomik yapısı

Beynin en büyük kısmını serebrum oluşturmaktadır. Sağ ve sol hemisfer olarak iki kısımdan oluşur. Dokunma, görme ve işitme gibi daha yüksek işlevlerin yanı sıra akıl

yürütme, duygular, konuşma, öğrenme ve hassas hareket kontrolünü gerçekleştirir. Beyincik serebrumun altında bulunur. Beyincik, beyin sapının orta beynine, pons ve medulla ile birleşir. Fonksiyonu, kas hareketlerini organize etmek, duruşu sürdürmek ve dengeyi kontrol etmektir. Beyin sapı ise serebrum ve serebellumu omuriliğe bağlayan bir geçiş merkezidir. Sindirim, solunum, kalp atış hızı, vücut ısısı, uyanma, uyku, hapşırma, öksürme, kusma ve yutkunma gibi birçok otomatik işlevi yerine getirir [46].

Beynin tam olarak en büyük kısmı olan beyin, iki beyin yarım küresinden oluşur. Her yarım küre, dört önemli lob'a (Ön (frontal) lob, yan (parietal) lob, arka (occipital) lob, şakak (temporal) lobu) bölünmüştür. Yarım kürelerin dış kısmına gri madde olarak da bilinen serebral korteks denir. Beynin yüzeyinde kalan çıkıntılara girus, beyin yüzeyindeki oluklara sulci denir. Bu sırtlar ve oluklar genellikle konumlarına göre adlandırılmaktadır. Beynin önemli bölümleri ve işlevleri Tablo 2.1'de verilmiştir [47].

Tablo 2.1. Beyin bölümleri ve işlevleri

Beyin bölümü	**İşlevi**
Ön lob	Karakter, duygu, davranış, sorgulama, planlama, problem çözme, konuşma, vücut hareketi, zeka, konsantrasyon
Yan lob	Dil ve kelimeleri kavrama, dokunma, ağrı, sıcaklık, görme, işitme, duyu ve hafızadan gelen sinyalleri yorumlama
Arka lob	Görme yorumlanması (renk, ışık, hareket)
Şakak lobu	Hafıza, işitme, koku algısı, sıralama ve organizasyon

2.2. Beyin Tümörleri

Beyin tümörü, beyindeki hücrelerin anormal ve kontrolsüz bir şekilde büyümesinden kaynaklanan bir kitle oluşumudur. Ölümcül seviyesi, tümör tipi, yeri, büyüklüğü ve gelişim durumu gibi faktörlerin birleşimine bağlıdır. Beyin tümörleri kanserli (malign–kötü huylu) veya kanserli olmayan (benign–iyi huylu) olmak üzere 2 çeşittir. Kötü huylu veya iyi huylu olmalarına bağlı olarak çeşitli beyin tümörü türleri vardır. Amerikan Nörolojik Cerrahlar Derneği (The American Association of Neurological Surgeon, AANS) eğitim amaçlı beyin tümörünün sınıflandırılması listesini

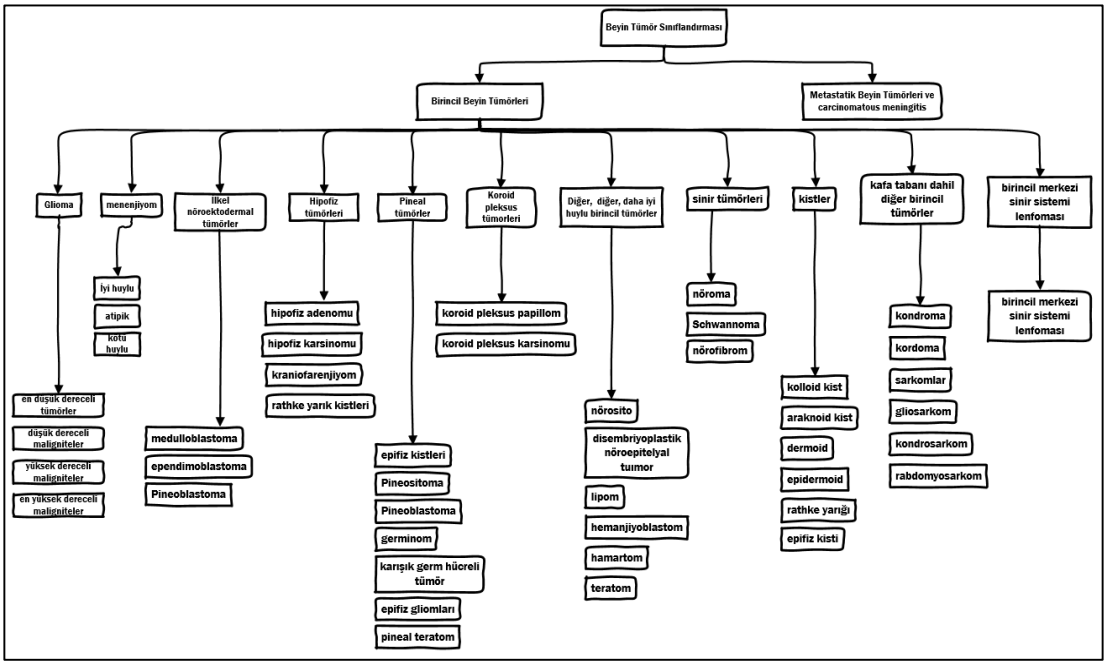
sağlamıştır. Şekil 2.2'de birincil ve metastatik beyin tümörü olarak listelenmiş iki beyin tümör sınıfı gösterilmektedir. Aynı zamanda her beyin tümörünü de tedavi planlamasını yapmak ve sonuçları tahmin etmek için Dünya Sağlık Örgütü (World Health Organization) dört gruba ayırmıştır:

I. Derece: İyi huylu, iyi tanımlanmış sınırları olan, yavaş büyüme ve genellikle uzun süre hayatta kalma oranı ve ameliyatla iyileştirilebilme ihtimaline sahiptir. Çeşitleri, plositik astrositom, kraniofaringiom, ganliositomi gangliogliom.

II. Derece: Yavaş büyüyen, nadiren iyi tanımlanmış bir sınırla yayılma, yavaş büyüyen hücreler, diğer normal hücrelere yayılabilme, yüksek evre bir tümör olarak tekrar edebilme ihtimali vardır. Çeşitleri, diffüz astrositom, oligodendrogliom, oligoastrositom, neurositom.

III. Derece: Kötü huylu, daha hızlı büyüme, yayılma ve tekrarlama ihtimali yüksektir. Çeşitleri, anaplastik astrositom, anaplastik oligodendrogliom, anaplastik gangliom, anaplastik ependimom.

IV. Derece: Yakındaki dokulara hızlıca yayılır ve büyür. Çeşitleri, GBM (glioblastoma multiforme), gliosarkom, medulloblastom, PNET (Primitif Nöroektodermal) [48].



Şekil 2.2. AANS tarafından beyin tümörünün sınıflandırılması

2.2.1. Birincil (primer) beyin tümörleri

Başlangıç hücreleri beyinde olan tümörler birincil beyin tümörleridir. GBM, gliom astrositom, oligodendrogliom, medulloblastom, kraniofaringiom, ependimom, pituitary adenomas birincil beyin tümörleri primer beyin tümörlerindendir. Amerika'da yapılan bir istatistiğe göre gliomlar primer beyin tümörlerinin %30'unu oluşturmaktadır. Gliomların aynı zamanda %80'i kötü huyludur ve %54'ü GBM olarak teşhis edilmiştir. İyi huylu ve kötü huylu olabilmekte ve nadiren metastaz yaparlar [49].

İyi huylu (benign) beyin tümörleri, yavaş büyüyen ve normal dokuyu bir kenara iten, ancak çevresindeki normal dokuyu istila etmeyen, düşük dereceli, kanserli olmayan beyin tümörleridir. Şekilleri düzgün, homojen yapıda, sınırlandırılmıştır. İyi tanımlanmış ve metastatik olmayan tümörler olarak bilinmektedirler. Çünkü herhangi bir sekonder tümör oluşturmazlar. Tedavisi genellikle cerrahi olarak yapılmaktadır. Hayati bir bölgede bulunmuyorsa ölüm riski taşımazlar. Kötü huylu (malign) beyin tümörleri ise hızla büyüyen ve çevresindeki normal dokuyu istila eden kanserli beyin tümörleridir. Heterojendirler, iyi tanımlanmamışlar, düzensiz bir şekilde büyürler ve uzak organlarda benzer tümörlerin büyümesini başlattıkları için metastatik tümörler olarak bilinirler. Malign beyin tümörleri veya kanserli beyin tümörleri en ölümcül hastalıklar arasında sayılabilir [50].

2.2.2. Metastatik (sekonder) beyin tümörleri

Kökenini başka organdan alarak lenfatik ve kan (hematojen) sistemleri yolu ile beyine sıçrayarak oluşan tümörlerdir. Beyin tümör oluşturduktan sonra bir ya da birden fazla noktada tümör oluşturabilir. Beyin metastazları ise kansere bağlı ölüm sebebi olmasının yanı sıra erişkinde görülen en sık merkezi sinir sistemi neoplazmıdır. Beyin metastazlarının toplumda görülme sıklığı giderek artmaktadır; günümüzde beyin metastazların primer beyin tümörlerine oranı neredeyse eşit olmuştur. Dünya çapında nüfusun yaşlanması, gelişmiş tanı yöntemleri, kanser hastalarının daha uzun süre hayatta kalmasını sağlayan tedavi protokolleri bu artışa neden olmuştur. Kanser hastalarının %40'ından fazlasında beyin metastazı gelişmektedir. Erişkinlerde beyin dokusuna metastaz yapan en sık kafatası dışındaki primer tümör akciğer kanseridir.

Onu sırasıyla meme kanseri, cilt kanseri (melanom), böbrek kanseri (renal karsinom) ve kalın bağırsak (kolon) kanseri takip etmektedir. Tüm beyin metastazlarının yaklaşık %10'u tanı anında bilinmeyen bir primer neoplazmdan orijin alır. Hastaların %10'unda sadece beyin tutulumu mevcuttur. Tedavi olanakları bazı hastalarının hayat süresini ve yaşam konforunun uzamasına yardımcı olabilmektedir [51].

2.3. Tıbbi Görüntüleme Teknikleri

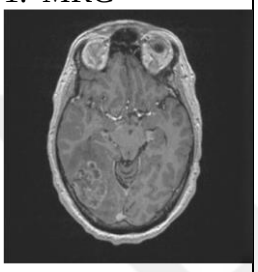
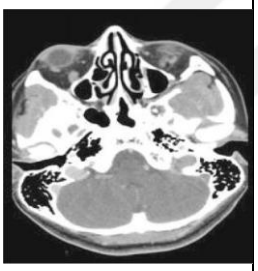
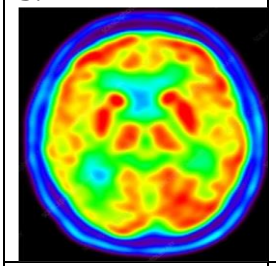
Tıbbi görüntüleme, klinik muayene için insan vücudunun görselleştirmek için kullanılan bir tekniktir. Vücudun çeşitli bölümlerinin yanı sıra dokuların çalışmasını ve işleyişini analiz etmeye yardımcı olur. Ayrıca, sorunun erken aşamada tespit edilmesine anatomik ve fizyolojik açıdan yardımcı olur ve bu da sorunun teşhisine yardımcı olur. Tıbbi görüntüleme manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT), ultrason, elastografi, dokunsal görüntüleme, endoskopi, pozitron emisyon tomografi (PET) ve tek foton emisyon bilgisayarlı tomografi gibi yöntemleri içerir [52].

Bilgisayarlı Tomografi (BT), Pozitron Emisyon Tomografi (PET) ve Manyetik Rezonans Görüntüleme (MRG), Röntgen (X-ray) gibi beyin tümörlerinin erken teşhisi için birçok tanısal görüntüleme tekniği kullanılmaktadır. Beyin tümörlerinin teşhisi, tedavi planlaması ve tedavi sonucu değerlendirilmesinde ağırlıklı olarak Manyetik Rezonans Görüntüleme (MRG) ile yapılmaktadır. Diğer tüm görüntüleme teknikleriyle karşılaştırıldığında MRG, yumuşak dokuların yüksek kontrast, yüksek uzaysal çözünürlük ve zararlı radyasyon üretmediğinden beyin tümörü tespit ve tanımlamasında etkilidir. MRG, sağlıklı ve hasta dokular arasındaki anatomik yapı farklılıklarını belirlenemek ve tanımlamak için büyük mıknatıslar içinde oluşturulan manyetik alana radyo dalgaları kullanan tıbbi görüntüleme tekniğidir. Tümörlerin saptanması ve sınıflandırılması amacıyla difüzyon MR, perfüzyon MR, Bilgisayarlı Tomografi (BT), Difüzyon Tensor Görüntüleme (DTG), fonksiyonel MR, MR spektroskopi gibi değişik MR yöntemleri kullanılmaktadır [53-54].

MR görüntülemenin en önemli avantajı invaziv olmayan bir teknik olmasıdır [55]. Tıbbi karar destek sistemleri günümüzde kanser araştırması, gastroenteroloji, kalp hastalıkları, beyin tümörleri, vb. gibi geniş bir tıbbi alanda yaygın olarak

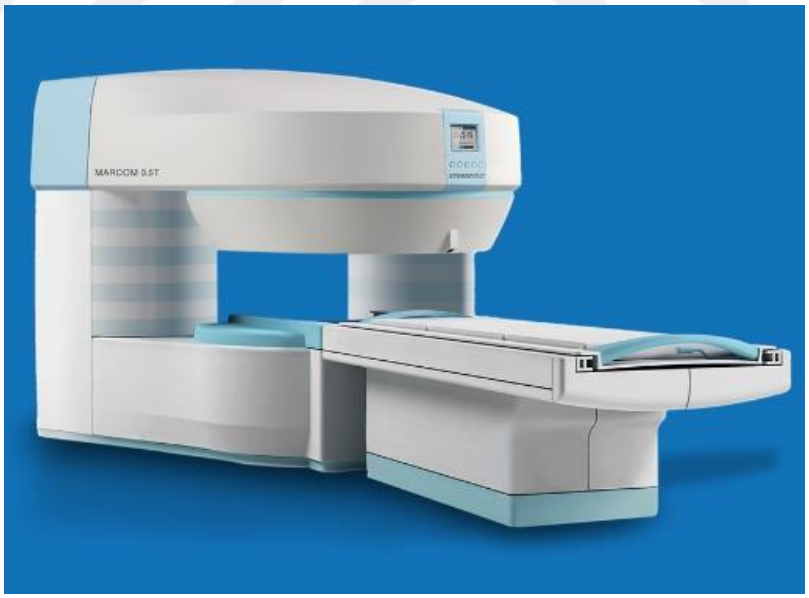
kullanılmaktadır [56]. Tam otomatik, normal ve hastalıklı insan beyni sınıflandırması araştırma ve klinik çalışmalar için büyük önem taşıyan manyetik rezonans görüntülerinden elde edilebilmektedir [57]. Tablo 2.2'de çeşitli beyin tümör görüntüleme teknikleri avantaj ve dezavantajları ile verilmiştir.

Tablo 2.2. Tıbbi görüntüleme yöntemleri

Tıbbi görüntüleme yöntemleri	**Avantajları**	**Dezavantajları**
1. MRG 	• Herhangi bir iyonlaşma radyasyonu üretmez. • Medikal görüntülerde daha iyi çözünürlük sağlar. • Kullanım alanı: Tümör, yaralanma, kist, enfeksiyon ve kanamayı tespit etmek için kullanılır.	• Klostrofobik kişiler için kesinlikle tavsiye edilmez. • Kullanımıyla çok fazla gürültü üretmektedir.
2. BT tarama 	• Hızlı ve acısızdır. • Kemik benzeri yapılar hakkında detaylı bilgi sağlar. • Ayrıca lezyonları sınıflandırabilir. • Kullanım alanları: tümörlerin ve damar hastalıklarının tespiti, göğüs, karın ve pelvis muayenesi.	• İyonlaşma radyasyonlarına zararlı maruz kalma. • Kötü çözünürlük.
3. PET 	• Organların ve yumuşak dokuların işleyişini görselleştirir. • Daha yüksek çözünürlüklü görüntüler sağlar. • Farmakoloji, nöroloji, nöropsikoloji ve benzeri alanlarda kullanılabilir.	• Kullanması pahalıdır. • Radyasyonlar hamile kadınlar için zararlıdır.
4. X-ışınları 	• X-ışınları en ucuz görüntüleme yöntemidir. • En çok kullanılan ve kullanışlı bir tekniktir. • Tıp ve farmakoloji alanlarında olabilir. • Kemiklerde, organlarda ve yumuşak dokularda oluşabilecek yaralanmaları tespit etmek için kullanılır.	• Yeterli bilgi sağlanmaz. • Maruz kalma ne kadar yüksekse, cilt kanseri olasılığı o kadar yüksektir. • DNA'da değişikliğe neden olur.

2.3.1. Manyetik rezonans görüntüleme

Manyetik Rezonans Görüntüleme (MRG) cihazlarında ilk başta büyük mıknatıslar ile üretilen güçlü statik ve gradyan manyetik alan içinde radyo dalgaları dokulara gönderilerek hücrelerdeki hidrojen atomunu uyarılır. Daha sonra oluşan sinyaller özel antenler ile bilgisayar ortamında toplanarak işlenmesi sonucunda görüntüye dönüştürüldüğü bir tıbbi görüntüleme yöntemidir. Bu sayede belirli tipteki (sağlıklı, kanserli) anatomik yapılar diğer yapılardan ayırt edilebilmektedir Günümüzdeki kullanılan MRG cihazları genellikle 0,15T (Tesla)-2T mıknatıs içerir, çözünürlüğü yüksek görüntü elde etmek için MRG cihazları 8 T güce kadar çıkarılabilmektedir. Hastaların radyasyon ve ilaca maruz kalmaması bu cihazların önemli avantajlarındandır [58]. MRG cihazları açık veya kapalı olarak imal edilebilmektedir. Hastayı ürkütmemek ve yanlarına refakatçi alabilmelerini sağlama ayrıca kapalı MRG cihazlarına sığamayan hastalar için MRG cihazları Şekil 2.3'teki gibi açık formda üretilebilmektedir [59]. Dezavantajı etrafı açık olduğu için güçlü manyetik alan üretemez ve kapalı forma göre daha düşük çözünürlükte görüntüler üretir.



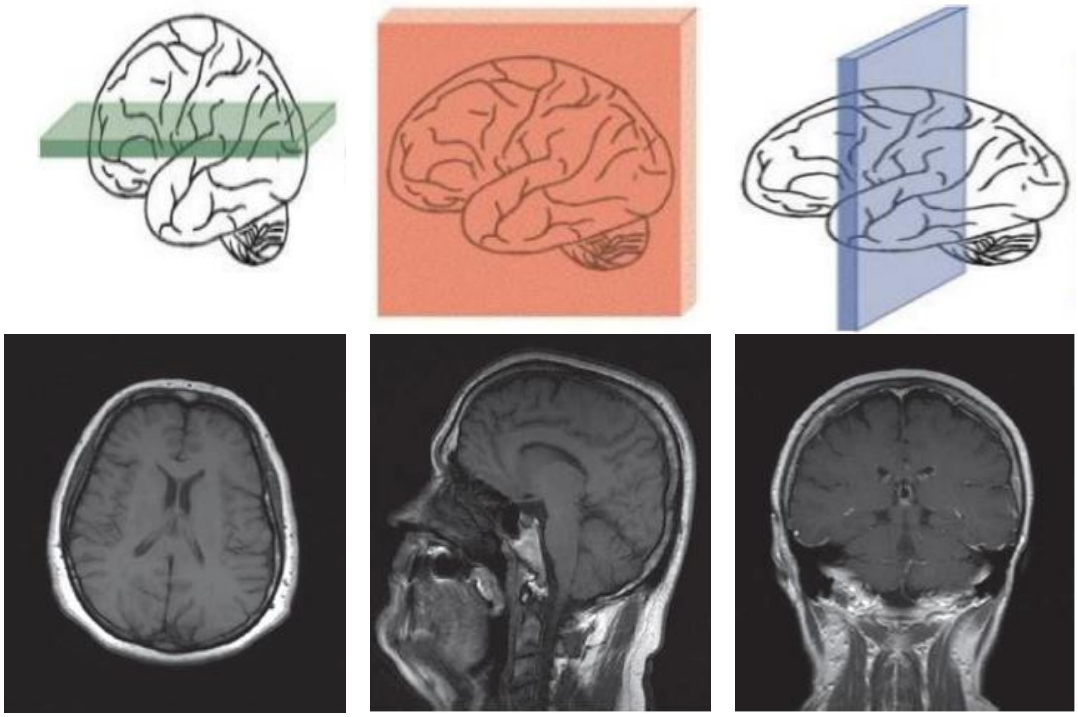
Şekil 2.3. Açık MRG cihazı

Kapalı MRG cihazları yüksek güçlü mıknatıslardan oluşan tüp içerisine hasta yatırılarak görüntü elde edilmesi sağlanır. Açık MR cihazlarına göre çok daha yüksek güçte oldukları için daha yüksek çözünürlükte görüntüler elde edilebilmektedir. Şekil 2.4'te örnek bir kapalı MR cihazı bulunmaktadır [60].



Şekil 2.4. Kapalı MRG cihazı

MRG cihazları aksiyel, sagittal ve koronal olmak üzere üç farklı eksende görüntü sağlayabilmektedir. Aksiyel eksende baştan başlayarak ayaklara doğru görüntü kesitleri elde edilir. Koronal eksende kesitler arkadan öne doğru çekilir. Sagital eksende ise soldan sağa doğru kesit görüntüler elde edilir. Şekil 2.5'te aksiyel, koronal ve sagital görüntü örnekleri bulunmaktadır [61].



Şekil 2.5. Sırasıyla çekilmiş aksiyel, sagittal ve koronal görüntüler

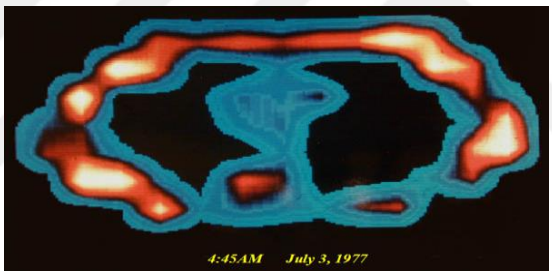
2.3.2. Manyetik rezonans görüntüleme tarihçesi

MRG'nin temelleri 20. yüzyılın ortalarında Profesor Isidor Rabi'nin Nükleer Manyetik Rezonans (NMR) üzerine yapmış olduğu çalışmalar ile oluşturulmuştur. Rabi çalışmaları sonucunda atomların belirli seviye bir manyetik alanda radyo dalgaları ortaya çıkardığını keşfetmiştir. 1944 yılında bu çalışması ile Rabi Nobel fizik ödülünün sahibi olmuştur. Bu çalışma daha sonra 1946 yılında katı ve sıvı atomlar üzerinde Felix Bloch ve Edward Purcell tarafından denenmiş MRG'nin fenomenleri belirlenmiştir. Bu çalışmaları ile 1952 yılında Nobel fizik ödülünü kazanmışlardır. 1970 yılında Raymond Damian MR'da tümörlü dokuların sağlıklı dokulara göre farklı sinyaller yaydığını keşfetmiştir. Daha sonra 1973 yılında Paul C. Lauterbur insan vücuduna uyarlanmıştır. Lauterbur, bilgisayarlı tomografi tekniğinde kullanılan ters projeksiyon tekniği ile su kabı içerisindeki iki tüpten ilk MR görüntüsünü elde etmiştir. 1975 yılına gelindiğinde Zürich üniversitesinden Richard Ernst alınan sinyallerin frekans ve fazlarını belirleyerek MR görüntülemeyi önermiştir. Böylelikle günümüz MRG cihazlarının temeli atılmıştır. 1977 yılında Damadian mide hastalığı geçirdiğinde x ışınlarının yeterli olmadığını farketmiş ve tüm vücut görüntülenmesini MR ile gerçekleştirmiştir. Aynı yıl Peter Mansfield'de çok hızlı görüntü elde edebilen Echo Planar Imaging (EPI) tekniğini keşfetmiştir. Damadian ve ekibi 1977 yılında sağlıklı bir insanın ve 1978 yılında ise kanser olan bir insanın ilk Manyetik Rezonans Görüntüsünü elde etmiştir. Şekil 2.6'da Damadian ve ekinin geliştirmiş olduğu MRG cihazı ve Şekil 2.7'de ise elde ettikleri ilk MR görüntüsü bulunmaktadır. 1980 yılında ise Hawkes, MRG'nin multiplanar özelliğini tanımlayarak bir lezyonun ilk kez görüntülemiştir. MRG cihazında ilk kez kontrast madde 1984 yılında Schörner ve ekibi tarafından kullanılmıştır [62-64].

1986 yılında Haase ve arkadaşları, hızlı görüntüleme sekansları ile tetkik süresi süresini kısaltmışlardır. Charles Dumoulin 1987 yılında MR-Anjiyografi (MRA) tekniğini geliştirerek kontrast madde verilmeden kan damarları görüntülemiştir. 1993 yılında geliştirilen fonksiyonel MRG (fMRG) ile sadece kalp görüntülemede kullanılabileceği düşünülen cihazlar beyin MRG alanında da kullanılmaya başlanmıştır. Türkiye'de ilk defa MRG cihazı 1989'da Dokuz Eylül Üniversitesi Tıp Fakültesi'nde kullanılmıştır.



Şekil 2.6. İlk MR makinesi



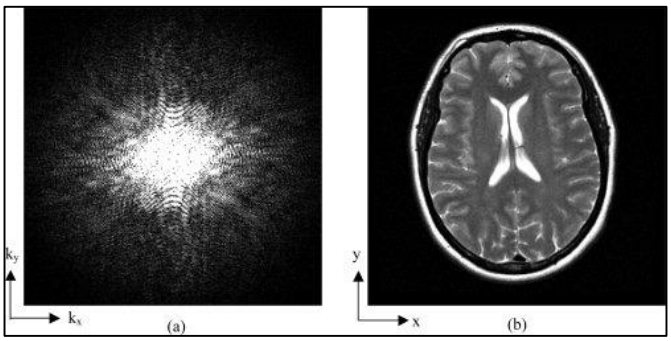
Şekil 2.7. İlk MR görüntüsü

2.3.3. Manyetik rezonans görüntüleme temel prensipleri

Bir MRG sistemi bir paramanyetik mıknatıs, radyo frekans (Radio Frequency, RF) alıcı-vericisi, kontrol birimi olarak bir bilgisayar ve bir yazılımdan oluşmaktadır. Normal bir MRG işlemi günümüzde 10-20 dk. arasında sürmektedir. NRG cihazları PET ve BT'de olduğu gibi iyonize radyasyon kullanmadığı için hasta vücuduna bir zarar vermemektedir.

İnsan vücudunun yaklaşık üçte ikisi sudan oluşmaktadır. MRG temeli ise Hidrojen atomlarındaki protonlardan elde edilen sinyallerinden gelmektedir. Bu sinyaller kullanılarak MR görüntüleri elde edilmektedir. İnsan vücudu MRG cihazı içine yerleştirilir ve büyük bir statik manyetik alan (1,5T-3T) uygulanır. Böylece insan vücudunda bulunan H atomundaki protonlar manyetik alana zıt yönde harekete

geçerler. Sabit manyetik alan kuvveti etkisi altından protonlar konumlarında hareketsiz kalırlar. RF vericisinden daha sonra bir sinyal gönderilir. RF sinyalleri gönderilmesi ile oluşan manyetik alan protonla aynı büyüklükte frekansa sahip ise protonlar enerji elde ederek manyetik alana zıt yönde hareket etmeye başlarlar. Radyo sinyalleri geldiği anda oluşan elektromanyetik alan rezonans frekansı denilen bir frekansta oluşmaktadır. RF sinyali kesildikten sonra protonlar tekrar eski konumuna yani mıknatıslar tarafından sağlanan statik manyetik alanla aynı hizaya gelirler. Protonlar ilk konumlarına gelirken her farklı dokuya ait proton değişen miktarlarda ve farklı zamanda enerji yayarlar. Burada protonların göstermiş olduğu değişim sinyalleri RF alıcı ile alınarak bilgisayar ortamına aktarılır. Daha sonra bu sinyaller yüksek kazanç düşük gürültüye sahip yükselteçler ile yükseltilir. MR sinyali hem karmaşık bir sayı haline dönüşür. Daha sonra bu sinyal filtreleme işleminden geçirilerek Larmor frekansından ayrılır ve geriye eko sinyali kalır. Daha sonra Analog Dijital Dönüştürücüler (ADC) devreleri ile sayısallaştırılarak bilgisayar ortamında Fourier Transformu (FT) alınır. Daha sonra sinyaller k uzayına uzaysal frekanslarına göre yerleştirilir. İki kez FT alındıktan sonra nihai MR görüntüsü Şekil 2.8'deki gibi elde edilir [65-66].

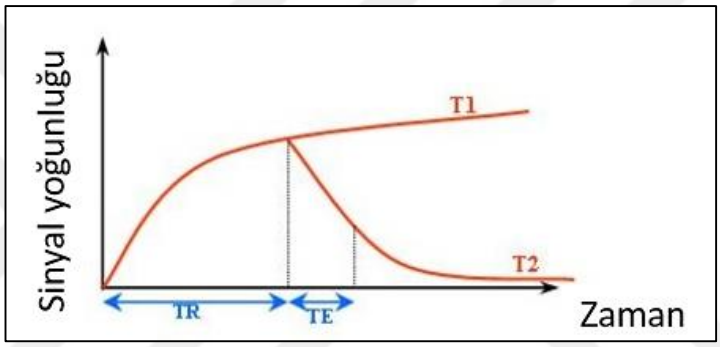


Şekil 2.8. K uzayından görüntü elde edilmesi

2.3.4. Manyetik rezonans görüntülerinde kullanılan sekanslar

MRG, özellikle beyin tümör teşhisinde kullanılan en belirleyici tıbbi görüntüleme tekniğidir. Beyin tümöründeki bazı lezyon, ödem, tümör, nekroz vb. bölgeleri daha net ayırt etmek için farklı MRG sekansları üretilmiştir. Hastaya uygun sekansta tarama yapılması teşhis ve tedavi planı açısından oldukça önemlidir. Farklı dokularda bulunan H atomlarındaki protonlar manyetik alanda rezonans frekansına girdikten sonra denge

konumuna geçerken farklı dinlenme oranlarında eski konumuna dönerler. MRG'de farklı kontrastta görüntüler oluştururken, TR (tekrarlama süresi) ve TE (yankı süresi) dinlenme zamanları, eski konumuna geri gelen protonların yoğunluğu, spektral kaymalar, sapma açısı, akış gibi farklı doku değişkenleri kullanılır. MRG sekansları oluşturmak için farklı açılarda RF sinyalleri H atomlarına gönderilir. FID, dönüş (spin) eko, uyarılmış eko olmak üzere üç tip RF sinyali MRG cihazlarında kullanılmaktadır. Bu sinyallerde TR ve TE zamanları oldukça önemlidir. TR ardışık uygulanan iki RF sinyali arasında kalan zamandır. TE ise bir RF sinyalinin başlangıcından tepe noktasına ulaşana kadar geçen süredir. Şekil 2.9'da T1 ve T2 sekanslarının oluşmasını sağlayan TR ve TE sürelerinin değişimi görülmektedir [61].



Şekil 2.9. MRG'de TE ve TR sinyallerinin değişimi

2.3.4.1. T1-ağırlıklı sekans

Şekil 2.9'a bakıldığında dokuların birbirinden farklı yüksek kontrastta görülmesi için TR zaman aralığının çok uzun olmaması gerekmektedir. Bu süre tümör, yağ ve su içeren dokular için maksimum 800 ms civarında seçilmelidir. Pratikte ise 400-800 ms aralığında değişebilmektedir. Beyinden MR T1-ağırlıklı görüntüsü Şekil 2.10(a)'da görülmektedir. Daha koyu bölgeler omurilik sıvısını, ödem ve lezyonları gösterirken, gri, beyaz renkteki bölgeler yağ ve kan dokularına karşılık gelmektedir. T1 ağırlıklı görüntüler beyindeki yağ ve su içeren dokuları ayırt etmede sıklıkla kullanılmaktadır.

2.3.4.2. T2-ağırlıklı sekans

T2-ağırlıklı görüntüler, yüksek kontrastta görüntü elde etmek için TR parametresinin oldukça uzun, TE değerinin de bu değere uygun olarak seçilmesi gerekmektedir. Genelde bu değerler için TR 2000 ms'den daha yüksek olması tavsiye edilirken TE

değerinin de 85 ms'den daha yüksek olması beklenmektedir. Bu görüntülerde T1 ağırlıklı görüntülerin tersine yağ içeren dokular daha karanlık su içeren dokular daha açık gözükmektedir. Beyin T2-ağırlıklı kesit görüntüsüne örnek Şekil 2.10(b)'de verilmiştir. Omurilik sıvısı, kan ve yağ, ödem ve lezyonların büyük kısmı bu sekansta açık, beyinde bulunan gri ve beyaz dokular ise karanlık görülmektedir.

2.3.4.3. T2*-ağırlıklı sekans

Bu sekansta TR zamanı T1 ve T2 gibi spin eko RF sinyalinin kullanıldığı sekanslardan daha kısadır. Bu sayede çok daha hızlı kullanılabilmektedir. Aynı zamanda süre kısalığından dolayı kayıplar artar ve hassaslık azalır. Beyin T2*-ağırlıklı sekansı Şekil 2.10(c)'de görülmektedir. Kan akımına hassas oldukları için MRA ve kan akışı ölçümlerinde kullanılabilir. Vücuda çok daha az RF enerjisi verildiği için yüksek manyetik alanlarda tercih edilmektedir. Bu sekansta kan, kemik ve kalsiyum içeren yapılar ve patolojik dokular karanlık görünmektedir.

2.3.4.4. Proton ağırlıklı sekans

T1 ve T2 ağırlıklı görüntüler çok fazla kontrast farkına sahip değildirler. RF sinyalleri kesildiği zaman dönen protonların dokudaki Proton ağırlıklı (Proton Density, PD) değerini belirlerken bu dönme miktarı da sinyal değişikliğine yol açar. Dokuların içerisindeki bulunan su ile PD sekansı doğru orantılıdır. Bu yüzden yağ gibi daha katı yapıda olan dokular daha düşük PD değerine sahiptirler. T1 ağırlıklı ve T2 ağırlıklı görüntülerde PD etkisi her zaman mevcuttur. PD sekansında T1 etkisini yok etmek için TR oldukça uzun seçilir ve T2 etkisini yok etmek için TE minimum seçilirse MR kontrat değerlerini belirleyen tek parametre dokulardaki PD değerleridir. PD sekansında MR sinyali yağ beyaz ve gri dokular sırasına göre artış göstermektedir. Beyin MR PD görüntüsü Şekil 2.10(d)'de gösterilmiştir.

2.3.4.5. Difüzyon MRG

T1 ve T2 dışındaki sekanslar kullanılarak dokuların mikroskobik düzeyde incelendiği bir yöntemdir. Görüntü kontrastı dokulardaki su molekülünün hareketine (Brownian hareketi) bağlıdır. Su molekülleri izotropik (rastgele hareket) olmalarına rağmen dokularda bulunan su molekülleri anizotropiktir. Anizotropik su molekülleri prensip

olarak sinirsel lifler boyunca hareket ederler. Dokuları su difüzyon hızları temel alarak karakterize etmektedir. Serebral iskemik alanların değerlendirilmesi, abse ile kistik ya da nekrotik beyin tümörünün ayrımında, menenjit komplikasyonu olarak gelişebilecek steril subdural effüzyonların ampiyemden ayrımında, çarpma, MS gibi nörolojik rahatsızlıklarda da etkin olarak kullanılabilmektedir. Beyin Difüzyon MRG Şekil 2.10(e)'de gösterilmektedir.

2.3.4.6. T1rho sekans

Kas-iskelet görüntülemede kullanılmak üzere geliştirilen bir MRG sekansıdır. Şu anda, çoğunlukla araştırma amaçlıdır ve henüz yaygın klinik kullanıma sahip değildir. Sekans, makromoleküller ve toplu su arasındaki düşük frekanslı etkileşimlere karşı hassastır ve ağırlıklı olarak kıkırdak görüntülemede kullanılmak üzere araştırılmaktadır. Diğer alanlardaki uygulamalar (örneğin beyin, kalp ve karaciğer görüntüleme) aktif araştırma alanlarını oluşturmaktadır. Çalışma mantığı T2-ağırlıklı sekans ile benzerdir. Farklı daha yavaş iki kutuplu etkileşimler sonucu yeniden odaklanma sağlanmasıdır.

2.3.4.7. FLAIR sekans

FLAIR(Fluid Attenuated Inversion Recovery) MRG, ters geri kazançlı sıvılardan sinyalleri boşaltmak için kullanılan bir sekanstır. Bu sayede beyin omurilik sıvısı (BOS) sinyallerini baskılamak için kullanılır. Böylelikle görülmesi zor olan dokular da görülebilir hale gelir. Bu sekans görüntülerinde BOS dışındaki diğer dokular daha parlak gözükür. Beyin FLAIR MR sekansı Şekil 2.10(f)'de verilmiştir.

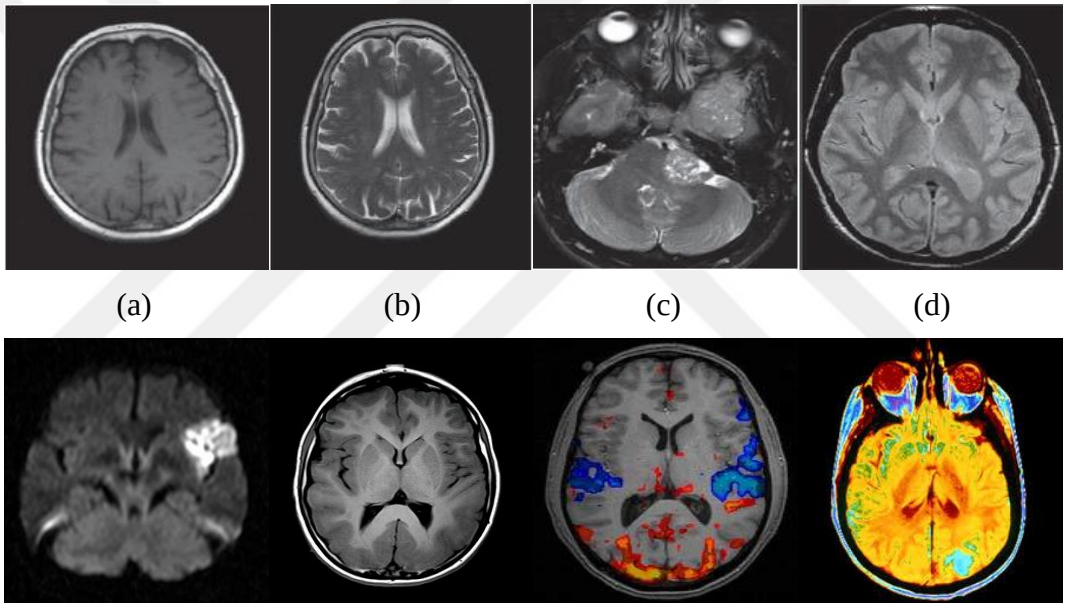
2.3.4.8. Fonksiyonel MRG

Fonksiyonel MRG (fMRG), sinirbilim çalışmalarında en çok tercih edilen bir görüntüleme tekniğidir. fMRI cihazları beyinde meydana gelen fonksiyonel değişimleri BOLD (Blood oxygenation level dependent, kan oksijenlenme seviyesine bağımlı) sinyalini ölçerek değerlendirmektedir. Sinir dokularındaki meydana gelen oksijen değişimleri T2* zamanında değişiklik getirir. Fonksiyonel MRG ameliyat esnasında veya ameliyat öncesinde hastanın hareket, hafıza ve konuşma kontrolünü

gözlemlemek için kullanılmaktadır. Şekil 2.10(g)'de örnek bir fMRG görüntüsü görülmektedir.

2.3.4.9.Manyetik rezonans perfüzyon

Kontrast madde kullanılarak beynin farklı tipteki dokularındaki kan miktarını gözlemlemek için kullanılmaktadır. Kontrast madde gadolinyumun beyin damarlarından ilk geçişi sırasında oluşturduğu hassasiyet T2* ağırlıklı MR sekansı ile görüntülenir. Bu yöntem ile genellikle en uygun biyopsi bölgesini belirlemek ve tümörlerin hızlı büyüme nedenleri belirlenmeye çalışılır. Şekil 2.10(h)'da örnek bir perfüzyon MR görüntüsü gösterilmiştir [61, 68-69].



(a) (b) (c) (d)

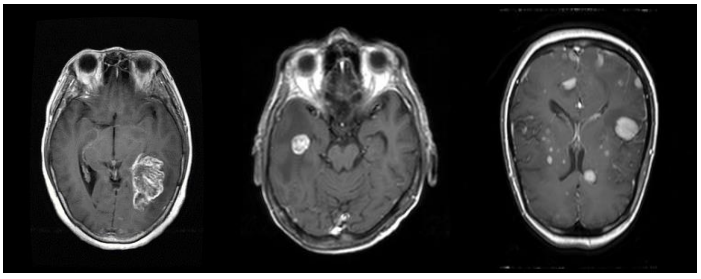
(e) (f) (g) (h)

Şekil 2.10. (a) T1-ağırlıklı, (b) T2-ağırlıklı, (c) T2*-ağırlıklı, (d) Proton ağırlıklı, (e) Difüzyon MRG (f) FLAIR, (g) Fonksiyonel MRG (h) Perfüzyon MRG

3. TEORİK BİLGİLER

3.1. Veri Seti

Bu tez çalışması kapsamında birincil (primer) tip glioma, ikincil (sekonder) tip olan akciğer ve meme kökenli metastatik beyin tümör tiplerinin sınıflandırılması gerçekleştirilmiştir. Çalışma kapsamında kullanılan verilerden metastatik beyin tümörleri Kocaeli Üniversitesi Tıp Fakültesi PACS sisteminden alınmıştır. Radyoloji doktorları tarafından tümörün belirgin olduğu en net kontrastlı T1-ağırlıklı (T1-C) sekansı belirlenmiştir. Tümörün belirli olduğu en net kesit alınarak metastatik tümörlerin veri seti oluşturulmuştur. Birincil tip glioma olan tümör görüntüleri ise 2005-2010 yılları arasında Guangzhou, Çin, Nanfang Hastanesi ve Çin, Tianjin Tıp Üniversitesi Genel Hastanesi'nden toplanan Beyin tümörü veritabanından elde edilmiştir [38, 70]. Kullanılan veri seti kontrastlı T1-ağırlıklı MRG görüntülerinden oluşmaktadır. Veri seti toplamda 233 hastadan alınmış 3064 kesitten oluşmaktadır. Bu kesitlerin 708 meningiomas, 1426 glioma, and 930 hipofiz (pituitary) tip tümör bulunmaktadır. Her kesitte tümör sınırları üç radyolog tarafından manuel olarak belirlenmiştir. Her MR diliminin boyutu standart 512×512 piksel ve sırasıyla 6 mm ve 1 mm'lik bir kalınlık kesit aralığındadır. Veri setinde ayrıca Medical College ve Hindistan Kolkata Hastanesi'nden deneyimli üç radyolog tarafından manuel olarak tanımlanmış ve doğrulanmış tümör sınırları bulunmaktadır. Şekil 3.1'de üç farklı tip örnek beyin tümörü görüntüsü verilmiştir.



(a) (b) (c)

Şekil 3.1. (a) Glioma, (b) akciğer, (c) meme metastazı tümör görüntüleri

3.2. İmge Pekiştirme (Gama Düzeltmesi)

Gama düzeltmesi, neredeyse tüm dijital görüntüleme sistemlerinin önemli bir özelliğidir. Bir pikselin sayısal değeri ile gerçek parlaklığı arasındaki ilişkiyi tanımlamaktadır. Gama düzeltmesi bir kameranın içeriği yakalama yöntemi, bir ekranın içeriği görüntüleme biçimi ve görsel sistemimizin ışığı işleme biçimi arasındaki farklılıkları düzeltmek için kullanılır. Standart bir monitörde gama olmadan, dijital kameralar tarafından yakalanan gölgeler gözümüze göründüğü gibi görünmez. Aynı zamanda gama düzeltme, gama kodlama veya gama sıkıştırma olarak da adlandırılır.

$$G = (L-1) \times \left(\frac{F}{(L-1)} \right)^{\gamma} \tag{3.1}$$

Denklem (3.1) kullanılarak görüntü konstratı gamma düzeltmesi ile iyileştirilebilir. Denklemde γ parametresi gama faktörünü, L maksimum gri seviyesi (256), F ise değiştirilmek istenen görüntüdeki piksel değerini göstermektedir. γ=1 ise eşleme doğrusal, γ<1 eşlemenin daha parlak çıkış değerlerine göre eşlenmesi, γ>1 ise piksellerin eşlenmesi daha koyu değerlere gerçekleştirilmektedir [71].

3.3. Yerel İkili Örüntüler

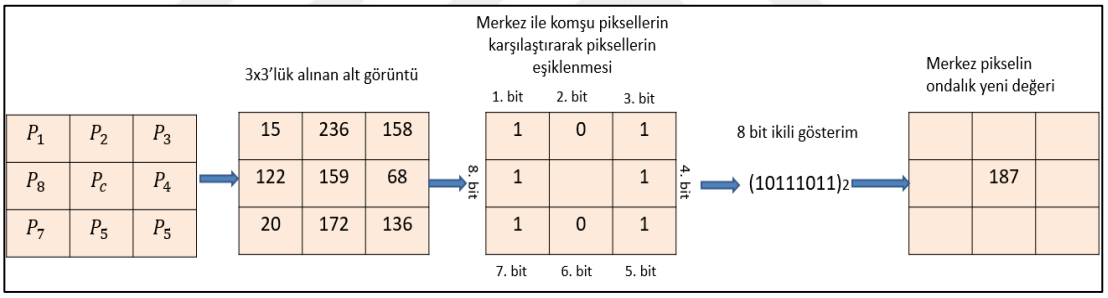
Yerel İkili Örüntüler (YİÖ) metodu görüntü işleme yöntemlerinde sıklıkla başvurulan istatistiksel bir yaklaşımdır. Ojala ve ekibi bu operatörü yerel görüntülerdeki kontrast düzeyini tanımlamak için kullanmışlardır. Görüntülerdeki ışık değişimlerine karşı hassas olmadığı için iki boyutlu gri seviyeli görüntülerde kullanılabilmektedir. Bu yöntem ile görüntülerden nitelikli öznitelik çıkarma işlemi gerçekleştirilebilmektedir. Bilgisayar görü uygulamalarında yaygın bir şekilde kullanılmaktadır [72-73].

YİÖ operatorü iki boyutlu bir görüntüdeki pikselleri kendi etrafındaki pikseller ile karşılaştırarak örüntüler elde etmektedir. YİÖ operatörü, 3×3 komşuluğunda merkez pikseli (P_C) ve etrafındaki pikselleri $(P_i) = (i = 0,1, \dots ,7)$ karşılaştırarak her piksel için ikili bir $S(f_P - f_C)$ değeri oluşturmaktadır [74]. Karşılaştırma sonucunda merkez piksel için ikilik tabanda yeni bir değer elde edilmektedir. İkilik tabanda elde edilen

bu değer onluk tabana dönüştürülerek merkez piksel bu onluk değer ile etiketlenmektedir. Daha sonra tüm görüntüdeki her piksel tek tek merkez piksel olarak kabul ederek tüm pikseller için yeni onluk etiketler oluşturulmaktadır. Bir pikselin etiketlenmesine YİÖ operatörü kullanarak gerçekleştirilen bir örnek Şekil 3.2'de verilmiştir. Görüntüdeki her piksel merkez piksel kabul edilerek komşuları arasındaki farkı alınarak basamak fonksiyonu ile ikilileştirilmesi ile YİÖ değerleri elde edilir (Eşitlik 3.2) [75].

$$\text{YİÖ}_{P,R}(X_c)=\sum_{p=0}^{p-1}\mu(X_p-X_c)2^p,\ \mu(y)=\begin{cases}1, & y\geq 0\\ 0, & y<0\end{cases} \tag{3.2}$$

$\text{YİÖ}_{P,R}$ biçimindeki operatörde, R yarıçapı komşu piksellerin merkez piksel ile arasındaki uzaklığını temsil ederken, P ise işleme alınan komşu piksel sayısını belirtmektedir [76]. Şekil 3.2'deki örnekte R yarıçap bir (1) alınırken, komşu sayısı P ise sekiz (8) alınmıştır.



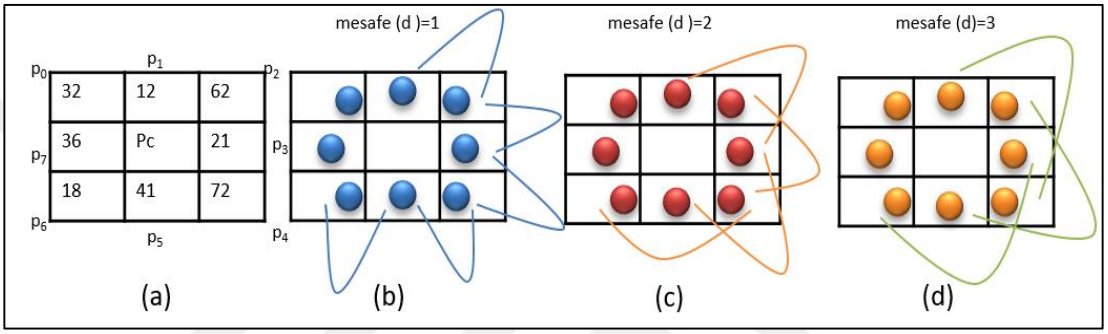
Şekil 3.2. YİÖ etiketlerinin oluşturulması

Görüntülerdeki yüzeylerinin büyük bir kısmı uniform örüntülerden oluşmakdır. İkili YİÖ kodunda 0'dan 1'e veya 1'den 0'a geçiş sayısı 2 veya daha az ise bu örüntüler uniform örüntülerdir. İkili kodunda 00000000 ve 11111111 örüntülerinde 0 geçiş sayısı, 01100000 ve 11000011 örüntülerinde 2 geçiş sayısı olduğundan bu örüntüler uniform örüntülerdir. Uniform örüntüler kullanılarak bir görüntüdeki kenar, spot, köşe gibi genel basit dokular belirlenebilmektedir [77-79].

3.3.1. Komşuluklarına göre yerel ikili örüntüler

Komşuluklarına göre yerel ikili örüntüler her pikselin etrafındaki komşuları arasındaki ilişkiye göre oluşturulmaktadır. Kısaltması dYİÖ olarak belirlenmiştir. Her merkez

pikselin P_c etrafındaki 8 komşu $(P_i) = (i = 0,1,\ldots,7)$ alınarak komşular arasındaki karşılaştırmalar sonucu elde edilen ikili (binary) dizinin onlu karşılığı olarak alınmaktadır. Karşılaştırmalarda bir piksel sonraki pikselden büyük ise "1", diğer durumlarda "0" olarak alınır. dYİÖ'nin mesafe belirten *d* harfi ile gösterilen bir parametresi bulunmaktadır. Bu parametre karşılaştırılacak ardışık komşular arasındaki mesafeyi belirtir. Farklı *d* parametre değerleri için farklı örüntüler elde edilmektedir. Şekil 3.3'te dYİÖ'nin farklı mesafelerden nasıl ikili desen örüntüleri oluşturduğunu gösteren örnekler verilmiştir [77].



Şekil 3.3. Komşuluklarına göre dYİÖ elde edilmesine bir örnek

Şekil 3.3(a)'da orijinal bir alt resim gösterilmektedir. Şekil 3.3(b), 3.3(c) ve 3.3(d)'de sırayla dYİÖ metodunda mesafenin 1, 2 ve 3 olduğu durumlarda karşılaştırılacak komşu pikselleri göstermektedir.

dYİÖ yöntemi her merkez piksel etrafında seçilen P adet piksele bağlıdır. (P_c) merkez piksel ve $(P_i) = (i = 0,1,\ldots,7)$ merkez pikselin etrafındaki komşular olmak üzere d=1, d=2 ve d=3 için örnekler verilmiştir.

$$T=(P_c, P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7) \tag{3.3}$$

$$P_c = S(P_0>P_1), S(P_1>P_2), S(P_2>P_3), S(P_3>P_4), \ldots. , \\ \ldots., S(P_4>P_5), S(P_5>P_6), S(P_6>P_7), S(P_7>P_0) \tag{3.4}$$

$$S(P_i > P_j)=\begin{cases}1 & P_i > P_j \\ 0 & P_i \leq P_j\end{cases} \tag{3.5}$$

Denklem (3.3)-(3.5) kullanılarak $P_i>P_j$ ise "1", diğer durumlarda "0" alınır.

Şekil 3.3(b)'a bulunan örneğin d=1 için dYİÖ'nin hesaplanma Denklem (3.6)-(3.8)'de gösterilmiştir.

$$P_c = 32>12|12>62|62>21|21>72|72>41|41>18|18>36|36>32 \tag{3.6}$$

$$P_c = 1,0,1,0,1,1,0,1 \tag{3.7}$$

$$P_c = (10101101)_2 = (173)_{10} \tag{3.8}$$

Şekil 3.3(c) için yani d=2 için dYİÖ'nin hesaplanması Denklem (3.9)-(3.12)'da verilmiştir.

$$\begin{aligned} P_c = {} & S(P_0>P_2), S(P_1>P_3), S(P_2>P_4), S(P_3>P_5), \ldots, \\ & \ldots, S(P_4>P_6), S(P_5>P_7), S(P_6>P_0), S(P_7>P_1) \end{aligned} \tag{3.9}$$

$$P_c = 32>62|12>21|62>72|21>41|72>18|41>36|18>32|36>12 \tag{3.10}$$

$$P_c = 0,0,0,0,1,1,0,0 \tag{3.11}$$

$$P_c = (00001100)_2 = (12)_{10} \tag{3.12}$$

Şekil 3.3(d)'de verilen d=3 için dYİÖ hesaplanması Denklem (3.13)-(3.16)'de gösterilmiştir.

$$\begin{aligned} P_c = {} & S(P_0>P_3), S(P_1>P_4), S(P_2>P_5), S(P_3>P_6), \ldots, \\ & \ldots, S(P_4>P_7), S(P_5>P_0), S(P_6>P_1), S(P_7>P_2) \end{aligned} \tag{3.13}$$

$$P_c = 32>21|12>72|62>41|21>18|72>36|41>32|18>12|36>62 \tag{3.14}$$

$$P_c = 1,0,1,1,1,1,1,0 \tag{3.15}$$

$$P_c = (10111110)_2 = (190)_{10} \tag{3.16}$$

Örneklerden görüldüğü gibi farklı *d* parametre değerlerine göre farklı örüntüler elde edilebilir.

3.3.2. Açılara dayalı yerel ikili örüntüler

YİÖ'nün arkasındaki temel fikir, bir görüntünün mikro örüntülerden oluştuğunu varsayılmasıdır. Bu mikro desenlerin histogramı, bir görüntüdeki yerel özelliklerin dağılımı hakkında bilgi içermektedir. Açılara dayalı yerel ikili örüntüler (αYİÖ) operatörü her pikselin değerini bir açı α değerine göre hesaplamaktadır [77]. Açı değerleri (α=0, 45, 90 ve 135) derecelerinden biri olmaktadır. Bir açı değerine göre merkez pikselin (P_c) üzerinden çizilen düzlem üzerinde kalan komşular (P_i={P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7} değerlendirilmektedir. Merkez pikseli, çizilen düzlem üzerinde kalan komşularla karşılaştırılarak yani P_c>P_i ise 1, diğer durumlarda 0 olarak etiketlendirilerek elde edilen ikili dizgenin onluk değeri merkez pikselin değeri olarak alınmaktadır. αYİÖ değeri Denklem (3.17) ile hesaplanmaktadır. αYİÖ hesaplanmasına ilişkin örnek Şekil 3.4'te verilmiştir.

$$\alpha\text{Y}\dot{\text{I}}\text{Ö} = \sum_{i=0}^{P} u(P_i - P_c)2^i \tag{3.17}$$

Şekil 3.4'te gösterildiği gibi iki yatay ve iki dikey dört farklı açı için YİÖ operatörü hesaplanmaktadır. Farklı açılara göre hesaplanan YİÖ operatörleri birbirinden farklılık göstermektedir.

Örüntülerin farklı açılar ile aranması αYİÖ yönteminin farklı doku özellik çıkartma problemlerinde başarı sağlayacağı düşünülmektedir. Şekil 3.4'e göre farklı açılara göre elde edilen αYİÖ operatörleri aşağıda hesaplanmıştır.

α=0 için αYİÖ örüntüleri Denklem (3.18)-(3.21) kullanılarak bulunabilir.

$$\begin{aligned} P_c = {} & S(P_0>P_c), S(P_1>P_c), S(P_2>P_c), S(P_3>P_c), \ldots, \\ & \ldots, S(P_4>P_c), S(P_5>P_c), S(P_6>P_c), S(P_7>P_c) \end{aligned} \tag{3.18}$$

$$\begin{aligned} P_c = {} & S(207>215), S(245>215), S(245>215), S(255>215), \ldots, \\ & \ldots, S(171>215), S(167>215), S(136>215), S(109>215) \end{aligned} \tag{3.19}$$

$$P_c = 0,0,0,0,1,1,1,0 \tag{3.20}$$

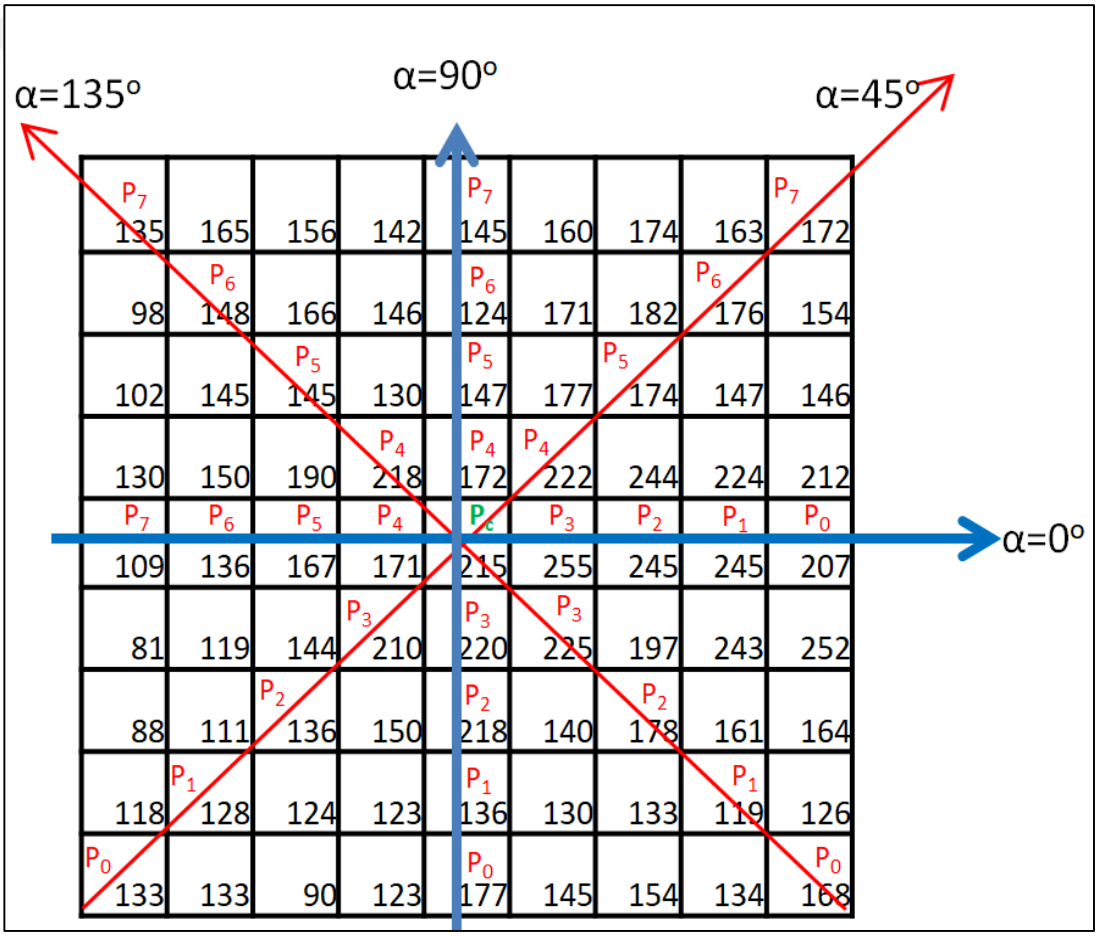
$$P_c = (00001110)_2 = (14)_{10} \tag{3.21}$$

α=45 için αYİÖ örüntüleri Denklem (3.22)-(3.24) kullanılarak bulunabilir.

$$P_c = S(133>215), S(128>215), S(136>215), S(144>215), \ldots, \ldots, S(222>215), S(174>215), S(176>215), S(172>215) \tag{3.22}$$

$$P_c = 0,0,0,1,0,0,0,0 \tag{3.23}$$

$$P_c = (00010000)_2 = (16)_{10} \tag{3.24}$$



Şekil 3.4. Açı tabanlı YİÖ

α=90 için αYİÖ örüntüleri Denklem (3.25)-(3.27) kullanılarak bulunabilir.

$$P_c = S(177>215), S(136>215), S(218>215), S(220>215), \ldots, \ldots, S(172>215), S(147>215), S(124>215), S(145> 215) \tag{3.25}$$

$$P_c = 0,0,0,0,1,1,0,0 \tag{3.26}$$

$$P_c = (00001100)_2 = (12)_{10} \tag{3.27}$$

α=135 için αYİÖ Denklem (3.28)-(3.30)'de olduğu gibi hesaplanabilmektedir.

$$\begin{aligned} P_c = {} & S(168>215), S(119>215), S(178>215), S(225>215), \ldots, \\ & \ldots, S(218>215), S(145>215), S(148>215), S(135>215) \end{aligned} \tag{3.28}$$

$$P_c = 0,0,0,1,1,0,0,0 \tag{3.29}$$

$$P_c = (00011000)_2 = (24)_{10} \tag{3.30}$$

3.4. Makine Öğrenmesi Yöntemleri

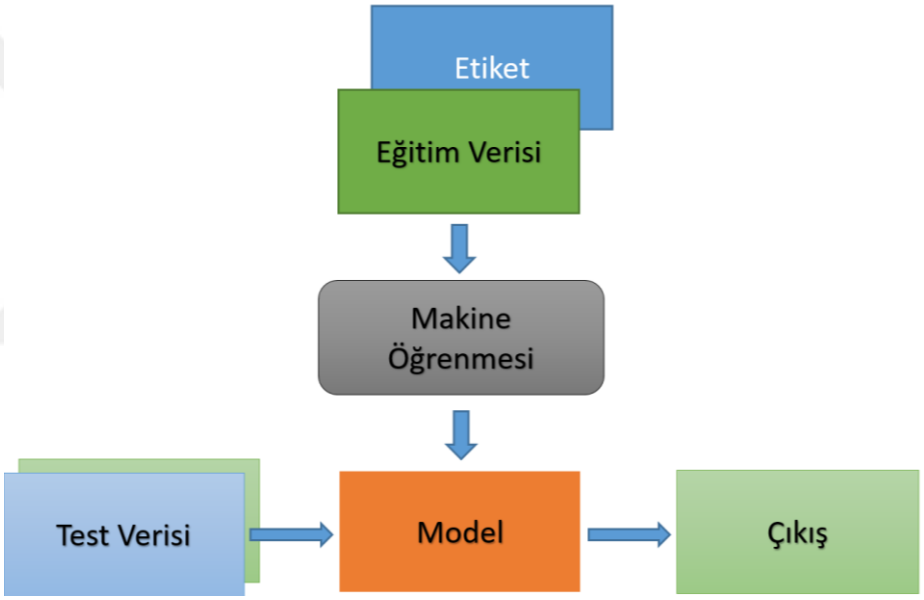
Günümüzdeki en büyük bilgi kaynaklarından bir tanesi de yıllarca birikmiş ve tecrübe edilmiş verilerdir. Yirminci yüzyılın ikinci yarısında, makine öğrenimi, tahmin yapmak için verilerden bilgi türeten kendi kendine öğrenen algoritmaları içeren Yapay Zekânın (Artificial Intelligence, AI) bir alt dalı olarak geliştirilmiştir. İnsanların büyük miktarda veriyi analiz ederek manuel olarak kurallar türetmesini ve modeller oluşturmasını zorunlu kılmak yerine, makine öğrenimi tahmine dayalı modellerin performansını kademeli olarak iyileştirmek ve veriye dayalı kararlar almak için verilerdeki bilgileri yakalamak için daha verimli bir alternatif sunmaktadır. Makine öğrenmesi verileri kullanırken üç kısma ayırır. Eğitim verisi oluşturulan makine öğrenmesi modelini eğitmek için kullanılan veri, doğrulama (validation) verisi model eğitim aşamasında modelin performansını ölçmek ve varsa eğitim parametrelerini optimize etmek için kullanılan veri, test verisi ise model eğitim aşamasını geçtikten sonra modelin başarını ölçmek için kullanılan veridir. Şekil 3.5'te model oluşturulması ile ilgili aşamalar verilmiştir. Makine öğrenmesi yöntemleri sınıflandırma, regresyon, kümeleme ve boyut indirgeme problemlerinde kullanılabilmektedir [80].

Üç çeşit makine öğrenmesi yöntemi vardır:

- Denetimli Öğrenme (Supervised Learning): Kurulan modele giriş verileri ve bu verilerin çıkışları (etiketleri), modelin bu giriş ve çıkış arasında bir bağıntı oluşturması

için verilir. Daha sonra başka bir veri ile model test edilir. Bilinen en basit yöntem olarak eğri uyduma yöntemi örnek verilebilir.

- Denetimsiz Öğrenme (Unsupervised Learning): Bu modelde giriş verisine çıktısı (etiketleri) verilmeksizin veriler arasında bir örüntü bulması istenmektedir. Bu yöntemlere genellikle kümeleme, olasılık tahmini ve boyut indirgeme işlemlerinde kullanılmaktadır.
- Takviyeli Öğrenme (Reinforcement Learning): Model içinde bulunduğu dinamik ortamı algılar ve belirli bir hedefe ulaşmak için doğru kararlar almayı amaçlar. Doğru kararlar verdiğinde sistemi ödüllendirirken yanlış kararlarda cezalandırır. Bu şekilde denenen durumların doğru veya yanlış olduğu bulunmaktadır [81].



Şekil 3.5. Makine öğrenmesi uygulama şeması

3.4.1. k-en yakın komşuluk

k-en yakın komşuluk (k-Nearest Neighbor, k-NN) hem sınıflandırma hem de regresyon problemlerinde kullanılabilen en basit makine öğrenmesi yöntemlerinden birisidir. k-NN parametrik olmayan yani veri dağılımın olasılıksal yoğunluklarının bilinmediği durumlarda sınıflandırma veya regresyon analizi gerçekleştirmek için geliştirilmiştir. Başka bir deyişle model yapısı veri setinden belirlenir. Bu durum gerçek dünyadaki veri kümelerinin çoğunun matematiksel teorik varsayımları takip etmediği uygulamalarda çok yardımcı olmaktadır. Tembel (Lazy) algoritma, model

üretimi için herhangi bir eğitim veri noktasına ihtiyaç duymadığı anlamına gelir. k-NN uygulaması basit uygulanabilir, gürültülü verilerine karşı etkili, eğitim verisi büyük ise algoritmanın daha etkili çalışabilmektedir. Tüm eğitim verileri test aşamasında kullanılır. Bu nedenle eğitim süreci hızlanır ve test aşaması daha yavaş ve daha maliyetli hale gelir. Maliyetli test aşaması zaman ve bellek anlamına gelir. k-NN yönteminin en büyük dezavantajı, k-NN'nin tüm veri noktalarını taraması için daha fazla zamana ihtiyacı vardır ve tüm veri noktalarını taramak, eğitim verilerini depolamak için daha fazla bellek gerektirmesidir. Ayrıca *k* parametresine ihtiyaç duyması en iyi sonuç için hangi uzaklık metodunun uygulanacağı açık değildir.

1951 yılında k-NN algoritması Fix ve Hodges tarafından örüntü sınıflandırma da kullanılmak üzere tanıtılmıştır. Daha sonra 1967 yılında Cover ve Hart k-NN algoritmasının biçimsel özelliklerini belirlemişlerdir. Bu çalışmalarda olan k=1 ve $n \rightarrow \infty$ için k-NN sınıflandırma hatasının Bayes hata oranının iki katı ile sınırlandırıldığı gösterilmiştir [82]. k-NN sınıflandırmasının bu tür biçimsel özellikleri oluşturulduktan sonra, yeni reddetme yaklaşımları 1970'te Hellman tarafından, Bayes hata oranının iyileştirilmesi 1975'te Fukunaga ve Hostetler tarafından, mesafe ağırlıklı yaklaşımlar 1976'da Dudani ile, 1978'te Bailey ve Jain tarafından, bulanık yöntemler 1983'te Jozwik tarafından, 1985'te Keller vd. tarafından, esnek hesaplama yöntemleri 2000'de Bermejo ve Cabestany tarafından geliştirilmiştir [83-84].

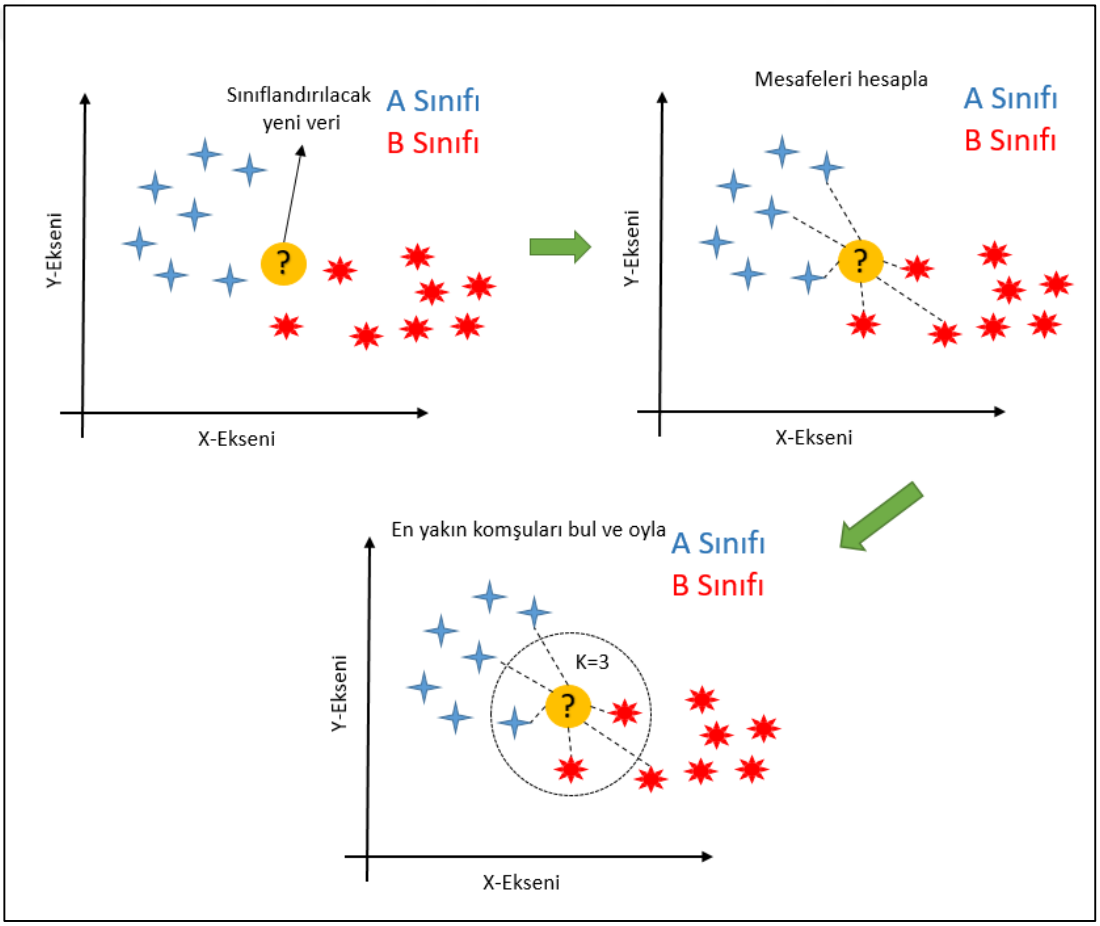
k-NN algoritmasında k parametresi en yakın komşu sayısını belirlemektedir. Birbirine yakın nesnelerin aynı kategoriye alınması ile sınıflandırma işlemi gerçekleştirilmektedir. Test verileri en yakınlarındaki k adet komşular ile uzaklığı hesaplanarak sınıf etiketlerine bakılarak sınıflandırılır. Bu uzaklıklar bir bellekte kaydedilir. Daha sonra k adet uzaklıktaki eğitim verisi hangi sınıfa ait ise test verisi o sınıfa ait olarak oylanır ve bu test verisine o sınıf etiketi verilir. Şekil 3.6'da k-NN algoritmasına örnek bir uygulama bulunmaktadır. k-NN algoritması uygulama aşamaları aşağıdaki gibidir:

- Rastgele bir k parametresi belirlenir.
- Bu parametre doğrultusunda test noktasının k adet en yakın komşuları belirlenir.
- Test noktası ile belirlenen noktalar arasındaki uzaklık hesaplanır.

- Uzaklık hesaplanırken n boyutlu $x = (x_1, x_2, \ldots, x_n)$ ve $M = (m_1, m_2, \ldots m_n)$ noktaları arasındaki Öklid uzaklığı Denklem (3.31)'deki gibi hesaplanır.

$$\sqrt{\sum_{i=1}^{n} (x_i - m_i)^2} = \sqrt{(x_1 - m_1)^2 + (x_2 - m_2) + \ldots + (x_n - m_n)} \tag{3.31}$$

- Denklem (3.31)'deki uzaklıklar hesaplandıktan sonra ek küçük k adet uzaklık seçilir.
- Seçilen k adet örnek arasında en çok hangi sınıf etiketi var ise test edilen yeni veri oy çokluğu yöntemi ile en çok olan sınıf etiketi ile etiketlenir [85].



Şekil 3.6. k-NN sınıflandırma algoritması

3.4.2. Rastgele orman

Rastgele orman (Random Forest, RO) yöntemi denetimli bir sınıflandırma ve regresyon algoritmasıdır. RO, verileri ikili biçimde sınıflandırmak için kuralları

kullanan karar ağaçlarına dayalı bir yöntemdir. 1963 yılında Morgan ve Sonquist karar ağaçları ile RF modelinin temelini oluşturmuş ve Breiman 2001 yılında (Classification and Regression Tree, CART) sınıflandırma ve regresyon ağaçları yöntemi ile RO modeli sınıflandırma problemlerinde kullanılmaya başlanmıştır [86].

Sınıflandırma problemlerinde, verileri bölmek için kullanılan ana kurallar Denklem (3.32) ve Denklem (3.33)'te yer alan G_{ini} ve regresyon kriterleridir. Denklem (3.32)'da y_l ve y_r sırasıyla sol ve sağ düğümlerde bulunan verilerin ortalamasını göstermektedir. Denklem (3.33)'te N_l ve N_r sırasıyla sağ düğümde ve sol düğümde bulunan elemanların sayılarını p_{kl} ve p_{kr} parametreleri ise sırasıyla sağ ve sol bölümlerdeki sınıfların oranıdır.

$$R_{ss} = \sum_{sol}\left(1 - p_{k1}\right)^2 + \sum_{sağ}\left(y_i - y_r\right)^2 \tag{3.32}$$

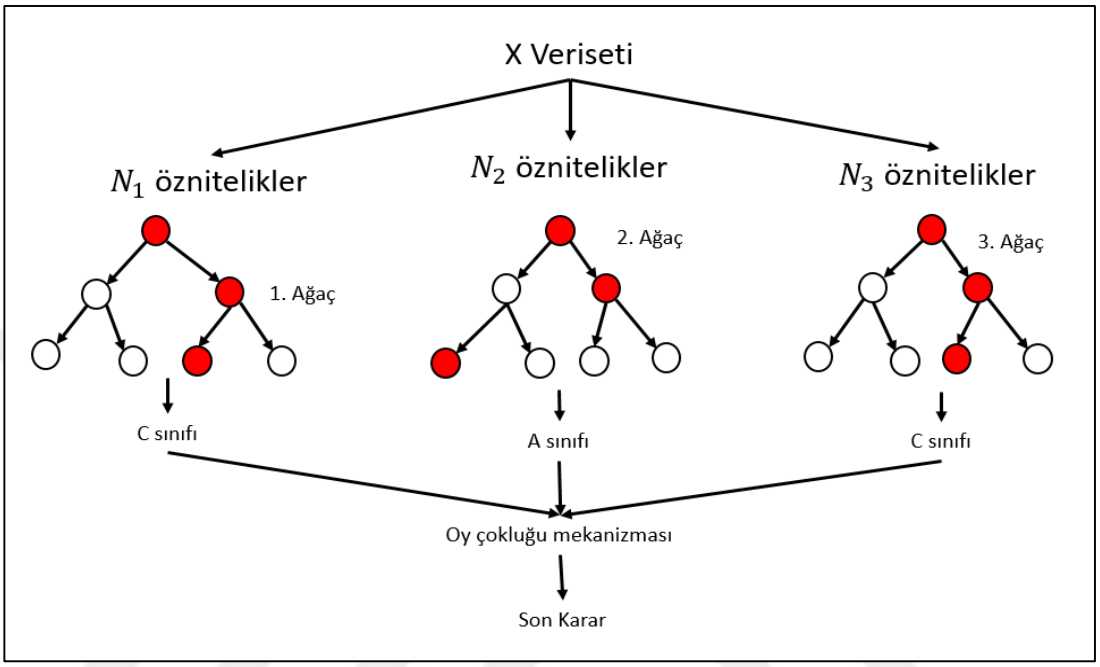
$$G_{ini} = N_l \sum_{k=1}^{K} p_{kl}\left(1 - p_{k1}\right) + N_r \sum_{k=1}^{M} p_{kr}\left(1 - p_{kr}\right) \tag{3.33}$$

Rastgele ormanlar, birçok sınıflandırma ve regresyon ağacı oluşturmak için yinelemeli bölümlemeyi kullanır ve ardından sonuçları bir araya getirir. Her ağaç, eğitim verilerinden bir önyükleme örneği kullanılarak bağımsız olarak oluşturulur. Rastgele ormanın son tahminleri, her bir ağacın tahminlerinin ortalaması alınarak yapılır. Çok sayıda karar ağacı için bu tür oylama mekanizması, az miktarda eğitim verisi, hızlı eğitim (training), daha az manuel müdahale, gürültülü ve eksik değerli verilere karşı sağlamlık içeren eğitim modellerini kolaylıkla oluşturabilir. Böylelikle modelin tahmin doğruluğu da iyileşmiştir olur.

Eğitim aşamasında X'in eğitim veri setindeki objeleri temsil ettiği göz önüne alındığında (bir N×M matrisi, burada N eğitim verilerinin sayısı ve M, her verinin boyutudur); L bir N×1 matrisin eğitim setinin etiketlerini temsil eder. Ntree, ormandaki ağaç sayısı anlamına gelen topluluk büyüklüğünü temsil eder. θ_k (rastgele ormanlardaki her rastgele ağaç, k = 1, 2, ... , Ntree); M_{try}, bölünmek üzere rastgele seçilen özelliklerin sayısını temsil eder. RO, birden çok karar ağacı sınıflandırıcıdan oluşan bütünleşik bir sınıflandırıcıdır ve Denklem (3.34)'teki gibi tanımlanabilir:

$$h(X, \theta_k), \qquad k = 1, 2, \ldots, N_{tree} \tag{3.34}$$

Spesifik olarak her ağaç Şekil 3.7'deki gibi ve aşağıdaki maddeleri kullanarak oluşturulabilir.



Şekil 3.7. X veri seti için örnek bir RO yapısı

1. Algoritma, sağlanan veri kümesinden rastgele örnekler seçer. Örnekler ne kadar çok rastgele olursa örneklerin biribirine olan korelasyonu azalacağı için elde edilen sonucun doğruluğu artar.
2. Orijinal eğitim veri setinden Ntree adet karar ağacı önyükleme setlerini değiştirerek (torbalama, bagging) çizilir. Eğitim örneklerinin yaklaşık üçte ikisi ağacı büyütmek için kullanılır ve diğer üçte biri eğitim adımına paralel olarak çapraz doğrulama gerçekleştirmek için kullanılır. Torba dışı numuneler (Out of Bagging, OOB numuneleri) model performansının bir tahminini elde etmek için kullanılabilir.
3. Her önyükleme için budanmamış bir ağaç yetiştirilir. Bununla birlikte, her düğümde rastgele Mtry değişkenlerini seçilir ve G_{ini} indeksinin en düşük sonucunu sağlayan en iyi bölünme seçilir. Ağaç, budanmadan daha fazla bölünme mümkün olmayana kadar büyütülür [87].

3.4.3. Destek vektör makineleri

Vapnik yapısal risk minimizasyonu yöntemleri ve istatistiksel öğrenme teorisini temel alarak kümeleme, yoğunluk tahmini, öğrenme, sınıflandırma ve regresyon problemlerinde kullanılmak üzere Destek Vektör Makineleri (DVM) modelini geliştirmiştir. İstatistiksel öğrenme teorisi, gözlemlenen verilerden bir model ile verinin sağlam yapısını bir matematiksel model ile temsil ederek bir sınıflandırma modeli oluşturmayı amaçlamaktadır. Bu teori ile girdilere karşılık gelen çıktılar eşlenerek sınıflandırılabilmektedir. İstatistiksel öğrenme teorisinde veri eğitim ve test olarak ayrılmaktadır. Boustquet istatistiksel öğrenme yönteminin temelini elde bulunan veri kümesinden bir model oluşturup bu model doğrultusunda karar verme çerçevesi oluşturmaya dayandırmaktadır [88].

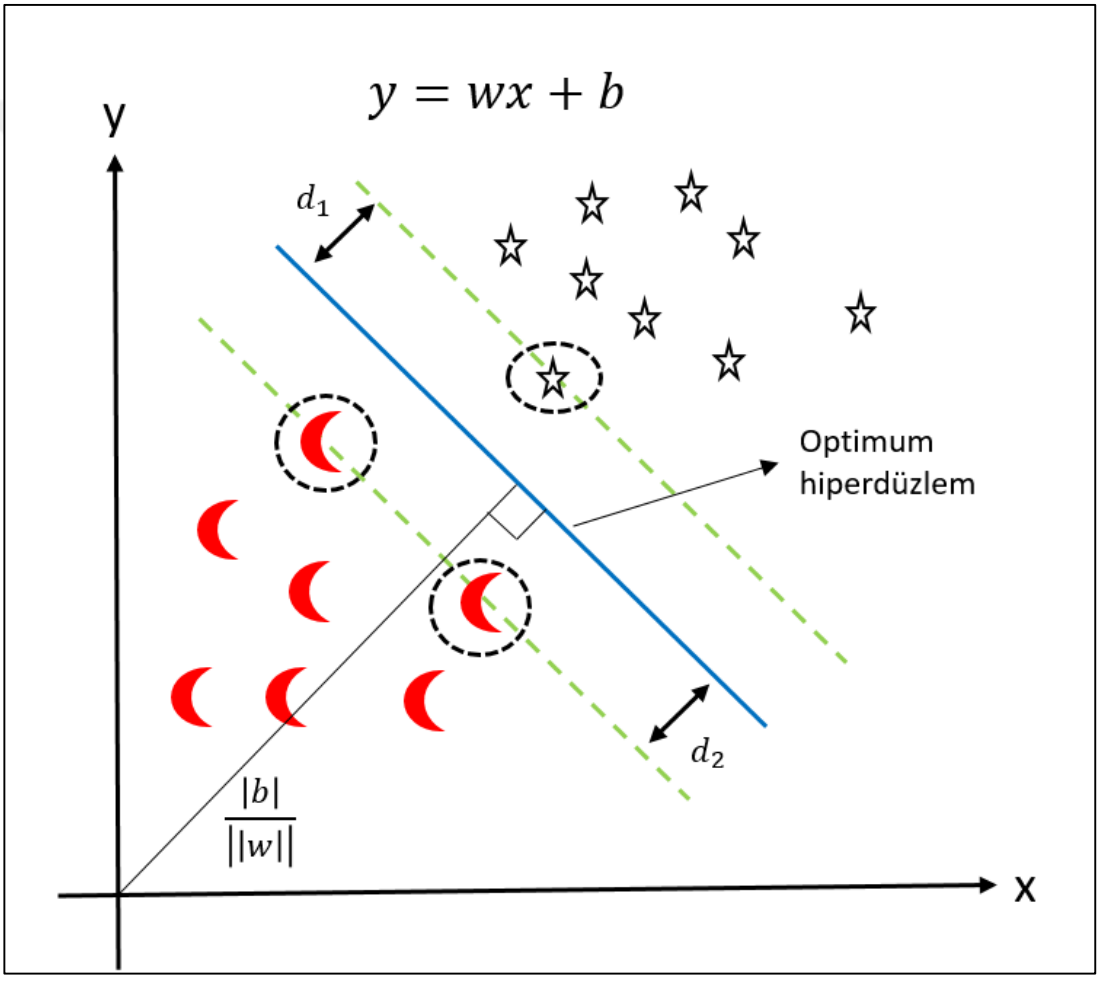
DVM modelindeki amaç ikili sınıflandırmalarda iki sınıfı birbirinden ayıran en uygun hiperdüzlemin fonksiyonun oluşturulmasıdır. Burges'e göre en uygun hiperdüzlem ilgili durumların hiperdüzlemin bir tarafında diğerlerinin bir tarafa alınması ile farklı sınıfların destek vektörlerine olan uzaklıklarının maksimuma ulaştırılması ve deneysel sınıflandırma hatasının minimize edilmesi ile gerçekleştirilmektedir. Destek vektörleri, iki sınıfı verilerinden en yakın iki örneğin arasındaki mesafeyi maksimize eden aynı zamanda hiperdüzleme en yakın vektörlerdir [89].

DVM sınıflandırıcıları, veri setinin doğrusal veya doğrusal olmayarak ayrılmasına göre temel olarak ikiye ayrılmaktadır. DVM eğitimi için kullanılacak N elemanlı $\{x_i, y_i\}$ veri kümesi i=1, 2, …, N olsun. Burada $x_i \in R^p$ p adet niteliğe sahip giriş vektörü ve bu girişlere karşılık gelen $y_i \in \{-1, 1\}$ çıkış değerleridir. Doğrusal sınıflandırma durumunda, iki değer alan çıktı değerleri doğrusal bir hiperdüzlem ile ayrılabilecektir.

Denklem (3.35)'e eğitim kümesi $S = \{(x_1,y_1), (x_2,y_2), \ldots, (x_n,y_n)\}$ verildiğinde, bu denklem bu eğitim kümesi için uygun ağırlık vektörü w ve eşik değeri b hesaplayarak eğitim kümesinin doğrusallığına karar verecektir.

$$y_i=(wx_i+b)\geq 1 \qquad i=1, 2, \ldots, N \tag{3.35}$$

Denklem (3.35) genel bir ifade ile yazılırsa wx+b=0 eşitliği elde edilir ve iki vektör arasında bulunan en optimal hiperdüzlem için gerekli sınırlar çizilir. Bu sınırlar destek vektörlerini oluşturur. Şekil 3.8'de yeşil çizgiler sınırları, mavi çizgi en optimum hiperdüzlemi ve yeşil çizgiler ile mavi çizgiler arasında yer alan işaretli uzaklıklar ise destek vektörlerini göstermektedir. En uygun hiperdüzlem sınır çizgilerine iki eşit d uzaklığında bulunur. Elde edilen hiperdüzlemin boyutu ayırmak istenen uzayın boyutundan bir eksiktir. Hiperdüzlem, iki boyutlu düzlem için bir doğru, üç boyutlu uzay için bir düzlem, çok boyutlu uzaylar için hiperdüzlem olmaktadır [90].



Şekil 3.8. Optimum hiperdüzlem ve destek vektörleri

Destek Vektör Makinelerinin temel amacı Şekil 3.8'de görülen d uzaklığını maksimize etmek ve mavi çizgi ile gösterilen en uygun hiperdüzlemi elde edilen destek vektörlerinin ortasına yerleştirmektir. Sınırda bulunan iki farklı veri arasındaki uzaklık d=2/||w|| formülü ile bulunabilir. Bu uzaklık aynı zamanda hiperdüzlem ortasında yer

aldığı için birbirine eşit olan d_1 ve d_2 destek vektörlerinin toplamıdır. $\|w\|^2$ değerinin minimize edilerek bu iki sınırın birbirine olan maksimum uzaklığı bulunur.

Maksimum sınır Denklem (3.36) amaç fonksiyonunun, Denklem (3.37) kısıt fonksiyonuna göre çözülmesi ile bulunabilir. Bu doğrusal olmayan problemin çözümünde Lagrange Çarpanları yönteminden yararlanılmaktadır.

$$\text{Amaç fonksiyonu: Min } \frac{1}{2}\|w\|^2 \tag{3.36}$$

$$\text{Kısıt: } y_i=\left(wx_i+b\right)\geq 1 \tag{3.37}$$

Lagrange Çarpanları yöntemi bu problemi çözmek için temelleri Cortes, Vapnik tarafından daha sonra son hali Burges'in çalışmaları ile bulunmuştur. Bulunan Lagrange fonksiyonu Denklem (3.38)'deki gibi elde edilmiştir.

$$L_p\left(w,b,\alpha\right)=\frac{1}{2}\|w\|^2 - \sum_{i=1}^{n}\alpha_i\left[y_i\left(wx_i\right)+b\right]+\sum_{i=1}^{n}\alpha_i \tag{3.38}$$

Burada her bir $\alpha_i \geq 0$ eşitliği Lagrange çarpanlarını vermektedir. L_p fonksiyonunda, Lagrange çarpanlarını maksimize eden *w* ağırlık vektörü, *b* sabiti ise minimize eden bir fonksiyondur. Karush-Khun-Tucker (KKT) koşullarını elde etmek için fonksiyon *w* ve *b* değerlerine göre türevleri alınır ve sıfıra eşitlenir. Sonuç olarak Denklem (3.39) ve Denklem (3.40)'daki KKT koşulları elde edilir.

$$w=\sum_{i=1}^{n}y_i\alpha_i x_i \tag{3.39}$$

$$w=\sum_{i=1}^{n}y_i\alpha_i \tag{3.40}$$

Elde edilen KKT koşulları (3.38)'de yerine yazılarak ve optimizasyon problemi en maksimize tipindeki eşitliğe dönüşür. Her eğitim verisine özel bir tane Lagrange çarpanı Denklem (3.41) eşitliği, Denklem (3.42) eşitliğindeki kısıt ile altında çözüldüğünde elde edilir. Gunn 1998 yılında yaptığı çalışmalarda sınfırrdan büyük

Lagrange çarpanlarını destek vektörleri olarak adlandırmıştır. Destek vektörleri sıfırdan farklı ise sınırların üzerinde, sıfıra eşit ise sınırların dışında bulunmaktadır [91].

$$L_D(w,b,\alpha) = \sum_{i=1}^{n} \alpha_i + \frac{1}{2} \sum_{i=1}^{n} \sum_{j=1}^{n} \alpha_i \alpha_j y_i y_j \left(x_i x_j \right) \tag{3.41}$$

$$\sum_{i=1}^{n} y_i \alpha_i = 0 \tag{3.42}$$

3.4.4. Lojistik regresyon

Lojistik Regresyon (Logistic Regression, LR) analizi istatistiksel uygulamalarda, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi tanımlayabilmek amacıyla geliştirilmiş alternatif yöntemlerden birisidir. Sonuç değişkeninin kesikli olmasına oldukça çok sık karşılaşılmaktadır. Günümüzde böyle bir analiz yapmak için lojistik regresyon modelinin kullanılması ilk akla gelen standart bir analiz yöntemidir. Lojistik regresyon analizinin kullanım amacı diğer istatistiksel modellerde olduğu gibi, en az sayıda bağımsız değişkeni kullanarak en optimum çözüm ile bağımlı ve bağımsız değişkenler arasındaki ilişkiyi tanımlayabilen mantıklı bir model kurmaktır. Lojistik regresyon modelini, klasik doğrusal regresyon modelinden ayıran en büyük fark, lojistik regresyon modelinde bağımlı değişkenin binary (0-1 değer alan) veya iki değer alan değişken olmasıdır [92].

Lojistik Regresyon (LR) analizi ile bağımlı değişkenin bağımsız değişkenlere olan bağımlılığının belirlenmesinde kategorik olarak ikili, üçlü veya çoklu kategorilerde gözlenmesinden yararlanan bir tekniktir [93]. Aynı zamanda LR bağımlı değişkenin kategorilere sahip olduğundan bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini olasılıksal olarak açıklar. LR modeli doğrusal olmadığı için uygun methodlar ile doğrusallaştırılabilir [94]. LR analizi regresyon analizinden üç yönden ayrılmaktadır.

1. Doğrusal Regresyon (DR) analizinde tahmin edilecek bağımlı değişken sürekli iken, LR analizinde bağımlı değişken ayrık değerler almaktadır.

2. DR analizinde bağımlı değişkenin değeri, LR ise bağımlı değişkenin alabileceği değerlerden birinin gerçekleşme olasılığı kestirilir.
3. DR analizinde bağımsız değişkenlerin çoklu normal dağılım göstermesi gerekirken, LR analizinin için bağımsız değişkenler ile ilgili bir dağılıma gerek duyulmaz [92].

Çok değişkenli istatistiksel yöntemler üç gruba ayrılabilir:

1. Kümeleme analizi: Gözlemlerin yapıları itibariyle, kendi içlerinde belirli özelliklere göre sınıflara ayrılması amacıyla kullanılan bir tekniktir. Sınıflandırma, değişkenlerin birbirlerine olan uzaklıkları göz önüne alınarak yapılabilmektedir.
2. Diskriminant (Ayırma) analizi: Değişkenlere ait grupların belirli olduğu durumlarda kullanılan bir tekniktir. Amaç, gözlemleri verilerin yapısında bulunduğu düşünülen gruplara atayarak bir sınıflandırma modelinin elde edilmesidir.
3. Lojistik regresyon (LR) analizi: Kümeleme analiz modelinde gözlemlerin etiketleneceği grupların sayısı net değilken, diskriminant ve LR analizinde grup sayısı bilinmekte, veriler kullanılarak bir ayrımsama modeli elde edilmektedir. Kurulan bu model yardımı ile veri kümesine her eklenen yeni gözlemlerin hangi gruplara etiketlenmesi gerektiği belirlenmektedir. Bu üç yöntemden diskriminant analizi sık kullanılan ve çok bilinen yöntem olup varsayımları daha fazla ve zordur. LR analizi bir kısım varsayımlar(normallik, ortak kovaryansa sahip olma gibi) olmadığı zaman diskriminant analizi ve çapraz tablolara alternatif olarak kullanılabilirler. Bağımlı değişken ayrık değişken ise, normallik varsayımının ön koşul olması gerekmediği için kolay bir şekilde kullanılabilir [95].

LR analizinin, DR analizine göre üstün olmasını sağlayan, gerçekleşmesi gerekmeyen bağımlı ve bağımsız değişkenler arasındaki ilişki doğrusallığı, hata terimlerinin ve bağımlı değişkenin normal dağılıma uygunluğu, homojen varyansa sahip olma, gibi varsayımlardır. Ancak istatistiksel bir teknik olduğundan Lojistik Regresyon Analizinin sağlaması gereken varsayımlar şöyle sıralanabilir:

1. Matematiksel modelin doğru belirlenmesi: Gelecek tahmini yapabilmek için değişkenleri matematiksel kalıba oturtmaya çalışırken ortaya çıkar.
2. Çoklu doğrusal bağlantı olmamalı: Çoklu doğrusal bağlantı bağımsız değişkenler arasında yüksek bir ilişkinin olmasıdır. Bu varsayımın gerçekleşmemesi tahmin

sonucunu ciddi biçimde etkiler. Eğer bağımsız değişkenler arasında ilişki varsa, Lojistik Regresyon denklemine ait katsayıların standart hataları büyür. Çoklu doğrusal bağlantı, katsayıların tahmininde yanlılığa sebep olmasa da katsayıların standart hataları arttığı için güvenilirliği etkiler. Ayrıca Regresyon Analizinde çoklu doğrusal bağlantı probleminin testi olan VIF, Belirleme katsayısı aracılığıyla hesaplanır; ancak Lojistik Regresyon analizinde belirleme katsayısı için doğrudan bir karşılık olmadığı için hesaplanamaz.

3. Bağımlı ve bağımsız değişkenler arasındaki doğrusallık: Bağımsız değişken(ler)le bağımlı değişken arasındaki ilişki doğrusal değildir. Zaten lojistik regresyon analizi, doğrusallık varsayımını gerektirmez. Ancak lojistik regresyon denkleminin lojit dönüşümü, doğrusallaştırma işlemini barındırdığı için doğrusallık şartı arar. Bu sebeple varsayımın gerçekleşmemesi, bağımlı ve bağımsız değişken(ler) arasındaki ilişkilerin açıklanma gücünü düşürür.

4. Hata terimlerinin bağımsız olması: Bu analiz yönteminde de hata terimlerinin arasında otokorelasyon olmamalıdır; yani hata terimlerinde birbirinden bağımsız olma şartı aranmaktadır.

5. Gözlem sayısı, tahmin edilecek parametre sayısından fazla olmalıdır.

LR modelleri bağımlı değişken yapısına göre üçe ayrılmaktadır:

• İkili (Binary) LR analizi: Bağımlı değişkenin iki kategoriliden oluşmuş olup olumlu-olumsuz, başarılı-başarısız, evet-hayır şeklinde ifadelere olanak veren LR analizinin uygulandığı bir yöntemdir.

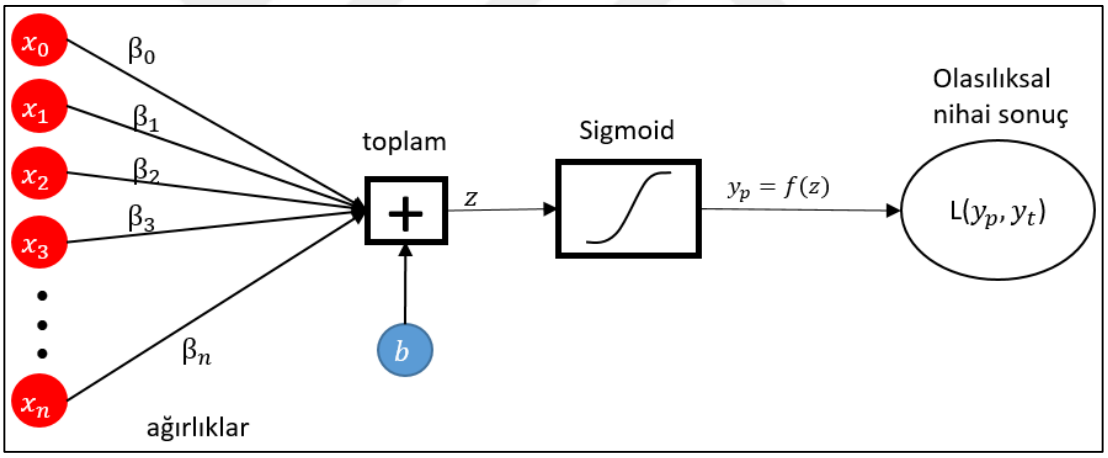
• İkiden çok kategorili (Multinominal) LR analizi: Bağımlı değişken ikiden çok kategoriye sahip ancak bu kategoriler arasında herhangi bir sıralama bulunmuyorsa kullanılabilir

• Sıralı (Ordinal) LR analizi: Bağımlı değişkeni çok kategorili yapıda olduğu ve bu kategoriler arasında sıralama olan analiz yöntemidir.

İlk LR modeli, Berkson tarafından 1944, 1953, 1955 yıllarında biyolojik deneylerin analizi için yaptığı çalışmalarında gösterilmiştir. 1962 yılında Cornfield LR modelindeki katsayı kestirimlerinde diskriminant fonksiyonu yaklaşımını ilk kez kullanmıştır. LR modelini Cox 1970 yılında yaptığı çalışmasında çeşitli uygulamalar

gerçekleştirmiş, Halpering ve ark. ise 1971 yılında LR analizinin, bağımsız değişkenlerin normal dağılıma uymadığı durumlarda diskriminant analizine alternatif olabileceğini göstermişlerdir. Finney ise 1972 yılında LR analizini probit regresyon analize alternatif olarak sunmuştur. Bonney 1987 yılında lojistik regresyon modelinin kullanımı ve geliştirilmesi üzerinde çalışmışlar gerçekleştirmiştir. Daha sonra aynı yıl Robert v.d. LR analizinde standart ki-kare, olabilirlik oran, pseudo, en çok olabilirlik tahminleri, uyum iyiliği ve hipotez testleri üzerinde çalışmışlardır. 1995 yılında Hsu ve Leonard LR fonksiyonlarında Bayes tahminlerinin elde ederek Monte Carlo dönüşümünü kullanmışlardır [96].

LR yöntemi bağımsız değişken(ler) arasında en iyi ilişkiyi bulmayı amaçlayan bir makine öğrenmesi yöntemidir. LR modelleri genelde ikili (binary) (evet-hayır, hasta-sağlıklı, kadın-erkek vb.) sınıflandırmalarda kullanılır. Lojistik regresyonda en az değişken ile en sade model oluşturulması amaçlanır.



Şekil 3.9. Lojistik regresyon modeli

Şekil 3.9'da örnek bir lojistik regresyon modeli verilmiştir. Burada x_1, x_2, x_3, …, x_n, değerleri giriş öznitelik verilerini, β ağırlık katsayısını, b bias değerini ve y ise çıkış değerini temsil etmektedir.

$$z_m = \sum_{i=1}^{n} \beta_i \times x_i + b \tag{3.43}$$

Giriş her x_i özniteliği başlangıçta rastgele belirlenen β_i ağırlığı ile bias (b) değeri Denklem (3.43)'teki gibi eklenir. Bulunan z_m fonksiyon değeri sigmoid aktivasyon

denklemi olan Denklem (3.44)'ten geçirilerek ve modelin olasılıksal nihai tahmin ettiği çıkış (y_p) değeri bulunur. Bulunan çıkış değeri her defasında güncellenir. LR yönteminde optimum ağırlık değerlerini bulmak için geri yayılım yöntemi kullanılmaktadır. Tahmin edilen çıkış (y_p) ve hedef çıkış (y_t) arasındaki kayıp fonksiyonu (loss function) Denklem (3.45)'teki gibi hesaplanır.

$$y_p = \frac{1}{1 + e^{z_m}} \tag{3.44}$$

$$L\left(y_p - y_t\right) = - \left(y_t \times \log\left(y_p\right) + \left(1 - y_t\right) \times \log\left(1 - y_p\right)\right) \tag{3.45}$$

Kayıp fonksiyonu bulunduktan sonra hata fonksiyonunun β ağırlık katsayısı minimum hata olacak şekilde En Çok Olabilirlik Yöntemi, Yeniden Ağırlıklandırılmış İteratif En Küçük Kareler Yöntemi, Minimum Logit Ki-Kare Yöntemi vb. yöntemler ile tahmin edilir. Bulunan bu ağırlık değerleri ile model eğitim aşaması tamamlanmış olur. Daha sonra eğitim verisinden farklı test verileri ile modelin bu ağırlık ve bias değerlerine göre çıkışı bulunur. Böylelikle sistemin performansı ölçülmüş olur [97].

3.4.5. Yapay sinir ağları

İnsan beynindeki öğrenme sistemde yer alan birbiriyle bağlantılı sinir hücreleri Yapay Sinir Ağları (YSA) için ilham kaynağı olmuştur. YSA, insan beyninin öğrenme fonksiyonun matematiksel olarak modellenmesi ile geliştirilmiştir. 1943 yılında Warren McCulloch ile Walter Pitts insan beyninin matematiksel kabiliyeti ile elektrik devrelerinden oluşan ilk temel bir YSA modeli geliştirmişlerdir. YSA uygulamada ilk olarak biyolojik sinir hücrelerinin (nöronların) modellenmesi ve bilgisayar sistemleri üzerinde kullanılması ile başlamıştır. Bir sinir ağı, öğrenme yoluyla elde edilen veriyi ağırlıklar yardımıyla birleştirerek, kullanılabilir hale getiren işlemcidir [98].

YSA modeli, sinir hücreleri arasında ilişki kuran, ilişkilerden sonuç çıkaran ve sonuçları test ederek optimize eden bir sistemdir. Bir sinir ağı, sinir hücreleri arasındaki ilişkinin belirlenmesi, bağlantı ağırlıklarının belirlenmesi ve aktivasyon fonksiyonundan oluşmaktadır. YSA'lar, ağırlık katsayıları ile birbirlerine bağlı birçok sinir hücrelerinin bir araya gelmesiyle oluşan matematiksel sistemlerdir. Sinir

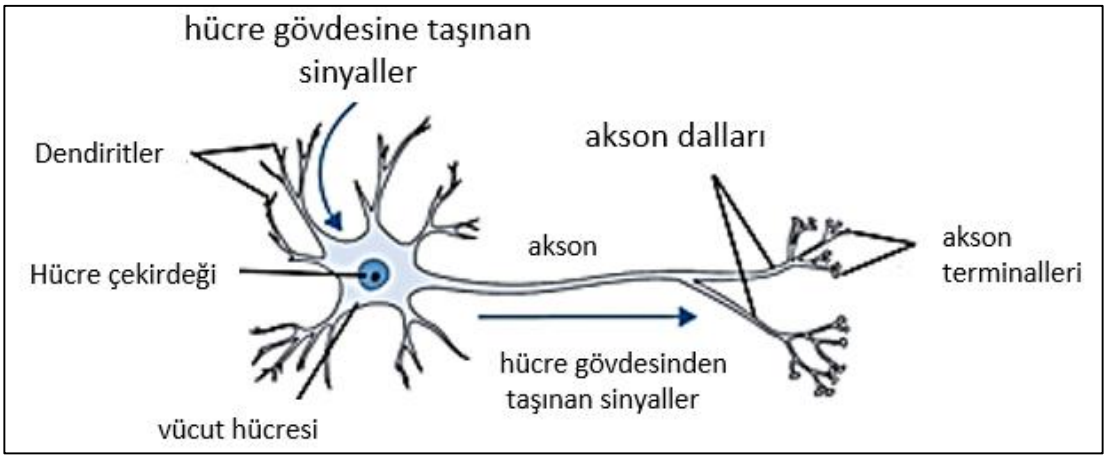
hücreleri, diğer sinir hücrelerinden aldığı sinyalleri birleştirir ve doğrusal olmayan bir şekle dönüştürerek sayısal bir sonuç elde eder. Sinir hücreleri bir ağ içinde birbirlerine bağlanırak sinir ağlarını oluştururlar. Bütün ağ yapıları sinir hücrelerinden veri arlarak sonuç üreten sinir hücrelerine sahiptirler [99-100].

YSA mimarisinde matematiksel modeller ile üretilen çıktıların doğruluk düzeyinin maksimum eden ağırlık değerleri hesaplanır. YSA eğitim verisini ile giriş değişkenleri ile tahmin ettiği değişkenler arasındaki ilişkiyi ağırlıklar ile belirler. Bu ilişkileri belirledikten sonra (eğitim aşaması), YSA test verileri ile test aşamasına geçebilir. Eğitme işleminin amacı optimum çözüme ulaşmaktır. YSA ağ yapısında bağlantı ağırlıkları adaptif olarak değiştirilerek daha iyi sonuçlar verebilmeleri amaçlanır. Ağ yapısındaki çok sayıdaki düğüm veya sinir hücreleri birbirine paralel çalıştığı için paralel dağıtılmış işlemciler olarak adlandırılırlar [101].

YSA öğrenme, sınıflandırma, tahmin, genelleme, özellik belirleme ve optimizasyon gibi problemlerde kullanılabilmektedir. Sistem modelleme, arıza tespiti, hata analizi, ses tanımlama, nesne sınıflandırma, ekonomik tahmin, kestirimci bakım, vb. konularda YSA'lar günümüze kadar etkin bir şekilde kullanılmıştır [102].

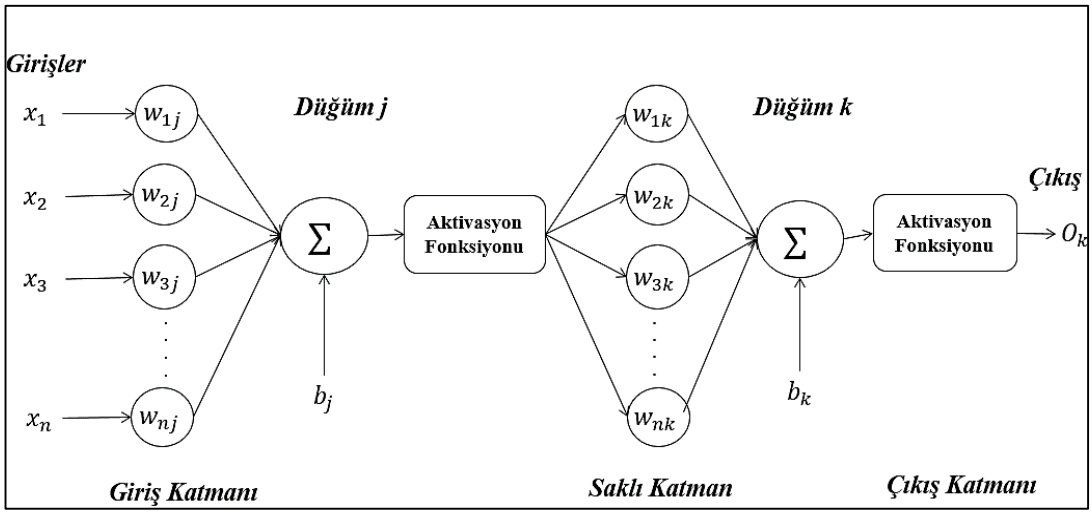
İnsanın beyninde bulunan bir sinir hücresi, dış kaynaklardan gelen sinyalleri alır, birleştirir, analiz eder ve sonucu bulur. Şekil 3.10 bir sinir hücresinin genel anatomik yapısı ve bu yapıda yer alan elemanlar arasındaki bağlantıyı göstermektedir. Dentritler, sinyallerin girdiği kanallardır. Diğer sinir hücrelerinden sinyalleri aralarındaki bağlantı ağırlık katsayıları ile kabul ederler. Çekirdek, gelen bu sinyalleri zaman içinde işleyerek bir çıktıya dönüştürür. Bu çıkan sinyal akson ve aralarındaki bağlantı ağırlıkları ile diğer sinir hücrelerine gönderilir [101].

Yapay sinir ağlarında yer alan yapay sinir hücreleri, biyolojik sinir hücrelerinin dört temel fonksiyonuna benzerler. Bir yapay sinir hücresinin temel yapı taşlarını girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış değerleri oluşturur. Şekil 3.11'de genel bir YSA modelinin mimarisi gösterilmektedir. Bu yapıya göre girişte bulunan sinir hücreleri girdileri almak, çıkışta bulunan sinir hücreler ise çıktıları dış ortama iletmek için görevlidirler. Aralarında kalan sinir hücreler ise gizli katmanda bulunular ve sadece ağ içersinde bağlantı kurabilirler.



Şekil 3.10. Biyolojik sinir hücresinin genel yapısı

Ağlar Şekil 3.11'de görüldüğü gibi giriş katmanı, gizli katman(lar) ve çıkış katmanından oluşmaktadır. Giriş katmanı, veri kümesinden öznitelik değerlerini alır ve bu değerleri gizli katmana iletir. Çıkış katmanı ise çıktıları dışarıya bir sonuç üretir. Giriş ve çıkış katmanları tek katman gizli katmanlar ise bir veya birrden fazla katmandan oluşabilir. Bu gizli katmanlar içerisinde çok sayıda birbirleri ile bağlı sinir hücresi içerirler. Genellikle gizli katmandaki bir sinir hücresi bir önceki katmanın tüm sinir hücrelerinden sinyal alarak işlemden geçirir ve çıktısını bir sonraki tabakanın tüm sinir hücrelerine gönderir. Böylece bir ileri besleme yolu oluşturulur [102].



Şekil 3.11. YSA katmanları

McCullogh ve Pitts biyolojik sinir hücrelerini basit bir matematiksel model ile göstermişlerdir. Bu matematiksel modelin fonksiyonel gösterimi Denklem (3.46) numaralı eşitlikteki gibidir.

$$y_i = \psi\left(g\left(x\right)\right) = \psi\left(\sum_{j=0}^{n} w_{ij}x_j - Q_i\right);\ x_i = \left(x_0, x_1, ..., x_n\right) \tag{3.46}$$

Denklem (3.48)'de, $\psi(.)$ birim basamak transfer (aktivasyon) fonksiyonunu, y_i çıkış değerini, $g(.)$ toplama işlemini, w_{ij} bağlantı ağırlık katsayılarını ve Q_i ise i. sinir hücresinin eşik değerini belirtmektedir.

$$\psi(.) = \begin{cases} 1 & g(.) \geq 0 \\ 0 & g(.) < 0 \end{cases} \tag{3.47}$$

Denklem (3.47)'de $g(.)$ toplama fonksiyonu olduğundan x_j gösterimi girişlerin doğrusal bir bileşimini temsil etmektedir.

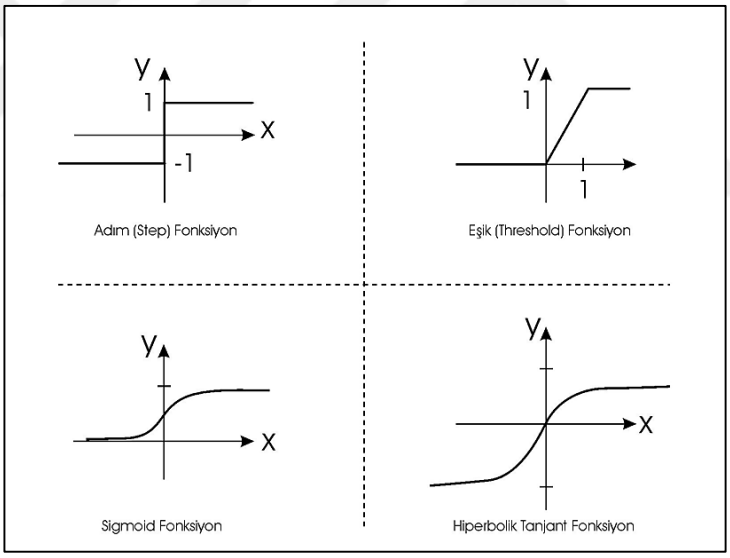
$$g(.) = \sum_{j=0}^{n} w_{ij}x_j - Q_i \tag{3.48}$$

Giriş değerler ilk olarak rastgele birer ağırlıkla ağırlıklandırılmaktadır. Her girdinin kendi nispi ağırlığı vardır. Ayrıca, ağırlıklar girdinin bağlantı gücünü belirleyen adaptif katsayılardır. Ağırlıklar, bilginin gösteriminde rol almasından dolayı ağın performansını etkileyen önemli bir faktördür. Ağırlıkların oluşturulmasında bazı temel kurallar kullanılmaktadır [100]:

- Benzer sınıflardan gelen girdiler aynı kategoride yer alacak şekilde sınıflandırılmalıdır.
- Ayrı sınıflarda yer alacak girdilerin ağdaki gösterimleri arasında önemli farklılıklar olmalıdır.
- Bir öznitelik önemli ise, bu özniteliği temsil eden birim sayısı daha fazla olmalıdır ki, birim sayısının fazla olması karar vermede etkili rol oynar ve hata durumlarına karşı tolerans sağlar.
- Önsel bilgiler ağ tasarımı sırasında kullanılmalıdır.

Ağırlıklandırma işleminden geçen giriş verileri toplama fonksiyonuna gönderilirler. Toplama fonksiyonu farklı işlemlerle bir hücreye iletilen girdilerin doğrusal birleştirilmesi yoluyla net girdileri hesaplar. Toplama fonksiyonunun en uygununu

(çarpımlar toplamı, minimum, maksimum, mod, çarpım veya çeşitli normalleştirme işlemleri) bulmak için belirli bir yöntem olmadığından deneme yanılma yöntemi kullanılmaktadır [102]. Belirlenen ağ mimarisi girdileri birleştirecek olan algoritmayı belirler. Belirlenen fonksiyonlar farklı değerler üretir ve sonra bu değerler ileri yönde gönderilir. Bazı toplama fonksiyonları ilave işlemler sonucunda girdiyi transfer (aktivasyon) fonksiyonuna iletir. Toplama fonksiyonu çıkışları aktivasyon fonksiyonu ile zamana bağlı olarak değişir. Transfer fonksiyonu, toplama fonksiyonundan aldığı değeri gerçek bir çıktı olarak üretir. Doğrusal fonksiyonlarda çıktı ile girdi orantılı olduğundan, transfer fonksiyonunda genellikle doğrusal olmayan bir fonksiyon kullanılır. Şekil 3.12'de en çok kullanılan eşik, sigmoid, hiperbolik tanjant (tanh) vb. transfer fonksiyonları gösterilmiştir. Transfer fonksiyonu sonuçta genellikle giriş değerinin olasılıksal çıktısını üretilir. Bu çıktı değeri dışarıya veya başka sinir hücresinin girişi olarak başka bir sinir hücresine iletilmektedir.



Şekil 3.12. Bazı transfer fonksiyonları

Geri yayılma şeklindeki bağlantı tipi bir katmanın çıktısının önceki katmana gönderilmesi ile oluşturulur. Şekil 3.11'deki gibi temel bir YSA hücresi için oluşturulan Denklem (3.46)'daki eşitlik Denklem (3.49)'daki gibi genelleştirilerek yazılabilir. Denklem (3.49)'daki eşitlikte tek bir yapay sinir hücrenin matematiksel gösterimini vermektedir. Bir sinir ağı, birçok sinir hücresinden oluştuğundan bu matematiksel gösterim genelleştirilmelidir. n tane giriş için modellenen bir sinir ağı yapısı, giriş katmanında n+1 adet sinir hücresi, çıkış katmanında ise bir adet sinir

hücresi bulundurur. Sinir ağı gizli katman içermiyorsa ağın fonksiyonel gösterimi tek sinir hücreli gösterim ile aynıdır. Sinir ağında gizli katman içeriyorsa sinir hücresi sayısı artacağından fonksiyonel yapı değişecektir. Bir gizli katmanlı ağ yapısının Denklem (3.50) gibi gösterilebilir.

$$y_i = \psi\left(g\left(x\right)\right) = \psi\left(w + \sum_{j=0}^{n} w_j x_j\right);\ x_i = \left(x_0, x_1, ..., x_n\right) \in \Re \tag{3.49}$$

$$y_k = f_k\left(\alpha_k + \sum_{j\to k} w_j f_j\left(\alpha_j + \sum_{i\to j} w_{ij} x_j\right)\right) \tag{3.50}$$

Denklem (3.50)'deki eşitlikte y_k parametresi çıkış değerlerini, f_k çıkış katmanı transfer fonksiyonunu, α_k çıkış katmanına ait sapma değerini, w_j çıkış katmanına ait ağırlıkları, f_j gizli katmana ait transfer fonksiyonunu, α_j sapma değerini, x_i giriş değerlerini, w_{ij} ise i. giriş elemanını j gizli elemanına bağlayan ağırlık katsayısını göstermektedir. İki gizli katman için Denklem (3.51)'deki eşitlikteki gibi olacaktır.

$$y_i = f_i\left(\alpha_l + \sum_{k\to l} w_l f_k\left(\alpha_k + \sum_{j\to k} w_{jk} f_j\left(\alpha_j + \sum_{i\to j} w_{ij} x_j\right)\right)\right) \tag{3.51}$$

Ağ yapısı oluşturulduktan sonra eğitim aşamasına geçilinebilir. Eğitim aşamasında deneyim yoluyla öğrenme özelliği kazanılmaktadır. Çünkü bu aşamada, problem için en uygun bağlantı ağırlık katsayıları belirlenmektedir. Girdiler ve çıktılar arasındaki ilişki bilinmediğinden esnek bir ağ ile başlanır ve bu ağ veriye uygun hale getirilir. Başlangıçta ağırlıklar rastgele olarak verilirerek eğitim (training) işlemi başlar. Amaç, eldeki girişler için toplam hatası minimum olan ağı oluşturmaktır. Eğitme işleminde kullanılan danışmanlı ve danışmansız olmak üzere iki yaklaşım vardır. Danışmanlı eğitmede hem giriş hem de çıkış verileri işleme alınır. İlk başta rastgele başlangıç ağırlıklarını ile girişler işlenerek çıkış üretilir ve istenilen çıkış arasında karşılaştırma yapılır. Hesaplanan hatalar geri gönderilir ve bu hata değerlerine göre bağlantı ağırlık katsayıları güncellenir. Bu işlem eğitim aşaması bitene kadar defalarca tekrarlanır ve bağlantı ağırlıkları her defasında güncellenir [101]. Gerçek değer ile modelin elde

ettiği değer arasındaki fark hata olarak kabul edilir. Bu yöntemin başlıca amacı, eğitim sürecinin hata oranının önceden belirlenen değerden daha az olana kadar devam etmesidir [104].

Danışmansız yaklaşım aynı zamanda adaptif eğitme olarak da bilinir. Bu yaklaşımda, danışmanlı yaklaşımda olduğu gibi ağa girişler bulunur fakat bu girişlere karşı olan çıkışlar bulunmaz. Sistem giriş verilerini sınıflandırmak için giriş verisinin hangi özelliklerinden yararlanacağına karar verir. Bu yöntem kendi kendine öğrenme veya adaptasyon olarak bilinir [100].

Öğrenme YSA'ların önemli özellik ve avantajlarını oluşturduğu için önemli bir yere sahiptir. Bir YSA'da öğrenme, ağın bir probleme için en gerçekçi çıktıyı elde edebilecek en iyi ağırlık değerlerinin bulunmasıdır. Bu nedenle öğrenme süreci YSA yapısındaki elemanlara bağlıdır. Bu elemanlardan ilki olan öğrenme fonksiyonu her işlem elemanının girişlerine ait bağlantı ağırlık katsayılarını belirlemektedir. Adaptasyon fonksiyonu diye adlandırılan bu fonksiyon giriş bağlantı ağırlık katsayılarını istenilen sonucu elde edene kadar değiştirilmelerini sağlamaktadır. İkinci önemli öğrenme elemanı olan hata fonksiyonu tahmin edilen çıkış ile istenilen çıkış arasındaki farkı hesaplayarak hata miktarını bulur ve gerekli durumlarda geri yayılma algoritması ile hatayı minimize etmeye çalışır.

Öğrenme elemanlarından bir diğeri ise öğrenme sürecinin hızı ve işlevi açısından oldukça önemli olan öğrenme oranıdır. Sinir ağlarının öğrenme kabiliyeti ile hızı arasında ters orantılı bir ilişki vardır. Öğrenme oranı ile ağın ne kadar eğitileceği belirlenir. Ağın karmaşıklık düzeyi, büyüklüğü, yapısı, kullandığı öğrenme kuralı ve beklenilen doğruluk derecesi öğrenme oranını belirler [101].

Öğrenme probleminin çözümü için ağırlıkların nasıl güncellendiğini gösteren öğrenme kuralları kullanılır. Avantajları ve dezavantajları olan birçok öğrenme kuralı vardır. Öğrenme kuralları farklı ağ yapıları için değişkenlik göstermektedir [105].

Hebb 1949 yılındaki çalışmasında öğrenmenin nasıl çözüleceğini incelemiştir. İlk öğrenme kuralı olarak bilinen Hebb kuralı, iki sinir hücresi arasındaki bağlantının sinirlerin aynı anda etkileşmesine bağlı olduğunu ifade eder. Kurala göre, iki sinir

hücresi matematiksel olarak aynı işaretli yani aktif ise bağlantı güçlendirilmeli, ters işaretli yani pasif ise bağlantı zayıflatılmalıdır. Bilinen birçok öğrenme kuralı Hebb kuralının geliştirilmesi yoluyla meydana gelmiştir. Hebb kuralına benzeyen Hopfield kuralında, ağırlıkları güçlendirilmesi veya zayıflatılması 0 ile 1 arasında değer alan sabit bir öğrenme katsayısı yardımıyla yapılmaktadır. En küçük kareler olarak da bilinen Delta kuralı ise, beklenen çıkış ile tahmin edilen çıkış arasındaki farklılığı azaltmak için, bağlantı ağırlıklarının sürekli değiştirilmesi temeline dayanmakta ve Hebb kuralının geliştirilmiş halidir. Kohonen kuralı, bir ağda yer alan sinir hücrelerinin çıktılara olan etkilerinin hesabına dayanmaktadır. Bu kuralda en büyük çıktıyı veren sinir hücresinin bağlantı ağırlıkları güçlendirilmektedir [102]. Beklenen çıktı ile gerçekleşen çıktı arasındaki farkın yerine iki sinir hücresinin çıktılarının korelasyonları arasındaki farkı kullanan Boltzman kuralı, delta kuralının özel bir halidir [103].

Genel olarak YSA modeli oluşturulurken ağ yapısının seçilmesi, sinir hücrelerinin özelliklerinin belirlenmesi ve öğrenme kuralının seçilerek parametrelerin belirlenmesi başlıca adımlardır. Ağ yapısı seçilirken, ağda yer alan katman sayısı ve her katmanda yer alacak sinir hücreleri sayısının belirlenmesi önemlidir, ancak bu sayıların seçilmesinde kullanılacak kesin bir kural henüz bulunamamıştır. Genellikle, bu sayılar deneme-yanılma yöntemi ile oluşturulur. YSA modeli oluşturulurken, ağ parametrelerinin belirlenmesi ağ performansını etkilediğinden önemli bir konudur. Ancak bu konuyla da ilgili kesin bir çalışma yoktur. Transfer fonksiyonun seçimi için bazı kurallar mevcuttur ve problemin yapısına göre değişmektedir. Öngörü problemlerinde hiperbolik tanjant, sınıflandırma problemlerinde ise sigmoid fonksiyonlarının kullanımı önerilmiştir [107].

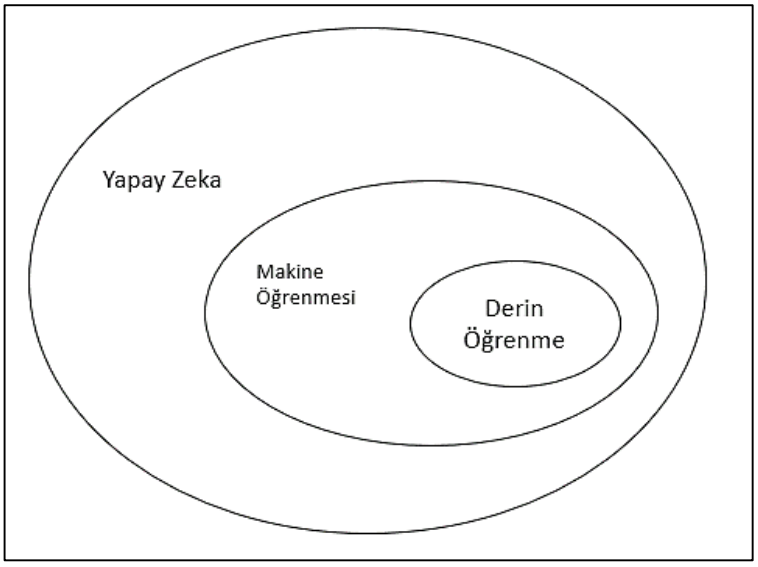
Model oluşturulurken dikkat edilmesi gereken hususlardan biri de verinin işlenmesidir. Veri setinde uç değerler bulunabileceğinden verinin ölçeklendirilmesi gerekir [102]. YSA'da veriler eğitim ve test verisi olmak üzere ikiye ayrılır. Eğitim verisi ağın oluşturulması ve eğitilmesi için test seti ise modelin değerlendirilmesi için kullanılır. Genellikle, test setinin büyüklüğü eğitim setinin %10'u ile %30'u arasındadır. Eğitim setindeki gözlem sayısının en az kabul edilen hata oranının ağ parametreleri ile çarpımı kadar olmalıdır [100].

Ağda bağlantı ağırlıkları belirlenirken performans ölçütleri olarak Hata Kareler Ortalaması (HKO), Ortalama Mutlak Hata (OMH), Ortalama Mutlak Yüzde Hata (OMYH) ve Hata Kareler Toplamı (HKT) yöntemleri kullanılır [107]. Uygulamada, birçok problem için hata fonksiyonu olarak Hata Kareler Toplamı (HKT) kullanılmaktadır ve Denklem (3.52)'deki eşitlikte gösterilmektedir [105].

$$HKT = \sum_{girdiler} \sum_{çıktılar} \left(beklenen\,çıktı - gerçekleşen\,çıktı \right)^2 \tag{3.52}$$

3.5. Derin Öğrenme

Derin öğrenmenin derinliği, ardışık katmanlar fikrinden ortaya çıkmıştır. Bir veri modeline kaç katman ile başarılı olabiliyorsa modelin derinliği bu katmanlardan derinliğinden anlaşılabilir. Diğer bir deyişle derin öğrenme katmanlı etiketlerin öğrenilmesi ve hiyerarşik etiketlerin öğrenmesi olarak adlandırılabilir. Modern derin öğrenme algoritmaları genellikle onlarca hatta yüzlerce ardışık gizli katman içerir. Gizli katman sayısını arttıkça karmaşık problemler için model daha uygulanabilir hale gelir. Derin öğrenme, Şekil 3.13'teki gibi makine öğreniminin bir alt alanıdır.



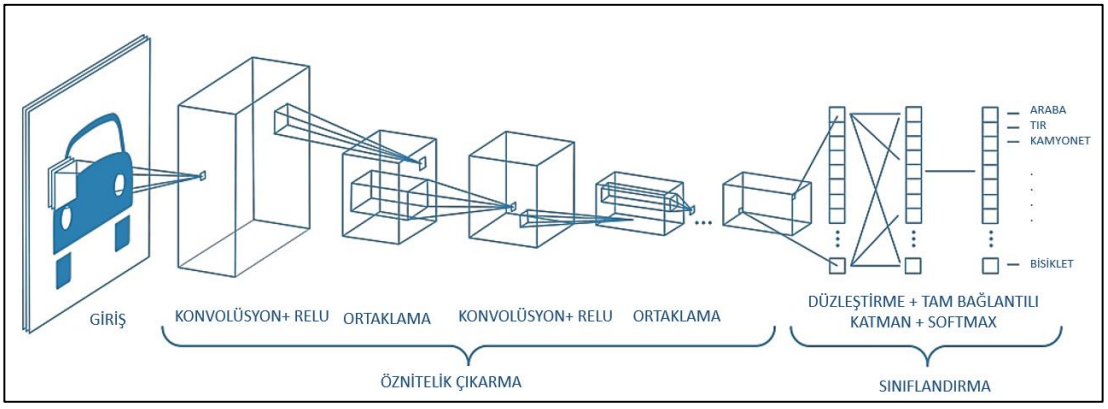
Şekil 3.13. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki

Derin öğrenme; görüntüler, metinler veya sesler gibi verilerden özellik çıkaran makine öğrenme tekniğidir. Bu teknikle çıkarılan özellikler öğrenilir ve sonraki görevler için

kullanılabilir. Makine öğrenimi ile derin öğrenme arasındaki en büyük fark özellik çıkarımının derin öğrenmenin kendi kendine gerçekleştirmesidir. Daha sınıflandırma veya tahmin kısmı ise tam bağlı katmanlar ile YSA modeline benzer şekilde gerçekleştirilir [108].

3.5.1. Evrişimli sinir ağları

Günümüzde Evrişimli Sinir Ağları (Convolutional Neural Network, CNN) modelleri görüntü tanıma ve işleme problemlerinde sıklıkla kullanılan bir tür yapay sinir ağları modelidir. CNN modelindeki öznitelik çıkarma ve sınıflandırma işlemlerini gerçekleştiren katmanların çok olmasından dolayı derin öğrenme modeli olarak kullanılırlar. CNN modelleri Şekil 3.14'teki gibi özellik çıkarımı ve sınıflandırma olmak üzere iki adımdan oluşur. Pikseller görüntüleri oluşturan en küçük parçalara verilen isimdir. Piksellerin matriks şeklinde bir araya gelmesi ile görüntüler oluşur. Her girdi görüntüsüne filtreler (kerneller) uygulandıktan sonra ortaklama (pooling) işlemi ile bir dizi evrişim (convolution) katmanından geçerek öznitelik çıkarılır. Daha sonra sınıflandırma tam bağlantılı katmanlarla başlar. Softmax aktivasyon fonksiyonu, görüntüdeki nesneleri 0 ile 1 arasında olasılıkla sınıflandırmak için uygulanır. Burada anlatılan kısım ileri yayılım algoritmasıdır [109-110].

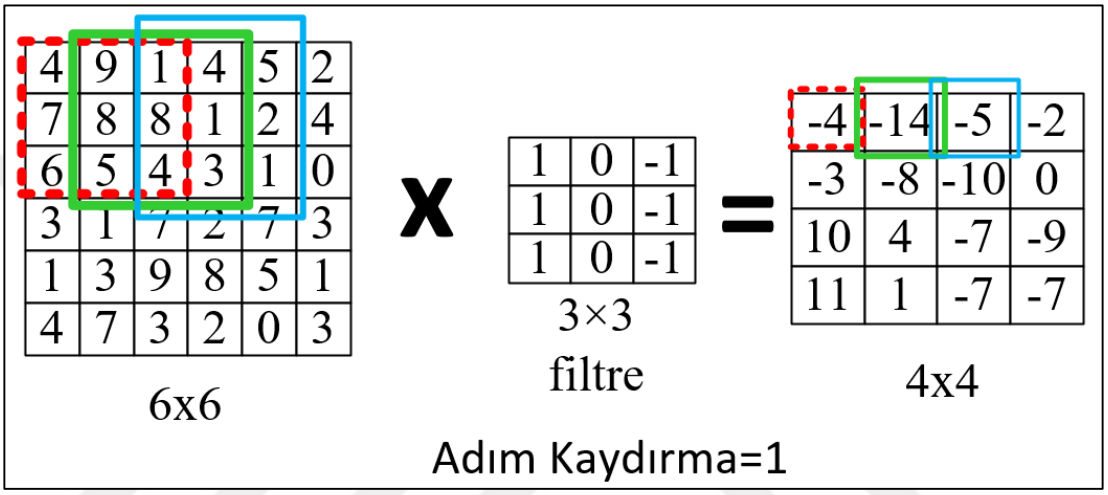


Şekil 3.14. CNN model örneği

Evrişim katmanları, giriş görüntülerinden öznitelik (feature) bilgilerini çıkarır. Evrişim katmanları görüntüdeki karakteristik belirleyici özniteliklerin görüntünün neresinde olduğunu bulmak için bir filtre kullanır. Filtre ilk önce X ve Y eksenlerine göre simetriği alınır. Daha sonra orijinal resmin üzerinde gezdirilerek üst üste gelen

sayılar çarpılır, toplanır bir sonuç elde edilir. Filtrenin bulunduğu merkez piksel artık bu değeri alır. Şekil 3.15'te 3×3 bir dikey kenar filtresi ile örnek bir resim üzerinde evrişim işlemi uygulanmıştır. Matriste bulunan her sayı değeri pikselin değerini temsil etmektedir. Denklem (3.53)'te Şekil 3.15'te kırmızı kutucuk üzerine belirlenen filtre ile gerçekleştirilen evrişim işlemi verilmiştir.

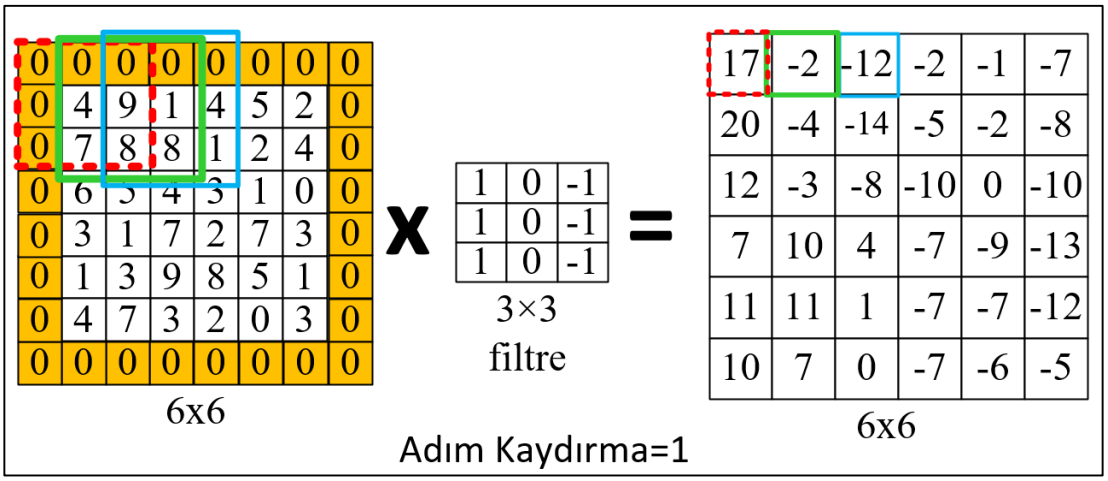
$$4\times(-1) + 7\times(-1) + 6\times(-1) + 9\times0 + 8\times0 + 5\times0 + 1\times1 + 8\times1 + 4\times1 = -4 \qquad (3.53)$$



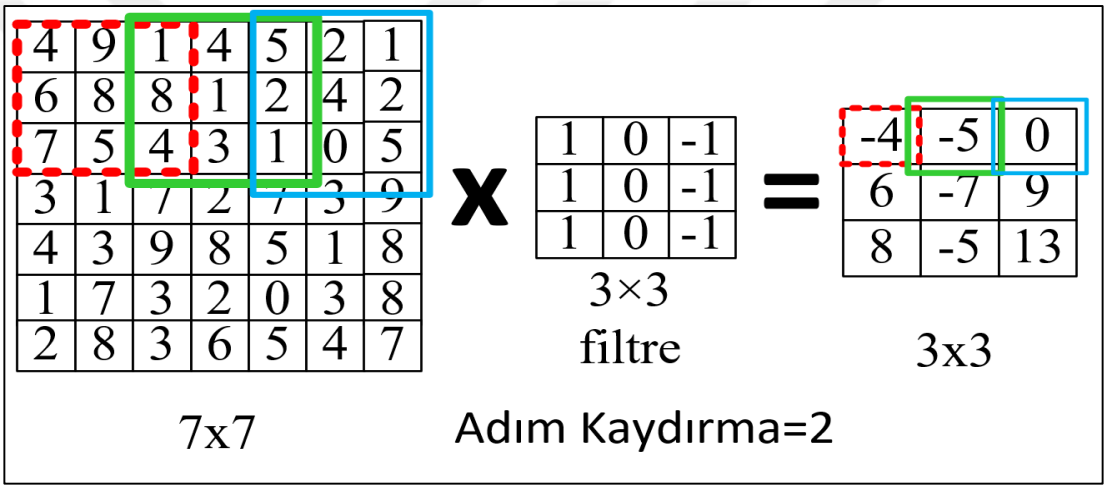
Şekil 3.15. Evrişim (convolution, konvolüsyon) işlemi

Katman çıkışlarında elde edilen öznitelik matris boyutları küçülebilir. Ayrıca kenar piksellerinin de hesaba katılması öznitelikleri modeli daha etkin yapabilmektedir. Bu sebep ile giriş diliminin kenarlarını evrişim işleminden önce satırlar ve sütunlar sıfırlarla ya da kenarda bulunan piksel değerleri ile doldurarak çözebilmektedir. Piksel doldurma en yaygın kullanımı girdiyle aynı boyutlarda çıktı üretmektir. Şekil 3.16'da bir önceki evrişim işlemine sıfır piksel doldurma (padding) işlemi gerçekleştirilmiştir.

Çıkış görüntüsünün boyutunun küçülmesini sağlayarak işlem maliyetini azaltmak adım kaydırma (stride) işlemi ile de yapılabilmektedir. Evrişim işlemi filtrenin bir piksel kayarak gezdirilmesi ile yapılabilirken adım sayısını arttırarak birden fazla piksel kaydırılabilir. Birbirini takip eden katmanlardaki nöronlar, girdi görüntüsünden kademeli olarak daha büyük bölgelerden örüntü yakalayacaktır. Böylece adım kaydırma ile girişin daha büyük ve daha karmaşık özellikleri tespit edilebilir. Şekil 3.17'de iki adım kaydırılarak yapılan örnek bir evrişim işlemi verilmiştir.

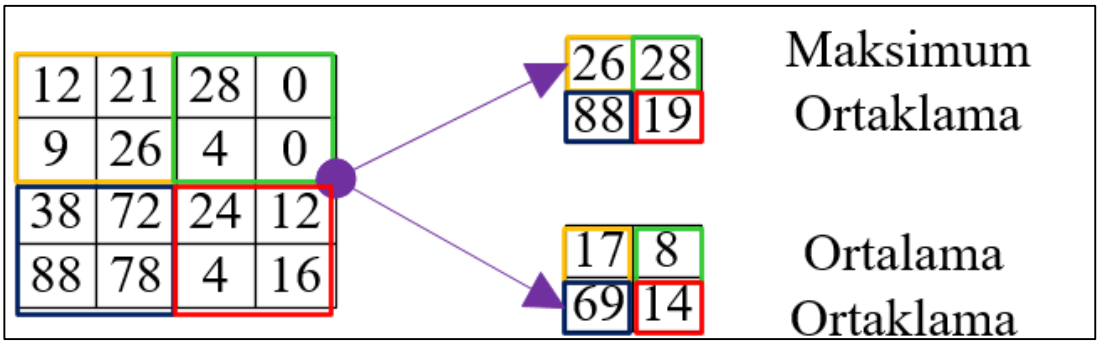


Şekil 3.16. Piksel doldurma (padding) işlemi



Şekil 3.17. Adım kaydırma işlemi

Çıkış görüntüsünün boyutunu düşürmenin bir yolu da işlem ortaklama (pooling) işlemidir. Bu işlem ile adım kaydırma işleminde olduğu gibi 1'den büyük bir adım kullanarak nöronların alıcı alanlarının (receptive field) artırılabilir. Konvolüsyonel sinir ağlarında genelde evrişim katmanından ortaklama işlemi kullanılır. Ortaklama işleminde öncelikle ortaklama maske boyutu belirlenir. Bir ortaklama katmanı, giriş görüntü dilimini belirlenen boyutta bir ızgaralara böler; burada her ızgara hücresi, bir dizi nöronun alıcı alanını temsil etmektedir. Ardından, ızgaranın her hücresine bir ortaklama işlemi uygulanır. Ortalama, maksimum işlemleri ile ortaklama işlemi gerçekleştirilebilir. Ortaklama katmanları hacim derinliğini değiştirmez, çünkü ortaklama işlemi her dilimde bağımsız olarak gerçekleştirilir. Şekil 3.18'de örnek bir ortalama ortaklama ve maksimum ortaklama işlemi verilmiştir.



Şekil 3.18. Ortaklama işlemi

Çıkış imge boyutunu Denklem (3.54) ile hesaplanabilir. Denklemde $n_{y,g}^{yeni}$ evrişim işlemi çıkış imge boyutunu, $n_{d,y}^{eski}$ görüntünün evrişim işleminden önceki boyutunu, p eklenen (padding) piksel sayısını, f filtre boyutunu ve s (stride) adım kaydırma sayısını temsil etmektedir. Ortaklama işlemi genellikle evrişim işleminden bağımsız gerçekleştirilir. Ortaklama sonucu oluşan imge boyutunu bulmak için Denklem (3.54)'te filtre boyutu yerine ortaklama boyutu yazılmalıdır.

$$n_{y,g}^{yeni} = \frac{n_{y,g}^{eski} + (2 \times p) - f}{s} + 1 \tag{3.54}$$

Bir evrişimli sinir ağı modeli evrişim, doğrultulmuş doğrusal birim (Rectified linear unit, ReLU), ortaklama, düzleştirme (flatten), tam bağlı katmanlar ve softmax sınıflandırma işlevi olmak üzere altı adımdan oluşur. İlk adımda, görüntülerden belirli öznitelikleri etkinleştirmek için giriş görüntüsüne bir dizi evrişim filtresi uygulanır. Eğitim hızını artırmak için ReLU aktivasyon fonksiyonu ile negatif değerler sıfıra eşitlenir ve pozitif değerler değişmeden kalır. Ortaklama adımının amacı, doğrusal olmayan alt örnekleme (downsampling) gerçekleştirerek ve dolayısıyla ağın öğrenmesi gereken parametre sayısını azaltarak çıktıyı daha basit hale getirmektir. Bu üç adım onlarca veya yüzlerce katmanda tekrarlanır ve her katman farklı özellikleri öğrenir.

Düzleştirme (flattening) adımında, tam bağlantılı katmanların evrişimli katmanlardan sonra kullanılması için tüm iki boyutlu diziler tek bir doğrusal vektöre dönüştürülür. Tam bağlantılı katmanlar, önceki evrişimli katmanların tüm yerel özelliklerini birleştirebilir ve YSA olduğu gibi ağırlık ve bias değerleri geri besleme yöntemi ile

güncellenerek öğrenilir. Prosedür, nihai sınıflandırma çıktısını sağlamak için softmax işlevinin uygulanmasıyla tamamlanmıştır [111].

3.5.2. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları YSA tabanlı modellerde öğrenme işlemi gerçekleşirken hesaplanan değerlere doğrusal olmayan hale getirerek modelin doğrusal olmayan problemlerde de etkin olmasını sağlamaktadır. Aktivasyon işlevleri, bir derin öğrenme modelinin çıktısını, doğruluğunu ve ayrıca bir modelin eğitiminin hesaplama verimliliğini belirlemektedir. Aktivasyon işlevlerinin ayrıca sinir ağının yakınsama yeteneği ve yakınsama hızı üzerinde büyük bir etkisi vardır veya bazı durumlarda, etkinleştirme işlevleri ilk etapta sinir ağlarının yakınsamasını engelleyebilir. Aktivasyon işlevlerinin ek bir yönü de, her veri örneği için binlerce hatta milyonlarca nöron üzerinden hesaplandığı için hesaplama açısından verimli olmaları gerektiğidir. Modern sinir ağları, modeli eğitmek için geri yayılım tekniğini kullanır; bu durum aktivasyon işlevi ve türev işlevi üzerinde maliyetli bir hesaplama yükü oluşturur. Aktivasyon fonksiyonu geri yayılım algoritmasında türev işlemi olduğundan türevlenebilir olarak seçilmelidir. Aslında aktivasyon fonksiyonları, bir sinir ağının çıktısını belirleyen matematiksel denklemlerdir. Fonksiyon, ağdaki her bir nörona bağlanır ve her bir nöronun girişinin modelin tahmini ile alakalı olup olmadığına bağlı olarak etkinleştirilip etkinleştirilmeyeceğini (fired or not) belirler. Aktivasyon fonksiyonları ayrıca her nöronun çıktısını 1 ile 0 veya -1 ile 1 arasında normalleştirmeye yardımcı olur.

3.5.2.1. Sigmoid fonksiyonu

Sigmoid fonksiyonu çıkışı 0 ile 1 arasında sınırlandırır. Sıfırdan küçük değeri büyük negatif sayılar sıfıra, büyük pozitif sayılar bire eşitlenerek çıkış normalleştirilir. Çıktı değerlerinde "sıçramaları" önleyerek yumuşak bir eğim (gradient) sağlar. Sigmoid fonksiyonunun en büyük dezavantajı gradiyenlerin ortadan kaybolması (vanishing gradient) problemi olması, çok yüksek veya çok düşük giriş değerleri için, tahminde neredeyse hiç değişiklik olmaz ve bu da kaybolan gradyan sorununa neden olur. Bu durum ağın daha fazla öğrenmeyi reddetmesine veya doğru bir tahmine ulaşmak için çok yavaş olmasına neden olabilir. Ayrıca çıkışların sıfır merkezli olmaması ve

maliyetli hesaplama diğer dezavantajlarındandır. Sigmoid fonksiyonu Şekil 3.19(a)'da gösterilmiştir. Sigmoid fonksiyonu Denklem (3.55) kullanılarak hesaplanabilir [112].

$$f(x) = \frac{1}{1+e^{-x}} \tag{3.55}$$

3.5.2.2. Hiperbolik tanjant fonksiyonu

Hiperbolik tanjant (tanh) fonksiyonu çıkış değerlerini -1 ile 1 arasına sınırlandırarak normalleştirir. Sigmoid fonksiyonu gibi gradiyenlerin kaybolma problemi vardır. Fakat sıfır merkezli olmasından dolayı güçlü negatif, nötr ve güçlü pozitif değerlere sahip girdileri modellemeyi kolaylaştırır ve bu avantajından dolayı sigmoid fonksiyonuna göre daha çok tercih edilmektedir. Hiperbolik tanjantın fonksiyonu Denklem (3.56) kullanılarak tanh aktivasyon fonksiyonu elde edilebilir. Şekil 3.19(b)'de verilen denklem ile tanh grafiği hesaplanmıştır [112].

$$f(x) = \frac{1- e^{-2x}}{1+e^{-2x}} \tag{3.56}$$

3.5.2.3. Relu fonksiyonu

Relu (Rectified Linear Unit, ReLU) fonksiyonu derin öğrenmede uygulamalarında en çok kullanılan evrişim işleminden sonra tercih edilen aktivasyon fonksiyonudur. Relu fonksiyonun hesaplama maliyeti üstel işlem olmadığı için diğer fonksiyonlara göre daha düşüktür. Aynı zamanda ağın çok hızlı bir şekilde yakınsamasına olanak tanımaktadır. Relu fonksiyonunda negatif değerler sıfır olarak alınırken pozitif değerler olduğu gibi alınır. Doğrusal olmayan problemlerde doğrusal bir işlev gibi görünmesine rağmen kullanılabilmektedir. ReLU'nun bir türev işlevi vardır ve geri yayılım algoritmasında kullanılabilmektedir. Girdiler sıfıra yaklaştığında veya negatif olduğunda, işlevin eğimi sıfır olur, ağ geri yayılımı gerçekleştiremez ve öğrenemez. Sıfır odaklı olmadığı için nöron kaybı gerçekleşmektedir.

Relu fonksiyonu Denklem (3.57)'deki gibi elde edilebilir. Şekil 3.19(c)'de relu grafiği çizdirilmiştir [112].

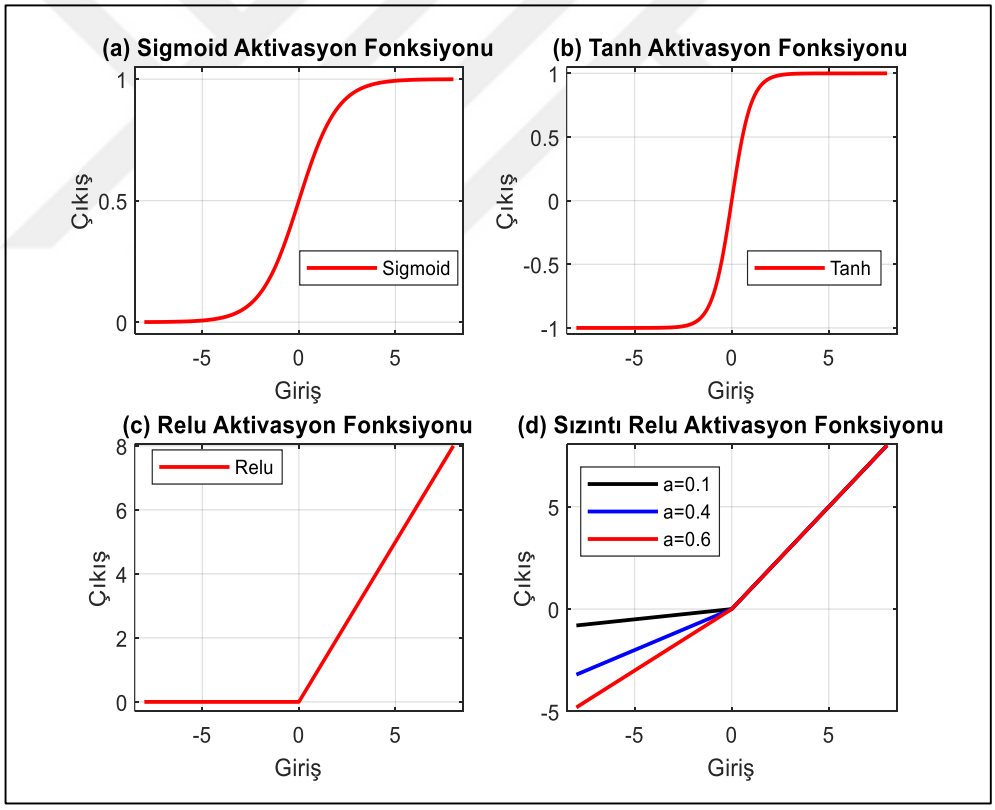
$$f(x) = maks(0, x) \tag{3.57}$$

3.5.2.4. Sızıntı relu fonksiyonu

Sızıntı relu (Leaky Relu) fonksiyonu, relu fonksiyonunun dezavantajı olan nöron kaybını önlemek için geliştirilen bir aktivasyon fonksiyonudur. ReLU'nun bu varyasyonu negatif alanda küçük bir pozitif eğimi vardır, bu nedenle negatif giriş değerleri çok küçük değerler alarak geri yayılımı algoritmasında kullanılabilir. Şekil 3.19(d)'de farklı a değerleri için fonksiyon grafiği verilmiştir.

Dezavantajları ise sonuçlar tutarlı elde edilemeyebilir ve negatif girdi değerleri için tutarlı tahminler sağlamayabilir. Denklem (3.58)'de, sızıntı Relu formülü verilmiştir [112].

$$f(x) = maks(a \times x, x) \qquad 0 < a < 1 \tag{3.58}$$



Şekil 3.19. Çeşitli aktivasyon fonksiyonları

3.5.2.5. Softmax aktivasyon fonksiyonu

Giriş değerleri pozitif, negatif, sıfır veya birden büyük olabilir, ancak softmax fonksiyonu bunları olasılıksal olarak yorumlanabilmeleri için 0 ile 1 arasındaki

değerlere dönüştürür. Girişlerden biri küçük veya negatifse, softmax onu küçük bir olasılığa dönüştürür veya giriş büyükse o zaman büyük bir olasılığa dönüştürür. Softmax fonksiyonu bazen softargmax fonksiyonu veya çok sınıflı lojistik regresyon olarak adlandırılır. Bunun nedeni, softmax'ın çok sınıflı sınıflandırma için kullanılabilecek bir lojistik regresyon genellemesi yapabilmesi ve formülünün, lojistik regresyon için kullanılan sigmoid fonksiyonuna çok benzer olmasıdır. Birçok çok katmanlı evrişimli sinir ağı, uygun şekilde ölçeklenmeyen ve anlaşılması zor olabilecek gerçek değerli puanlar veren sondan bir önceki tam bağlantılı katmanla bitmektedir. Burada softmax çok kullanışlıdır, çünkü bu fonksiyon puanları bir kullanıcının anlayabileceği hale getirerek, diğer sistemlere girdi olarak kullanılabilen normalleştirilmiş her sınıfa ait bir olasılık dağılımı üretir. Bu nedenle, evrişimli sinir ağının son katmanlarında bir softmax fonksiyonu kullanılır.

Evrişim katmanlarında genellikle relu fonksiyonu tercih edilirken tam bağlantılı katmanlarda hiperbolik tanjant (tanh) ve son katmanında softmax fonksiyonu kullanılmaktadır [113].

3.5.3. Optimizasyon yöntemleri

3.5.3.1. Stokastik gradyan inişi

Stokastik gradyan inişi (Stochastic Gradient Descent, SGD), toplu gradyan inişi veya vanilya gradyan inişinin aksine, her eğitim örneği x ve y için parametreleri günceller. SGD, yüksek varyanslı sık güncellemeler gerçekleştirerek amaç fonksiyonunun büyük ölçüde dalgalanmasına neden olur. Denklem (3.59)'daki gradyan inişi (Gradient descent, GD), gradyanı yerel bir minimuma yakınsamak için yinelemeli olarak kullanan popüler bir optimizasyon tekniğidir. GD'de ağırlıklar, ölçeklenmiş gradyan $\frac{\delta L}{\delta w_i}$ çıkarılarak güncellenir. Bunun nedeni, gradyanların maksimum yönü göstermesidir. Denklem Pozitif sabit η, eğimi ölçeklendirmek ve öğrenme hızını kontrol etmek için kullanılır. GD aramasının adımını belirler. Gradyanı hesaplamak ve ağırlıkları güncellemek için tüm eğitim veri kümesi yerine veri grupları kullanıldığında, GD'ye "stokastik" öneki eklenir. SGD'nin avantajı, her yinelemede daha hızlı çalışması ve grubun belleğe sığması için daha rahat olmasıdır. Tek bir

yineleme daha hızlı olmasına rağmen, SGD'nin yakınsaması çok daha fazla zaman alır. Bu sorunu çözmek için, SGD genellikle ivme (momentum) ile kullanılır. Denklem (3.60) ve Denklem (3.61)'de β momentum, ν hızdır. Genellikle, ν sıfır olarak ve β ise 0,9 alınarak sönümleme amacıyla kullanılır [114].

$$w_i = w_i - \eta . \frac{\delta L}{\delta w_i} \tag{3.59}$$

$$\nu = \beta \nu - \eta \frac{\delta L}{\delta w_i} \tag{3.60}$$

$$w_i = w_i + \nu \tag{3.61}$$

3.5.3.2. RMSProp optimizasyon fonksiyonu

RMSprop, sinir ağlarının eğitiminde kullanılan gradyan tabanlı bir optimizasyon tekniğidir. Geri yayılma algoritmasını bulan Geoffrey Hinton tarafından önerilmiştir Sinir ağları gibi çok karmaşık işlevlerin gradyanları, veriler işlev boyunca yayılırken kaybolma ya da patlama eğilimindedir. Rmsprop, mini toplu (mini batch) öğrenme için stokastik bir teknik olarak geliştirilmiştir. RMSprop, gradyanı normalleştirmek için kare gradyanların hareketli ortalamasını kullanarak yukarıdaki sorunu ele alır. Bu normalleştirme adım boyutunu (momentum) dengeler, patlamayı önlemek için büyük gradyanlar için adımı azaltır ve kaybolmayı önlemek için küçük gradyanlar için adımı artırır.

Denklem (3.62)'de ve Denklem (3.63)'te γ bir bozulma faktörüdür ve ϵ sıfıra dalmayı önleyen ve genellikle 10^{-8}'e ayarlanan küçük bir sabittir. Hinton, γ'nin 0,9'a öğrenme hızı η için varsayılan değer olan 0,001 ayarlanmasını önermektedir [115].

$$g = \gamma . g - (1 - \gamma) . \left[\frac{\delta L}{\delta w_i} \right]^2 \tag{3.62}$$

$$w_i = w_i - \frac{\eta}{\sqrt{g} + \epsilon} - \left[\frac{\delta L}{\delta w_i} \right] \tag{3.63}$$

3.5.3.3. Uyarlanabilir moment tahmini

Uyarlanabilir moment tahmini (Adaptive Moment Estimation, ADAM) her parametre için uyarlanabilir öğrenme oranını hesaplayan bir optimizasyon yöntemidir. RMSprop ve SGD'nin momentum ile birleşimi olarak görülebilir. RMSprop gibi öğrenme oranını ölçeklemek için kare gradyanları kullanır ve momentumlu SGD gibi gradyanın kendisi yerine gradyanın hareketli ortalamasını kullanarak momentumdan yararlanır. ADAM optimizasyon fonksiyonu sürtünmeli ağır bir top gibi davranır, hata yüzeyinde düz minimumları tercih eder. Denklem (3.64)-(3.66)'da m ve g sırasıyla gradyanların 1. momentinin (ortalama) ve 2. momentinin (ortalanmamış varyans) tahminlerini temsil eder. Uygulamada, sıfırda başlatılırlar. β_1 ve β_2 bozucu faktörlerdir ve tercihen sırasıyla 0,9 ve 0,999 olarak başlatılır [114].

$$m = \beta_1 m + (1-\beta_1).\left[\frac{\delta L}{\delta w_i}\right] \tag{3.64}$$

$$g = \beta_2 g + (1-\beta_2).\left[\frac{\delta L}{\delta w_i}\right]^2 \tag{3.65}$$

$$w_i = w_i - \frac{\eta}{\sqrt{g} + \in}.m \tag{3.66}$$

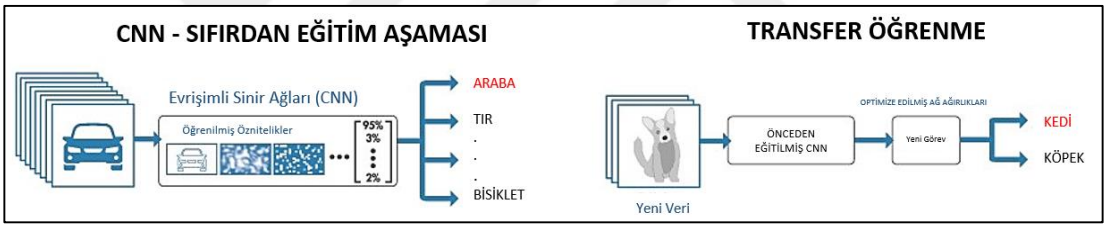
3.5.4. Transfer öğrenme

Klasik makine öğrenmesi uygulamalarında hali hazırda bulunan mevcut verilerle model eğitildikten sonra modelin daha önce tanımadığı veriler ile test edilmesi istenir. Eğitim sürecinde kullanılan veri sayısı arttıkça model daha çok öğrenmeye başlar ve başarısını arttırır. Eğitim verisi ile test verisi değiştiğinde, mevcut veri setine yeni durumlar eklendiğinde veya çıktığında sistemin yeniden eğitilmesi gerekmektedir.

Transfer öğrenmenin amacı karmaşık bir görevi çözmek için başlangıçta daha büyük bir veri kümesi üzerinde eğitilmiş (önceden eğitilmiş) bir modeli kullanarak bu önceden eğitilmiş modeli, nispeten daha basit küçük veri seti içeren bir problemi çözmektir. Transfer öğrenme ise insan öğrenmesi gibi büyük geçmiş tecrübelere

sahiptir. Transfer öğrenme yeni bir problem için eğitildiğinde model sıfırdan eğitilmez ve öğrenilen bilgiler ile problem çözülür. Böylece eğitim süreci daha hızlandırılarak önceden öğrenilmiş bilgiler yeni problem için kullanılmak üzere modele aktarılır. Zaman tasarrufu ve yüksek başarı oranı sağladığından güncel uygulamalarda sıklıkla tercih edilmektedir. Ayrıca yeterli eğitim verisinin olmadığı durumlarda transfer öğrenme tercih edilir. Geçmiş tecrübelerinin fazla olmasından dolayı transfer öğrenme gerçek zamanlı uygulamalarda daha yüksek başarı gösterir [116-117].

Şekil 3.20'de görüldüğü gibi araç, tır, bisiklet vb. sınıflandırması evrişimli sinir ağları ile gerçekleştirmek istenirse bu sınıflardan belirli sayıda eğitim verisi ile evrişim sinir ağları eğitilmelidir. Transfer öğrenmesinde ise tanımlı objeler için eğitim yapılmasına gerek yoktur. Dış dünyadan elde edilen kedi, köpek vb. sınıflara ait resimler kolaylıkla sınıflandırılabilir. Farklı uygulamalar için ise önceden eğitilmiş modellerin belirli katmanları değiştirilerek ağırlıklar ve bias güncellenmesi yapılır.



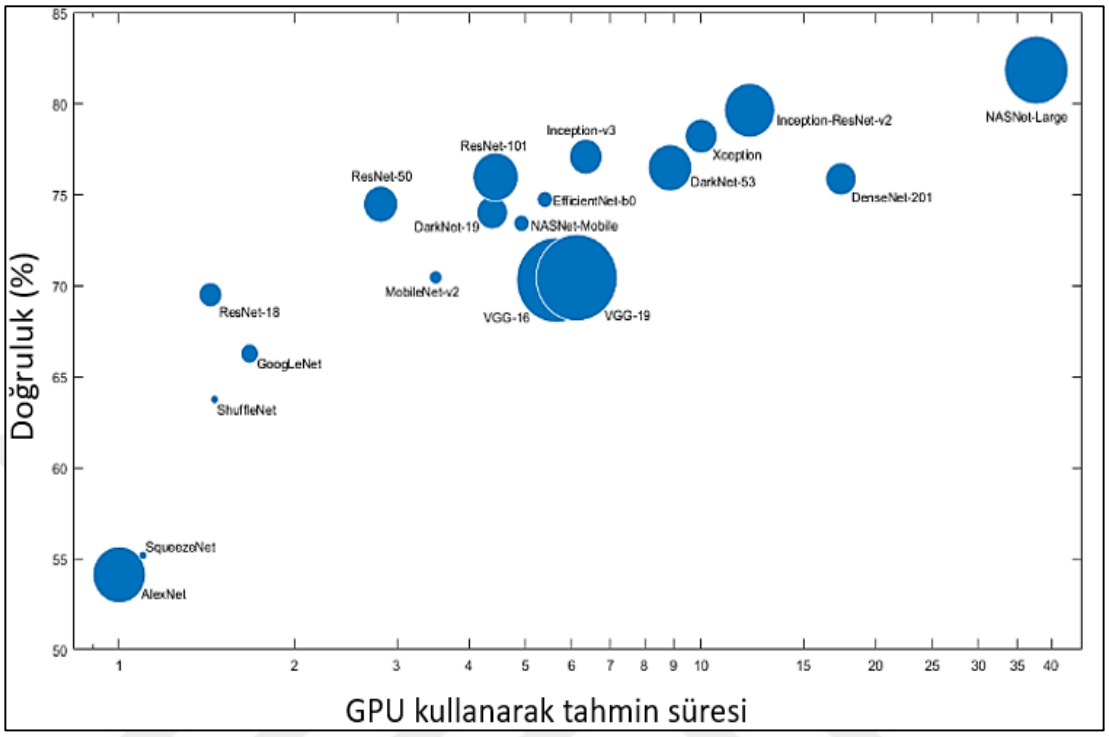
Şekil 3.20. Evrişimli sinir ağları ve transfer öğrenme

Veri kümeleri birbirine benzer ve birbiriyle alakalı olduğunda, ancak yeni veri kümesi küçük olduğunda, transfer öğrenimi aşağıdaki gibi uygulanabilir:

- Önceden eğitilmiş temel modelin sınıflandırma ile ilgili olan tam bağlı katmanları çıkartılır.
- Modelin sınıflandırma, tahmin gibi amacına yönelik yeni çıkış katmanı eklenir.
- Yeni bağlı tam bağlantılı katmanlarının ağırlıklarını rastgele seçilir.
- Yeni küçük veri kümesiyle tam bağlantılı katmanlar eğitilir.

Bu prosedürlerin uygulanmasıyla, kaldırılan tam bağlantılı katmanlarının dışındaki parametreler ve ağırlıklar yeni probleme aktarılır. Aktarılan ağırlıklar ve parametreler, görüntülerin özelliklerine göre optimize edilmiştir. Böylece transfer öğrenmesi uygulanmış olur. Probleme uygulanacak bir ağ seçerken ağların özellikleri dikkate

alınmalıdır. Ağların en önemli özellikleri ağ doğruluğu, hızı ve boyutudur. ImageNet veri setinde test doğruluğunu kullanarak ağ seçmek için Şekil 3.21 kullanılabilir [118].



Şekil 3.21. Imagenet sınıflandırma doğrulukları

3.5.4.1. Alexnet modeli

AlexNet, Krizhevsky ve ark. tarafından 2012 yılında geliştirilen derin bir sinir ağıdır. ImageNet büyük ölçekli görsel tanıma yarışması (The ImageNet Large Scale Visual Recognition Challenge, ILSVRC) 2012 veri seti ile eğitilmiş ve sınıflandırılması amacıyla tasarlanmıştır Ayrıca birden fazla GPU ile çalıştırılmıştır. Renkli boyutlu görüntüleri (227×227×3) 1000 kategoriye sınıflandırmak için inşa edilmiştir [119].

AlexNet, 8 katmanlı derinliğe sahip ileri beslemeli bir CNN türüdür. 5 evrişim katmanı ve 3 maksimum ortaklama katmanı ve 3 tam bağlantılı katman içermektedir. Toplamda 61 milyonun üzerinde eğitilebilir parametreye sahiptir. Alt örnekleme sırasında maksimum ortaklama (3×3 filtre) ve Relu aktivasyon fonksiyonlarını kullanır. Konvolüsyonlar için (11×11), (5×5) veya (3×3) boyutunda filtreler kullanılmaktadır. Şekil 3.22'de Alexnet mimarisi görülmektedir.

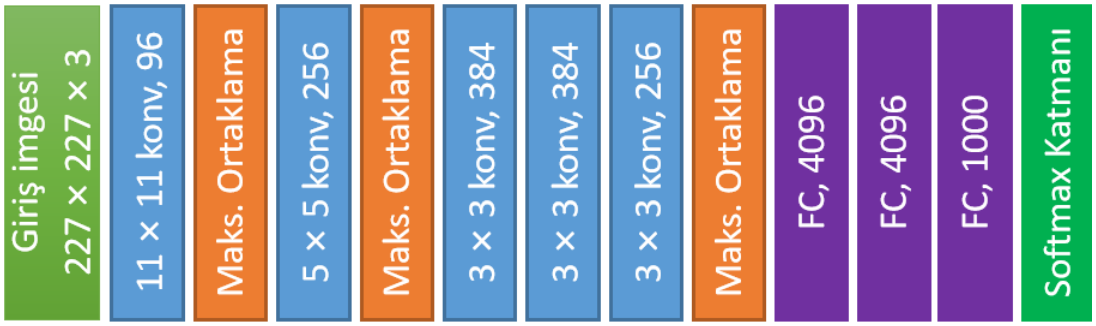
3.5.4.2. VGG19 modeli

VGG19 Oxford Üniversitesi'nden Visual Geometry Group (VGG) olarak adlandırılan bir grup tarafından geliştirilmiştir [120]. 16 evrişim katmanı, 3 tam bağlantılı katman, 5 maksimum ortaklama katmanı ve 1 Softmax katmanı olmak üzere 19 katmana sahiptir. Bu ağ girdi olarak (224×224×3) boyutlu görüntüleri kullanır. Yaklaşık 144 milyon eğitilebilir parametreye sahiptir. Görüntünün tüm kavramını kapsaması için Adım boyutu 1 piksel olan (3×3) boyutlu filtreler kullanılmıştır. Görüntünün uzaysal çözünürlüğünü korumak için uzamsal doldurma(padding) kullanılmıştır. Maksimum ortaklama, 2 adım kaydırma ile 2×2 piksel pencereleri üzerinde gerçekleştirilmiştir. Bu adımları Relu aktivasyon fonksiyonu takip etmiştir. ILSVRC sınıflandırması için ilk ikisi 4096 boyutunda olan üç tam bağlantılı katman uygulanmış ve üçüncü tam bağlantılı katman olarak 1000 kanallı oluşturulmuş ve sınıflandırma için softmax katmanı kullanılmıştır. VGG19 mimarisi Şekil 3.23'te görülmektedir.

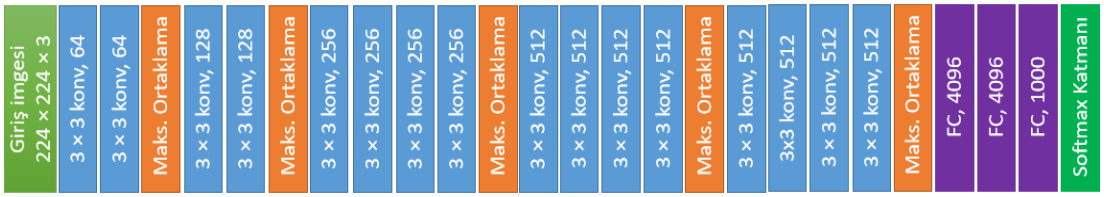
3.5.4.3. Resnet101 modeli

Microsoft araştırma ekibinden He ve ark. 2015 yılında VGG-19 modelinden esinlenerek Şekil 3.24'te görülen Resnet101 mimarisini geliştirmişlerdir. ImageNet veri seti için geliştirilen en derin mimarilerden birtanesidir. Genellikle bir CNN'de birkaç katman birbirine bağlanır ve çeşitli görevleri yerine getirmek için eğitilir. Ağ, katmanlarının sonunda birkaç düzeyde özellik öğrenir. Bu modeldeki evrişimli katmanların boyutu çoğunlukla 33 filtreye sahiptir. ResNet'te, katmanlar aynı çıkış öznitelik haritası boyutu için aynı sayıda filtreye sahiptir. Her katman için zaman karmaşıklığını korumak amacıyla öznitelik harita boyutu yarıya indirilirse filtre sayısı iki katına çıkar. Katmanları iki adımda evrişimle işleminden geçirerek alt örneklemeyi doğrudan gerçekleştirir. Resnet son katmanında global bir ortalama ortaklama katmanı ve Softmax ile etkinleştirilen, tamamen bağlı bir katman bulunur. Artık (residual) öğrenme, bu katmandan öğrenilen girdi özelliklerinin çıkarılması olarak tanımlanabilir. Resnet öğrenme sürecini her 33 filtre çiftine kısayol bağlantılarını k. katmanın girişini (k+x). katmana doğrudan bağlayarak gerçekleştirir. Katmanları atlamanın arkasındaki sebep, önceki katmandan gelen aktivasyonları yeniden kullanarak şimdiki katmanın ağırlıklarını öğrenene kadar gradyanların kaybolması

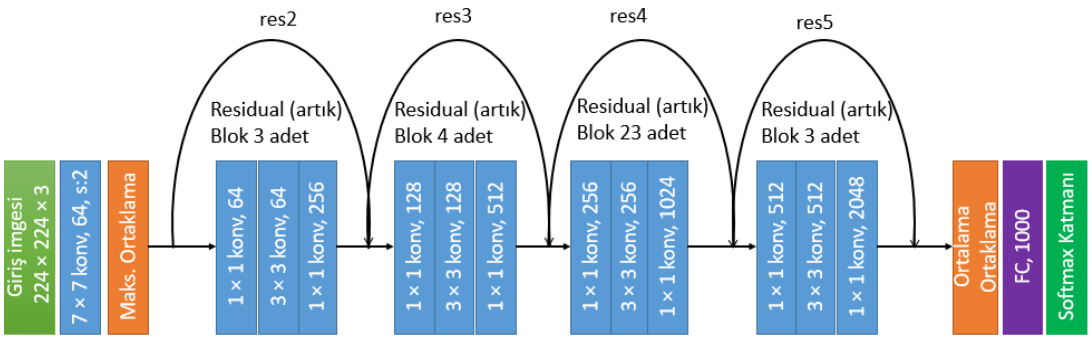
sorununu ortadan kaldırmaktır. Ağı eğitirken, ağırlıklar mevcut olanın yanındaki katmanı güçlendirecek ve ayrıca önceki katmanı sessize alacak şekilde ayarlanacaktır. Bu ağı eğitmenin basit derin evrişimli sinir ağlarını eğitmekten daha kolay olduğu görülmüştür. Aynı zamanda doğruluk azalması sorununu da çözmektedir. ResNet101, toplamda 101 evrişim katmanı ve üç tam bağlantılı katman içerir. Bununla birlikte, toplamda 33 artık blok katmandan oluşur ve bu blokların 29'u, üstteki artık bağlantılar olarak tanımlanan önceki bloğun çıktısını doğrudan kullanır ve bu artıklar, her birinin sonunda kullanılan toplama operatörünün ilk işleneni olarak kullanılır. 50 katmanlı ResNet'in değiştirilmiş bir versiyonudur. 44,6 milyon eğitilebilecek parametre içermektedir. Giriş görüntüsü olarak imgelerin 224×224×3 boyutunda olması istenmektedir [43, 121].



Şekil 3.22. Alexnet mimarisi



Şekil 3.23. VGG19 mimarisi



Şekil 3.24. Resnet101 mimarisi

3.6. Model Performans Kriterleri

Bu tez kapsamında önerilen modellerin başarımının tespiti için en popüler ve basit yöntem olan modele ait karışıklık matrisi (confusion matrix) elde edilmiştir. Tablo 3.1'de ikili sınıflandırma için oluşturulmuş karışıklık matrisi verilmiştir.

Tablo 3.1. Karışıklık matrisi

Sınıflar		**Gerçek sınıf**	
		Pozitif (1)	Negatif (0)
Tahmin edilen sınıf	Pozitif (1)	DP	YP
	Negatif (0)	YN	DN

- Tablo 3.1'deki DP (Doğru Pozitif) gerçek sınıfı pozitif ve pozitif olarak sınıflandırılan örnekleri,
- YN (Yanlış Negatif) gerçek sınıfı pozitif olan ve negatif olarak sınıflandırılan örnekleri,
- YP (Yanlış Pozitif) gerçek sınıfı negatif olan ancak modelin pozitif sınıflandırdığı örnekleri,
- DN (Doğru Negatif) ise gerçek sınıfı negatif olan ve negatif olarak sınıflandırılan örnekleri temsil etmektedir.

Karışıklık matrisi bulunduktan sonra değerlendirme ölçütleri bu matris yardımıyla bulunabilir:

- Doğruluk (Accuracy): Model değerlendirme kriterleri arasında en belirleyici ölçüttür. Modelin doğru yapılan tahmin sayısının tüm örnek sayısına bölünmesiyle elde edilir. Doğruluk değeri Denklem (3.69)'daki eşitlikle hesaplanabilir.

$$\text{Doğruluk oranı} = \frac{\text{DP} + \text{DN}}{\text{DP} + \text{DN} + \text{YP} + \text{YN}} \tag{3.69}$$

- Kesinlik (Precision): Modelin doğru tahmin ettiği pozitif sınıf sayısının tüm pozitif sınıf sayısına bölünmesiyle bulunabilir. Hassasiyet değeri Denklem (3.70)'deki eşitlikle hesaplanabilir.

$$\text{Kesinlik (P)} = \frac{DP}{DP + YP} \tag{3.70}$$

- Hassasiyet (Recall/sensitivity): Modelin doğru pozitif sınıf olarak tahmin ettiği sayının, toplam pozitif tahmin edilen sınıf sayısına bölünmesiyle bulunur. Kesinlik değeri Denklem (3.71)'deki eşitlikle hesaplanabilir.

$$\text{Hassasiyet (R)} = \frac{DP}{DP+YN} \tag{3.71}$$

- F-ölçütü (f-score): Kesinlik ve hassasiyet değerlerinin daha anlamlı bir ölçüt olabilmesi için kesinlik ve hassasiyet değerlerinin ağırlıklı ortalamasıyla f ölçütü hesaplanır. Doğruluk değerinden sonra en çok kullanılan değerlendirme ölçütüdür. F-ölçütü Denklem (3.72)'deki eşitlikle hesaplanabilir.

$$\text{f-ölçütü} = \frac{2\times P\times R}{P+R} \tag{3.72}$$

- ROC (Reciever Operator Characteristics) eğrisi: Sınıflandırma problemlerinde kullanılan bir başka değerlendirme ölçütü ROC eğrisidir. ROC eğrisi sınıflandırma problemlerinde performansları görselleştirerek değerlendirmek için kullanılır. ROC eğrisinin X ekseninde YP oranı ve Y ekseninde ise DP oranı bulunur. YP oranı Denklem (3.73) ve DP oranı Denklem (3.74) bulunan eşitlikle hesaplanabilir. ROC eğrisinde eğri sol üst köşeye doğru yaklaştıkça o sınıfa ait verilerin daha iyi sınıflandırıldığı orta bölgelere yaklaşıldığında ise daha kötü bir sınıflandırma yapıldığını ifade eder.

$$\text{YP oranı} = \frac{YP}{YP+DN} \tag{3.73}$$

$$\text{DP oranı} = \frac{DP}{DP + YN} \tag{3.74}$$

- AUC (Area Under the Curve) değeri: AUC değeri ROC eğrisi ile x ekseni arasında kalan alanı belirtir [122]. AUC değeri ROC eğrileri için bir değerlendirme ölçütüdür.

3.7. k-Katlı Çapraz Geçerlilik Testi

k-katlı çapraz geçerlilik testi (k-fold cross validation test) sınıflandırma modellerini değerlendirmek için gerçekleştirilen bir işlemdir. Modelin daha önce görmediği test verileri ile model performansı değerlendirilmektedir. Modelde işlenecek veri seti eğitim ve test verisi olarak bölünürler. Bu veri seti rastgele olarak *k* gruba bölünür ve yinelemeli olarak doğrulama için her seferinde farklı bir grup ve modeli eğitmek için geri kalan k-1 sayıda grup seçilir. Örnek bir k=5 için çapraz geçerlilik testi Şekil 3.25'te açıklanmıştır. k-katlı çapraz geçerlilik testi nihai sonuçları genellikle model doğruluk oranlarının ortalaması veya standart sapması ile hesaplanmaktadır [123].



Şekil 3.25. 5 katlı çapraz geçerlilik testi

4. ÖNERİLEN BEYİN TÜMÖR SINIFLANDIRMA MODELLERİ

Görüntü Arşivleme ve İletişim Sistemi (Picture Archiving and Communication System PACS) ekonomik depolama ve birden çok modaliteden görüntülere kolay erişim ve aktarım sağlayan bir tıbbi görüntüleme teknolojisidir. Tıbbi görüntüleme teknikleri olan ultrason, röntgen, bilgisayarlı tomografi ve MR teknojilerinin sağladığı görüntülerin tek bir kaynaktan yönetilmesini sağlar. PACS sisteminde bulunan görüntülerin analiz ve değerlendirme işlemleri tamamlandıktan sonra, uzaktan erişim ile doktorlar kendi bilgisayarından görüntü raporuna içeriğine erişebilmekte ve bu sayede teşhis koyarken hastanın diğer şikâyetleri ile birlikte değerlendirebilmektedir. Görüntülerin depolanmasını, erişimi, dağıtımı ve sunumu gibi olanaklar sunar. PACS, geleneksel film kâğıtlarına basılı görüntü alma, dağıtma ve görüntüleme ile ilişkili fiziksel ve zaman engellerini azaltmaktadır. Tıpta Dijital Görüntüleme ve İletişim (Digital Imaging and Communications in Medicine, DICOM) iki veya üç boyutlu tıbbi görüntüleri aktarmak, depolamak, yazdırmak, raporlamak ve analiz etmek için oluşturulan uluslararası standarttır [124].

Tez çalışması kapsamında birincil (primer) tip glioma, ikincil (sekonder) tip olan akciğer ve meme kökenli metastatik beyin tümör tiplerinin sınıflandırılması YİÖ tabanlı makine öğrenmesi ve transfer öğrenmesi modelleri (Alexnet, VGG19, Resnet101) gerçekleştirilmiştir. Çalışma kapsamında kullanılan verilerden metastatik beyin tümörleri Kocaeli Üniversitesi Tıp Fakültesi Radyoloji Bölümü'nden elde edilmiştir. Beyin metastazının kaynaklandığı birincil tümör odağı bilinen hastalara ait görüntüler Radyoloji bölümü doktorları tarafından ayırt edilmiştir. Doktorlar beyin metastazı kökenine ait görüntüleri dört sekansta (T1, T1-C, FLAIR ve difüzyon ağırlıklı MR) inceleyerek DICOM formatında kayıt etmişlerdir. Daha sonra radyoloji doktorları tarafından tümörün belirgin olduğu en net kontrastlı T1-ağırlıklı kesit belirlenmiştir. Her hastadan tümörün belirgin olduğu en net iki boyutlu kesit görüntü alınarak metastatik tümörlerin veri seti oluşturulmuştur. Birincil tip glioma tümör görüntüleri ise Çin, Nanfang Hastanesi ve Tianjin Tıp Üniversitesi Genel

Hastanesi'nden toplanan online olarak erişilebilen beyin tümörü veritabanından elde edilmiştir. Kullanılan veri seti kontrastlı T1-ağırlıklı MRG görüntülerinden oluşmaktadır. Böylelikle kullanılan görüntülerin hepsi aksiyel eksende çekilmiş kontrastlı T1-ağrılıklı olarak seçilmiştir. Ayrıca radyoloji doktorların tecrübelerinden de yararlanılarak en faydalı sekansın kontrastlı T1-ağırlıklı sekans olduğu için bu sekans üzerine yoğunlaşılmıştır. Tez kapsamında diğer bir amaç ise sadece diğer sekanslar (T1, FLAIR ve difüzyon ağırlıklı MR) kullanmadan sadece kontrastlı T1 ağırlıklı iki boyutlu sekanslar kullanarak sınıflandırma gerçekleştirmektir. Bu sayede üç boyutlu görüntülerde oluşan işlem karmaşıklığının önüne geçilmek istenmektedir. Beyin metastazı teşhisi konulmuş ve farklı gruplara ait toplam 298 hasta doktorlar tarafından seçilmiştir. Metastaz tipi grupları bu gruplarda bulunan hasta sayısı Tablo 4.1'de görülmektedir. Birincil tümör tipi bilinmeyen ve kontrastlı T1-ağırlıklı sekansı olmayan hastalar, çok az sayıda hasta içeren gruplar ve farklı açıdan çekilen görüntüler çalışma dışında tutularak veri seti oluşturulmuştur.

Tablo 4.1. Metastatik tip görüntülerin grupları ve hasta sayıları

Metastazın kökeni	**Hasta sayısı**
Akciğer	159
Meme	61
Primeri bilinmeyen	17
Melanom	7
Mide	7
Renal	7
Mesane	5
Tiroid	2
Endometrium	4
Kolon-Rektum	9
Diğer	20

Sınıflandırmada kullanılacak görüntülerin hepsinin aynı standartta olması gerekmektedir. Glioma verileri onnline standardize edilmiş veri seti olduğundan veri setindeki tüm görüntüler 512×512 boyutundadır. Kocaeli Üniversitesi PACS sisteminden elde edilen verilerin incelendiğinde görüntü boyutlarının standart olmadığı görülmüştür. Tablo 4.2'de bazı hastalara ait görüntü sayıları ve boyutları görülmektedir.

Tablo 4.2. Örnek bazı hastalar için MR görüntü sayısı ve boyutu

Hasta İsmi	**Sekans**	**Görüntü boyutu**
Hasta A	T1-C	288×288
Hasta B	T1-C	256×256
Hasta C	T1-C	512×512
Hasta D	T1-C	240×240
Hasta E	T1-C	480×480

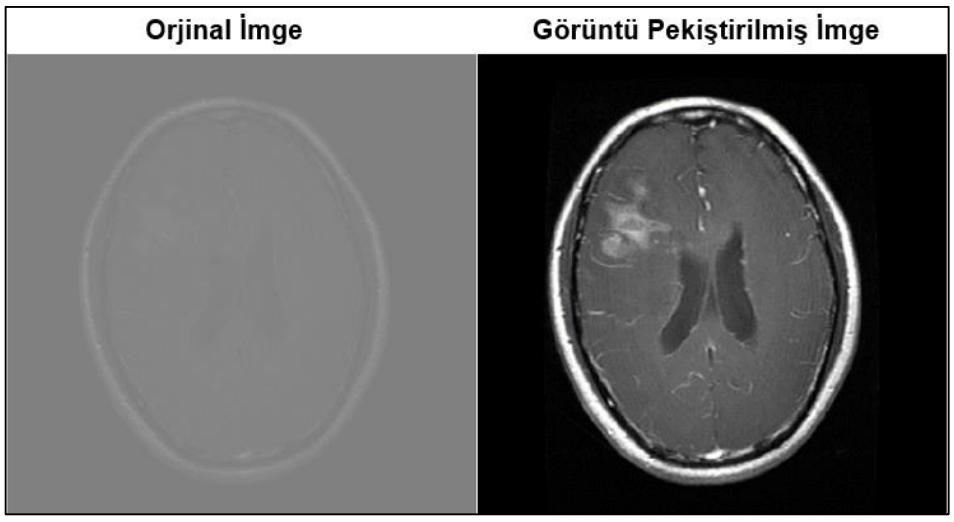
Görüntüler Tablo 4.2'de görüldüğü gibi görüntüler tutarsız oldukları için birkaç ön işlemden geçirilmiştir. Her hasta için alınan görüntüler ilk önce 512×512 boyutuna dönüştürülerek standart bir boyut elde edilmiştir. Tablo 4.3'te kullanılan sınıflandırma gruplarının sayısı, görüntü boyutu, çekildiği eksen ve sekans bilgileri verilmiştir.

Tablo 4.3. Sınıflandırma için kullanılacak hasta grupları ve özellikleri

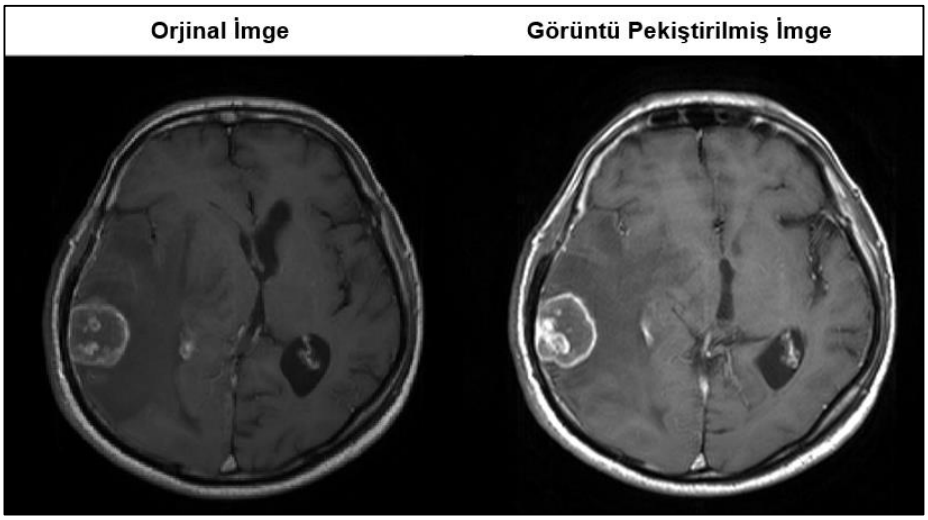
Tümör tipi	**Hasta sayısı**	**Görüntü boyutu**	**Eksen**	**Sekans**
Glioma	103	512×512	Aksiyel	T1-C
Akciğer metastazı	103	512×512	Aksiyel	T1-C
Meme metastazı	42	512×512	Aksiyel	T1-C

Glioma ve hastane resimlerinin gri seviyelerinin alt ve üst seviyeleri bulunarak tek tek doğrusal gama düzeltmesi ($\gamma = 1$) uygulanarak görüntü kontrast iyileştirilmesi gerçekleştirilmiştir.

Şekil 4.1 ve Şekil 4.2'de örnek glioma ve akciğer metastaz görüntüleri için gamma düzeltmesi uygulaması verilmiştir. Görüntüler belirtilen ön işlemlerden geçirilerek veriler sınıflandırma modellerinde kullanılmak üzere hazır hale gelmiştir.



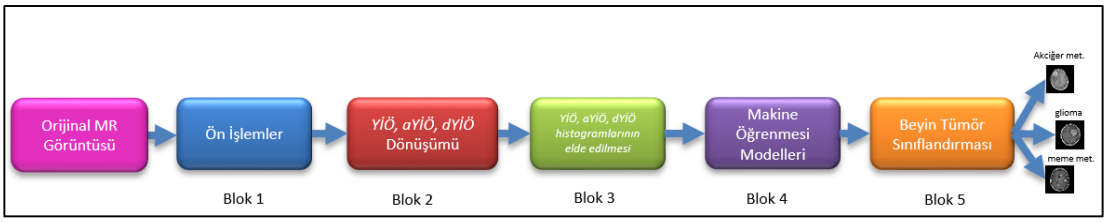
Şekil 4.1. Glioma görüntüleri için örnek gama düzeltmesi uygulaması



Şekil 4.2. Akciğer metastazı görüntüsü gama düzeltmesi uygulaması

4.1. Önerilen YİÖ Modeli

Beyin tümör tespiti için önerilen YİÖ yöntemleri birkaç aşamadan oluşmaktadır. Genellikle öznitelik çıkarım ve çıkarılan öznitelikler ile sınıflandırma işlemlerinden oluşmaktadır. Tümör tanıma için önerilen sistem Şekil 4.3'te verilmiştir. Önerilen sistem 5 aşamadan oluşmaktadır. Bu aşamalar aşağıda özetlenmiştir.



Şekil 4.3. Önerilen YİÖ sınıflandırma sistemi

Blok 1: Veri seti toplamda 248 tane iki boyutlu kesit görüntüden oluşmaktadır. Bu kesitlerin 103 tanesi glioma, 103 tanesi akciğer metastazı ve 42 tanesi de meme metastazıdır. Her MR diliminin boyutu 512×512 piksel olarak ayarlanmıştır. Daha sonra gama düzeltmesi uygulanarak görüntü kontrastları iyileştirilmiştir.

Blok 2: Görüntülere YİÖ, dYİÖ ve αYİÖ yöntemleri uygulanmıştır. Bu aşamada YİÖ görüntüleri oluşturulmuştur. Klasik YİÖ örüntülere ek olarak komşuluklarına göre dYİÖ ve açıya dayalı αYİÖ örüntüleri de elde edilerek farklı karakterde örüntüler elde edilmiştir.

Blok 3: YİÖ, dYİÖ ve αYİÖ tümör görüntülerinin histogramları oluşturulur. Histogramdaki her değer bir örüntüyü ifade eder. Bu örüntüler makine öğrenmesi yöntemler için öznitelik olarak kullanılmaktadır.

Blok 4: Sınıflandırma aşamasıdır. Bu aşamada k-NN, DVM, RO, LR ve YSA sınıflandırma modelleri kullanılmıştır. Sınıflandırma işlemleri 10-katlı çapraz geçerlilik testine göre gerçekleştirilmiştir. Sınıflandırma işlemleri 10 defa çalıştırılıp her seferinde farklı görüntüler test amaçlı kullanılmıştır. Sistemin başarısı bu 10 denemenin sonundaki sınıflandırma doğruluk ortalamasıdır. Sınıflandırma işlemleri açık kaynaklı makine öğrenmesi programı olan WEKA ortamında gerçekleştirilmiştir [125].

Blok 5: Bu aşamada model test verileri ile değerlendirilmiştir ve başarı oranları verilmiştir.

4.2. Önerilen Transfer Öğrenmesi Modelleri

Geleneksel CNN yapılarının küçük (limitli) verisetleri ile eğitim aşaması çok zor olmaktadır. Aşırı öğrenme yani ezberleme gibi eğitim aşamasında problemlerle karşılaşılmaktadır. Bu yüzden tezde hazır modeller kullanarak elde bulunan limitli veri setinden daha yüksek başarı elde edebilen önceden eğitilmiş modeller kullanılmıştır. Genel öznitelikler hazır modellerde daha önceden öğrenildiği için daha çok tercih edilmekte ve bu modeller birkaç değişiklik yapılarak kullanılabilmektedir. Şekil 4.4'te görülen önerilen transfer öğrenmesi sınıflandırma şeması aşağıda özetlenmiştir.

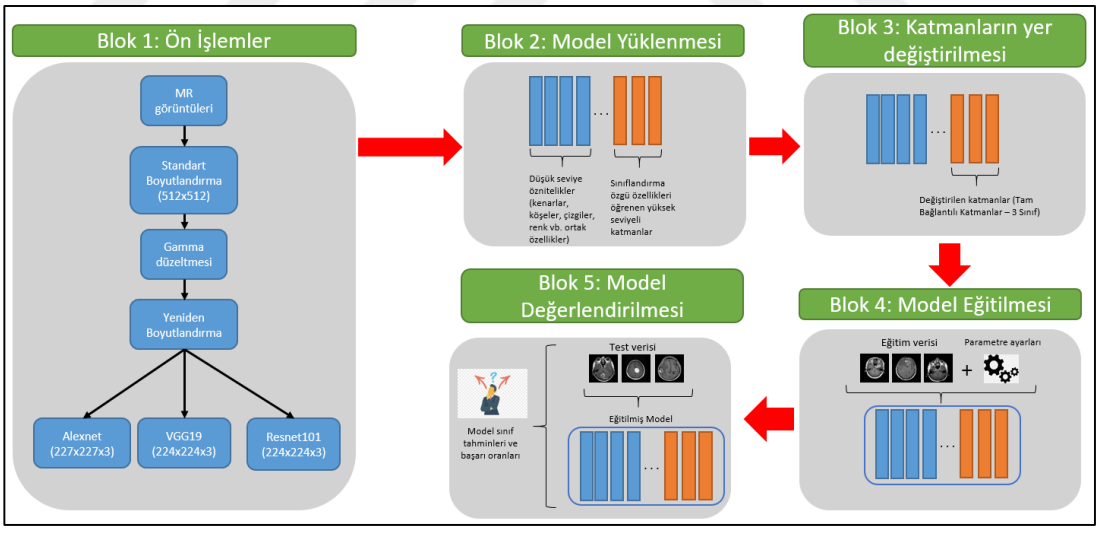
Blok 1: Veri seti toplamda 248 tane iki boyutlu kesit görüntüden oluşmaktadır. Bu kesitlerin 103 tanesi glioma, 103 tanesi akciğer metastazı ve 42 tanesi de meme metastazıdır. Her MR diliminin boyutu 512×512 piksel olarak ayarlanmıştır. Daha sonra gama düzeltmesi uygulanarak görüntü kontrastları iyileştirilmiştir. Hazır modeller kendi eğitim aşamalarında kullandıkları imge boyutlarındaki görüntüleri kabul etmektedir. Bu yüzden hazır modelleri için veri setindeki tüm görüntüler Alexnet için 227×227×3, VGG19 için 224×224×3, Resnet101 için 224×224×3 boyutlarına yeniden boyutlandırılmıştır.

Blok 2: Hazır modeller network yapısına yüklenmiştir. Hazır modellerde düşük katmanlarda kenar, köşe, çizgi, renk gibi görüntüler için düşük öznitelik (low features) denilen genel özellikler bulunurken, daha yüksek katmanlarda probleme spesifik yüksek öznitelikler (high features) bulunmaktadır.

Blok 3: Bu çalışmada kullanılan hazır modeller ImageNet veri setini sınıflandırmak için eğitilmişlerdir. Imagenet veri setinde 1000 sınıf bulunmaktadır. Sınıflandırma problemine özel olarak son softmax katmanı 3 sınıf sınıflandırabilecek şekilde değiştirilmiştir ve bu katmanda problem sınıflandırma olduğu için sınıflandırma katmanı olarak seçilmiştir.

Blok 4: Bütün ön ayarlar yapıldıktan sonra model eğitim parametreleri belirlenmiştir. Bu parametreler ve oluşturulan beyin tümör veri seti kullanılarak model eğitilmiştir.

Blok 5: Bu aşamada model test verileri ile değerlendirilmiştir ve başarı oranları elde edilmiştir. Sınıflandırma işlemleri Matlab Deep Learning Toolbox kullanılarak gerçekleştirilmiştir [126].



Şekil 4.4. Transfer öğrenmesi sınıflandırma şeması

5. DENEYSEL SONUÇLAR

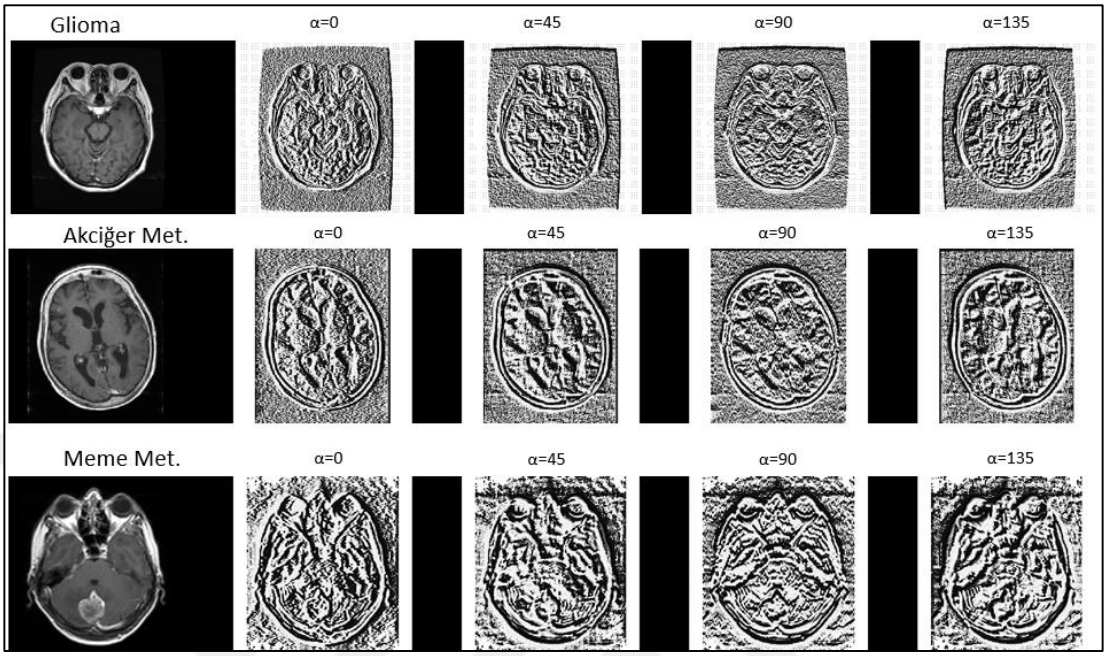
Bu tez çalışması kapsamında kontrastlı T1-ağırlıklı (T1-C) iki boyutlu glioma ve literatürde çok az çalışılan metastatik tip (akciğer metastazı, göğüs metastazı) beyin tümörlerinin sınıflandırılması gerçekleştirilmiştir. Çalışma kapsamında oluşturulan veri seti bir dizi ön işlemden geçirilerek standart hale dönüştürülmüştür. Daha sonra ilk yöntem olarak YİÖ tabanlı dYİÖ ve αYİÖ, şeklinde iki yeni yaklaşım kullanılmıştır. Bu yaklaşımlar klasik YİÖ yöntemi ile de karşılaştırılmıştır. dYİÖ, αYİÖ ve klasik YİÖ yöntemlerinden elde edilen sonuçlar verildikten sonra, bu yöntemlere ait tekdüze (uniform) özniteliklere ait sonuçlar da verilmiştir. İkinci yöntem olarak çeşitli hazır modeller kullanarak transfer öğrenmesi modelleri geliştirilmiştir. Bu yönteme ait sonuçlar için karışıklık matrisi elde edilmiş ve sonuçlar verilmiştir.

5.1. αYİÖ Yöntemine Ait Sonuçlar

Yöntemlerin başarısı ortaya çıkardıkları özniteliklerin güçlü olmalarına bağlıdır. Bu yöntemin tek parametresi vardır. α parametresi açı parametresidir. αYİÖ operatörü her pikselin değerini bir açı değerine göre hesaplamaktadır. Açı değerleri (α=0, 45, 90 ve 135) derecelerinden biri olarak seçilmiştir. αYİÖ'nin arkasındaki temel fikir, bir görüntünün mikro örüntülerden oluştuğunu varsaymasıdır. Bu mikro desenlerin histogramı, bir görüntüdeki yerel özelliklerin dağılımı hakkında bilgi içerir. Farklı beyin tümör çeşitlerine ait görüntülerin α=0, 45, 90 ve 135 açı değerleri ile elde edilen αYİÖ görüntüleri Şekil 5.1'de verilmiştir. Şekil 5.1'de α parametresinin farklı değerlerine göre farklı görüntülerin oluştuğu görülmektedir.

Histogram, sayısal bir resimde farklı renk değerinin sayısını göstermeede kullanılan bir grafiksel yöntemdir. Resmin tonları, parlaklığı hakkında histogram grafiklerinden bilgi alınabilir. Histogramlar piksel değerlerinin ağırlığını belirten grafiksel değerlerdir. Histogramları kullanarak görüntü matrislerimizde daha doğru değerler yükleyebiliriz. Bir histogram ne kadar ayrıksa görüntü o kadar nettir. Şekil 5.2'de elde

edilen görüntülerin histogramları verilmiştir. Histogramlardan görüldüğü gibi α parametresinin değeri değiştikçe örüntülerin farklı dağıldığı görülmektedir.



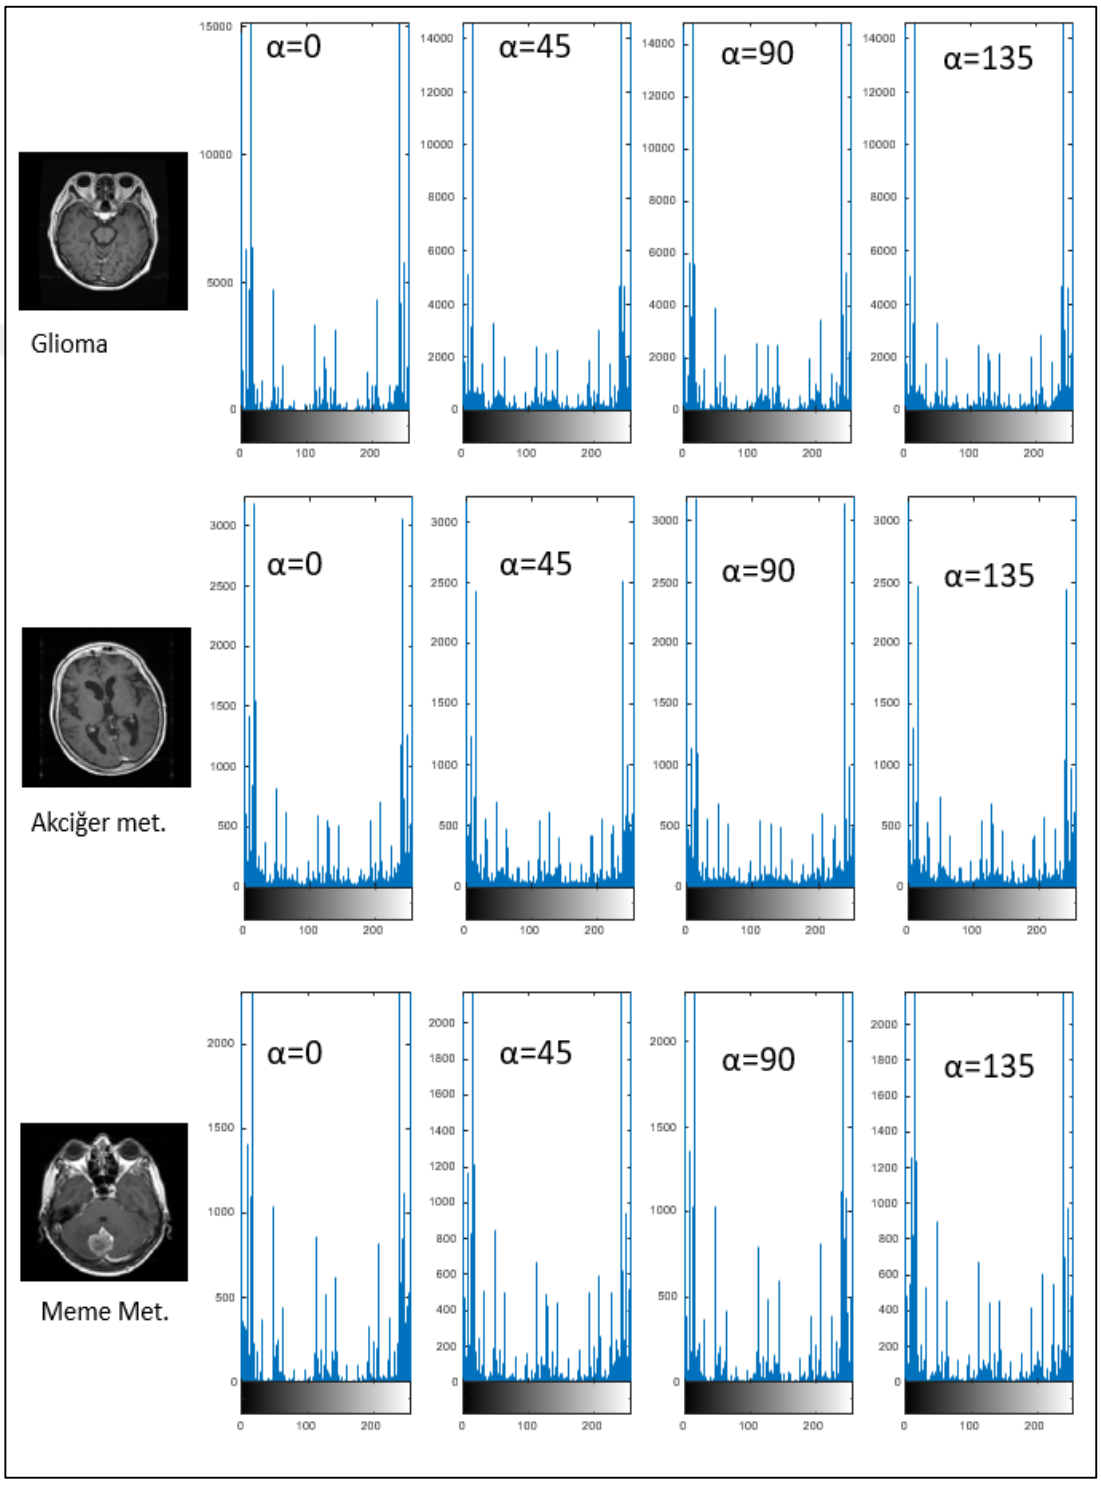
Şekil 5.1. αYİÖ yönteminin farklı α değerlerine göre oluşturduğu görüntüler

αYİÖ ile elde edilen örüntüler ile sınıflandırma işlemi gerçekleştirmek için DVM, k-NN, ANN, LR, RO gibi farklı makine öğrenmesi modelleri kullanılmıştır. Sınıflandırma işleminde 10 katlı çapraz geçerlilik testi kullanılmıştır. Elde edile başarı oranları Tablo 5.1'de verilmiştir. En yüksek başarı oranı %82,66 olarak α parametresinin α=45 olduğu DVM modeli ile elde edilmiştir. Tablo 5.1'den görüldüğü gibi kullanılan tüm makine öğrenmesi yöntemlerinde kabul edilebilir sonuçlar gözlenmiştir. α değerine denemeler sonucunda karar verilmelidir. α parametresinin başarı oranı küçük veya büyük α değerilerine bağlı değildir. En etkin öznitelikler elde edilebilen α değeri deneme-yanılma yöntemi ile bulunabilir.

Tablo 5.1. αYİÖ öznitelikler ile elde edilen başarı sonuçları (%)

Açı (α)	**DVM**	**k-NN**	**YSA**	**LR**	**RO**
0	81,45	81,45	80,64	73,79	81,85
45	**82,66**	78,62	81,85	77,41	81,09
90	81,45	77,01	79,03	72,58	81,45
135	82,25	77,82	79,43	76,80	82,25

En iyi sınıflandırma metodu için elde edilen karışıklı matrisi Tablo 5.2'de verilmiştir. Tablo 5.2'de karışıklık matrisinde görüldüğü üzere αYİÖ modelinde en çok akciğer metastazı ve meme metastazı sınıflarının birbiri ile karıştırıldığı görülmektedir. Glioma ve metastatik tümör ayrımında modelin çok başarılı olduğu görülmüştür.



Şekil 5.2. αYİÖ yönteminde farklı α değerleri ile oluşan histogramlar

Tablo 5.2. DVM ve αYİÖ$_{\alpha=45}$ ile elde edilen karışıklık matrisi

Sınıflar		**Gerçek sınıf**		
		Glioma	Akciğer Met.	Meme Met.
Tahmin edilen sınıf	Glioma	103	0	0
	Akciğer Met.	0	98	5
	Meme Met.	0	38	4

Karışıklık matrisi kullanılarak her bir sınıf için hassasiyet (R), kesinlik (P) ve f-ölçütü değerleri hesaplanmıştır. Bulunan değerler Tablo 5.3'te verilmiştir. Daha sonra sınıf sayıları dikkate alınarak ağırlıklı ortalama hesaplanmıştır. Tablo 5.3'e bakıldığında f-ölçütü değeri 0,782, R değeri 0,790, P değeri ise 0,827 olarak hesaplanmıştır. αYİÖ performans değerlerine bakıldığında; glioma ve metastaz tip tümörler arasındaki sınıflandırma çok başarılı sonuçlar elde edirken, akciğer ve meme metastaz tip tümörlerin arasındaki sınıflandırmada düşük performans ölçütleri elde edilmiştir.

Tablo 5.3. DVM ve αYİÖ$_{\alpha=45}$ için performans ölçütleri

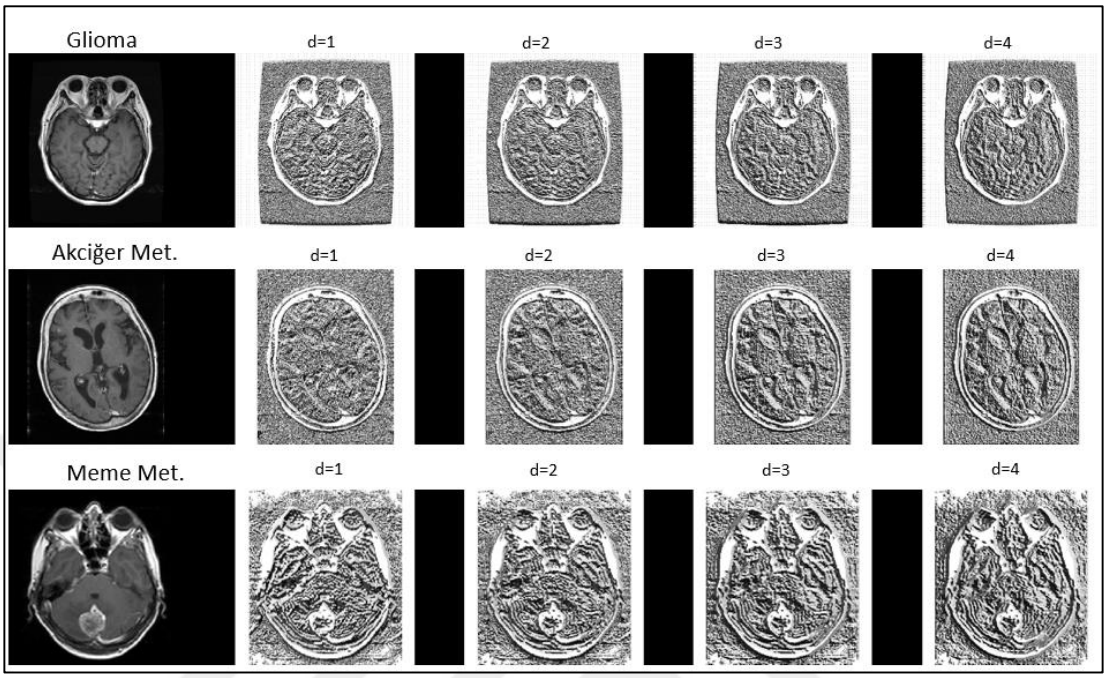
Sınıf	**Hassasiyet (R)**	**Kesinlik (P)**	**f-ölçütü**
Glioma	1,000	1,000	1,000
Akciğer Met.	0,721	0,951	0,820
Meme Met.	0,444	0,095	0,157
Ağırlıklı Ortalama	0,790	0,827	0,782

5.2. dYİÖ Yöntemine Ait Sonuçlar

Beyin tümörün tespitinde başarı görüntülerden elde edilen özniteliklerin etkinliğine bağlıdır. Geometrik veya dokusal yöntemler ile çıkarılan öznitelikler sınıflandırma metodun başarısını etkilemektedir. Bu modelde YİÖ tabanlı dYİÖ yönteminin beyin tümörü çeşidini tanımada olan etkinliği incelenmiştir. dYİÖ metodu mesafe *d* parametresine bağlıdır. Bu parametrenin değerine göre farklı öznitelikler elde edilmektedir. Veri setimizden üç farklı beyin tümörü çeşidine bağlı olarak *d* parametresinin farklı örüntüler oluşturduğu Şekil 5.3'te verilmiştir. *d* parametresinin farklı değerlerine göre farklı tümör görüntülerin oluştuğu Şekil 5.3'te görülmektedir.

Elde edilen öznitelikleri daha ayrıntılı görmek için yeni oluşan dYİÖ bu görüntülerin histogramlarının incelenmesi gerekir. Şekil 5.4'te bu elde edilen dYİÖ görüntülerin histogramları verilmiştir. Histogramlardan görüldüğü gibi *d* parametresinin değeri arttıkça örüntülerin kaybolduğu görülmektedir. Değerlerin kaybolması ile görüntüleri

en iyi karakterize eden öznitelikler kaybedilebileceğinden sınıflandırma başarı doğruluklarında da azalmalar meydana gelebilir.



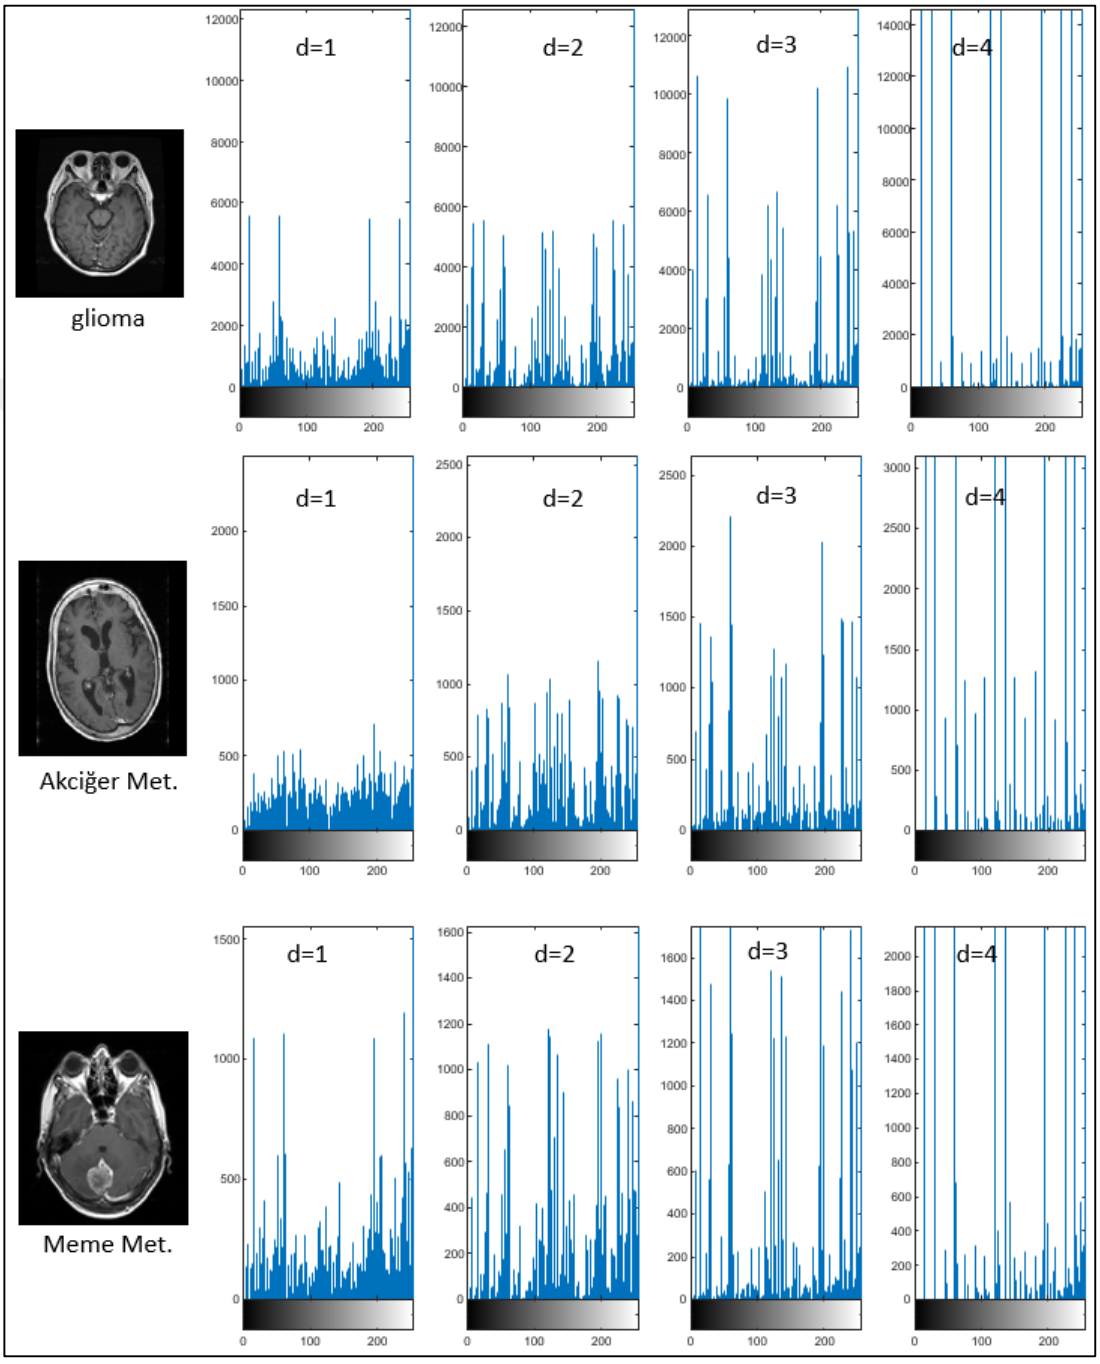
Şekil 5.3. dYİÖ yönteminin farklı d değerlerine göre oluşturduğu görüntüler

dYİÖ ile elde edilen örüntüler kullanılarak DVM, k-NN, ANN, LR, RO gibi farklı makine öğrenmesi yöntemler ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi Weka açık kaynak veri madenciliği aracı ile gerçekleştirilmiştir. 10 katlı çapraz doğruluk test uygulanarak elde edilen başarı sonuçları Tablo 5.4'te verilmiştir. Tablo 5.4'ten görüldüğü gibi genel olarak yüksek kabul edilebilir sonuçlar gözlenmiştir. En yüksek başarı oranı %93,54 olarak d=1 olduğu öznitelikler ve YSA modeli ile elde edilmiştir. Bazı örüntüler kaybolduğunda bazı modellerin *d* parametresinin değeri arttıkça başarı oranının düştüğü görülmektedir. Ancak *d*'nin farklı değerlerine bakmak gerekir. Farklı çalışmalarda bu parametrenin farklı değerlerin incelenmesi gerekebilir.

Tablo 5.4. dYİÖ öznitelikler ile elde edilen başarı sonuçları(%)

Mesafe (d)	**DVM**	**k-NN**	**YSA**	**LR**	**RO**
d=1	90,72	87,09	**93,54**	91,53	89,91
d=2	92,33	89,91	90,72	88,30	90,32
d=3	90,72	85,45	92,74	87,50	87,5
d=4	81,04	86,69	92,33	88,30	90,72

En iyi sınıflandırma metodu için elde edilen karışıklı matrisi Tablo 5.5'te verilmiştir. Tablo 5.5'te karışıklık matrisinde görüldüğü üzere dYİÖ metodunda en çok akciğer metastazı ve meme metastazı sınıflarının birbiri ile karıştırıldığı görülmektedir.



Şekil 5.4. dYİÖ yönteminde farklı d ile oluşan histogramlar

Karışıklık matrisi kullanılarak Tablo 5.6'daki hassasiyet (R), kesinlik (P) ve f-ölçütü değerleri hesaplanmıştır. Daha sonra sınıf sayılarına göre her sınıfa ağırlıklı katsayı

verilerek ağırlıklı ortalama hesaplanmıştır. Tablo 5.6'ya bakıldığında f-ölçütü değeri 0,936, R değeri 0,936, P değeri ise 0,935 olarak hesaplanmıştır. dYİÖ performans değerlerine bakıldığında; glioma ve metastaz tip tümörler arasındaki sınıflandırmada sadece 1 örnek yanlış sınıflandırılmışken, akciğer ve meme metastaz tip tümörlerin arasındaki 15 örneğin yanlış sınıflandırıldığı görülmüştür.

Tablo 5.5. YSA ve dYİÖ$_{d=1}$ ile elde edilen karışıklık matrisi

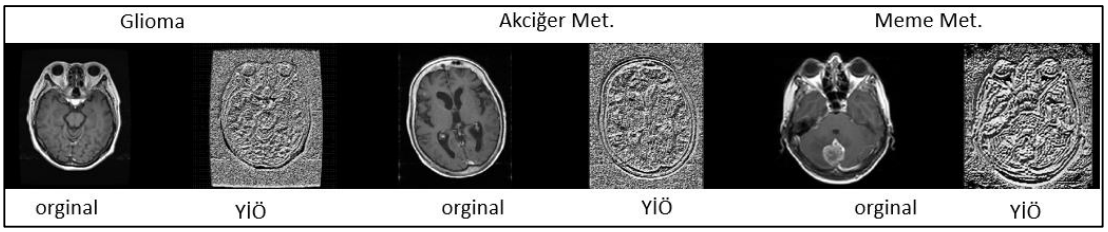
Sınıflar		**Gerçek sınıf**		
		Glioma	Akciğer Met.	Meme Met.
Tahmin edilen sınıf	Glioma	103	0	0
	Akciğer Met.	1	94	8
	Meme Met.	0	7	35

Tablo 5.6. YSA ve dYİÖ$_{d=1}$ ile elde edilen performans ölçütleri

Sınıf	**Hassasiyet (R)**	**Kesinlik (P)**	**f-ölçütü**
Glioma	0,990	1,000	0,995
Akciğer Met.	0,931	0,913	0,922
Meme Met.	0,814	0,833	0,824
Ağırlıklı Ortalama	0,936	0,935	0,936

5.3. Klasik YİÖ Sonuçları

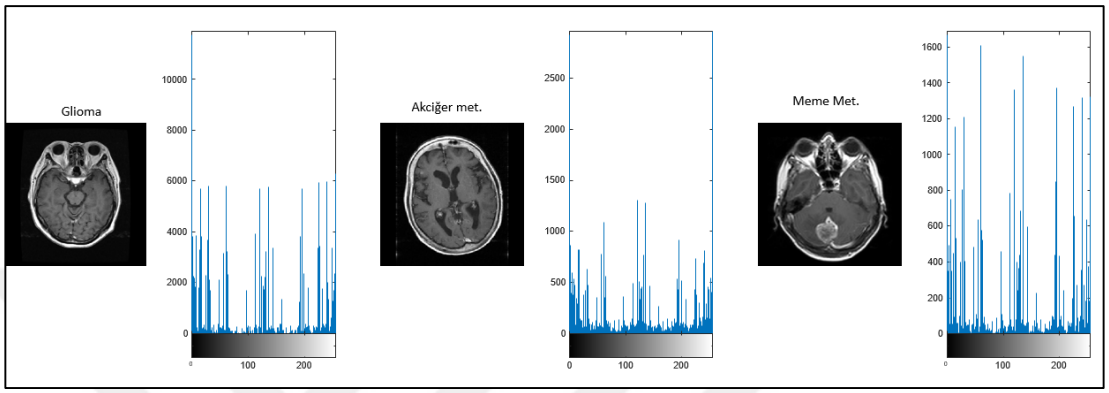
Önerilen yöntemlerin klasik YİÖ yöntemi ile karşılaştırılması gerekir. Klasik YİÖ ile görüntülerden tek bir öznitelik kümesi elde edilirken [31-32], dYİÖ ve αYİÖ yöntemlerinde *d* ve *α* parametrelerine göre farklı öznitelik grupları elde edilmektedir. Farklı beyin tümörü görüntülere YİÖ yönteminin uygulanması sonucu elde edilen görüntüler Şekil 5.5'te verilmiştir.



Şekil 5.5. Orjinal ve YİÖ görüntüleri

Beyin tümörü tipine göre YİÖ görüntülere ait histogramlar Şekil 5.6'da verilmiştir. Histogramlara bakıldığında her sınıfa ait farklı örüntüler elde edğildiği görülmektedir. Klasik YİÖ ile elde edilen örüntüler ile sınıflandırma işlemi gerçekleştirmek için

DVM, k-NN, ANN, LR, RO gibi farklı makine öğrenmesi modelleri kullanılmıştır. Sınıflandırma işleminde 10 katlı çapraz geçerlilik testi uygulanmıştır. Elde edile doğruluk oranları Tablo 5.7'de verilmiştir. En yüksek başarı oranı %83,46 olarak DVM modeli ile elde edilmiştir. Tablo 5.7'den görüldüğü gibi kullanılan kullanılan makine öğrenmesi modellerinde kabul edilebilir sonuçlar gözlenmiştir.



Şekil 5.6. YİÖ görüntülerine ait histogramlar

Tablo 5.7. YİÖ öznitelikler ile elde edilen başarı oranları (%)

Model	**DVM**	**k-NN**	**YSA**	**LR**	**RO**
Doğruluk Oranı	**83,46**	80,64	80,24	80,64	81,45

En iyi sınıflandırma metodu için elde edilen karışıklı matrisi Tablo 5.8'de verilmiştir. Tablo 5.8'de karışıklık matrisinde incelendiğinde klasik YİÖ modelinde en çok akciğer metastazı ve meme metastazı sınıflarının yanlış sınıflandırıldığı görülmektedir.

Tablo 5.8. DVM ile YİÖ için elde edilen karışıklık matrisi

Sınıflar		**Gerçek sınıf**		
		Glioma	Akciğer Met.	Meme Met.
Tahmin edilen sınıf	Glioma	103	0	0
	Akciğer Met.	0	96	7
	Meme Met.	0	34	8

Karışıklık matrisi kullanılarak Tablo 5.9'daki hassasiyet (R), kesinlik (P) ve f-ölçütü değerleri hesaplanmıştır. Model dengesiz sınıf içerdiğinden, sınıf sayıları dikkate alınarak ağırlıklı ortalama hesaplanmıştır. Tablo 5.9'a bakıldığında f-ölçütü değeri 0,805, R değeri 0,812, P değeri 0,835 olarak hesaplanmıştır. Klasik YİÖ performans değerlerine bakıldığında; glioma ve metastaz tip tümörler arasındaki sınıflandırmada

hata yapılmamışken, akciğer ve meme metastaz tip tümörlerin arasındaki 41 örneğin yanlış sınıflandırıldığı görülmüştür.

Tablo 5.9. YİÖ öznitelikler ile gözlenen performans ölçütleri

Sınıf	**Hassasiyet (R)**	**Kesinlik (P)**	**f-ölçütü**
Glioma	1,000	1,000	1,000
Akciğer Met.	0,738	0,932	0,824
Meme Met.	0,533	0,190	0,281
Ağırlıklı Ortalama	0,812	0,835	0,805

5.4. Tekdüze (Uniform) Örüntüler için Sonuçlar

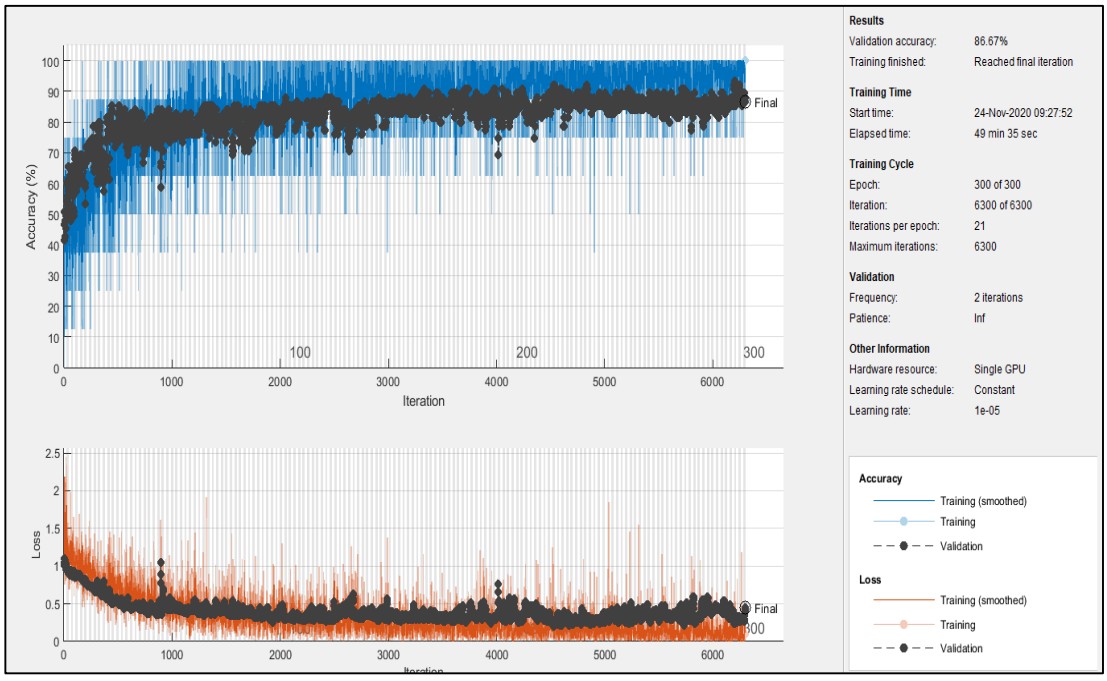
Görüntülerdeki yüzeylerinin büyük bir kısmı uniform örüntülerden oluşmakdır. İkili YİÖ kodunda 0'dan 1'e veya 1'den 0'a geçiş sayısı 2 veya daha az ise bu örüntüler uniform örüntülerdir. İkili kodunda 00000000 ve 11111111 örüntülerinde 0 geçiş sayısı, 01100000 ve 11000011 örüntülerinde 2 geçiş sayısı olduğundan bu örüntüler uniform örüntülerdir. Uniform örüntüler kullanılarak bir görüntüdeki kenar, spot, köşe gibi genel basit dokular belirlenebilmektedir. Bir görüntüde P(P-1)+2 sayısı kadar uniform örüntü vardır. YİÖ, dYİÖ ve αYİÖ yöntemleri ile elde edilen tekdüze örüntüler kullanılarak YSA ile sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen doğruluk oranları Tablo 5.10'da verilmiştir. Tekdüze örüntülerin sonuçlarına bakıldığında αYİÖ örüntüler için %81,45 olarak α parametresinin α=45 ve α=90 olması durumunda elde edilmiştir. Genel olarak ortalama başarı oranları gözlenmiştir. Klasik YİÖ metodunda ise tekdüze örüntüler ile %81,85 gibi başarı oranı elde edilmiştir. En yüksek başarı oranı ise dYİÖ metodunun d parametresinin d=4 olduğu tekdüze örüntüleri ile %93,54 olarak gözlenmiştir.

Tablo 5.10. Tekdüze örüntülere ait başarı oranları

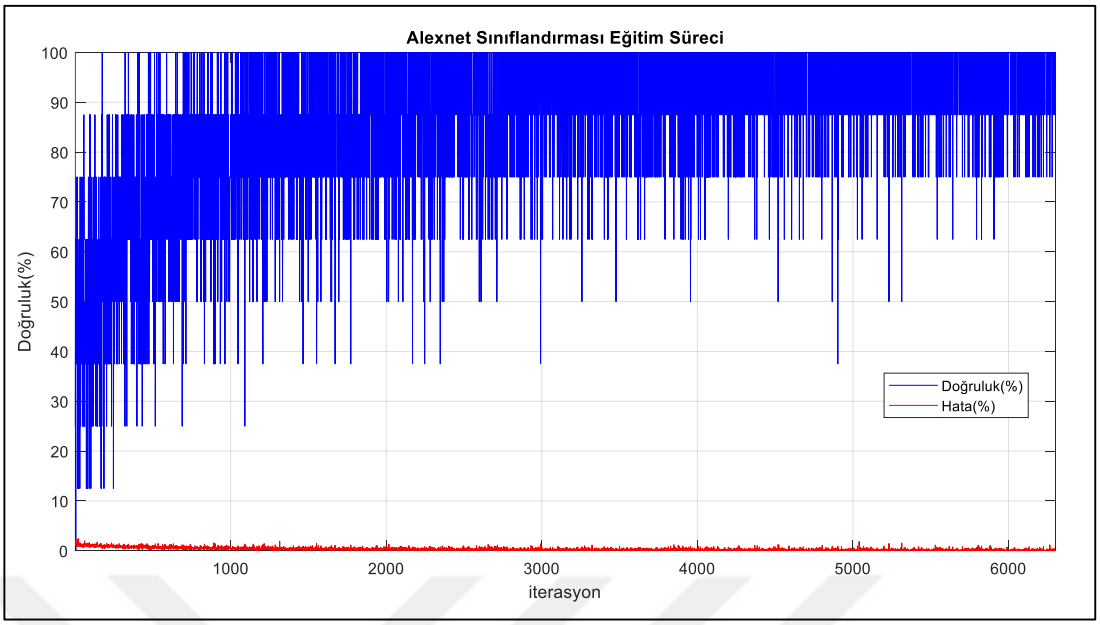
αYİÖ		**dYİÖ**		**YİÖ**
Açı(α)	**Doğruluk(%)**	**Mesafe (d)**	**Doğruluk(%)**	**Doğruluk(%)**
α=0	77,41	d=1	92,33	81,85
α=45	81,45	d=2	90,32	-
α=90	81,45	d=3	91,93	-
α=135	80,24	d=4	**93,54**	-

5.5. Alexnet Modeli ile Elde Edilen Sonuçlar

Alexnet modeli mimarisi gereği girişinde 227×227×3 boyutlu görüntüleri kabul etmektedir. Modelde kullanılacak veriler ön işlemden geçirildikten sonra Alexnet mimarisinde kullanılmak üzere 512×512 boyuttan 227×227×3 boyuta dönüştürülmüştür. Gri seviyeli imgeler RGB (Red, Green, Blue) kanalının üç boyutuna da yerleştirilerek üç boyutlu imgeler elde edilmiştir. Daha sonra Alexnet çıkış katmanına üç çıkışlı softmax sınıflandırma katmanı mimaride bulunan 1000 çıkışlı softmax katmanı ile değiştirilmiştir. Model parametreleri olarak ADAM optimizasyonu, 10^{-5} öğrenme oranı, epoch sayısı 300 ve batch boyutu 8 olacak şekilde girilmiştir. Veri setinin %70'i eğitim için, %30'u test için kullanılmıştır. Eğitim aşamasından sonra kaydedilen eğitilmiş model 5 kez çalıştırılarak ortaklama test doğruluğu elde edilmiştir. Ortalama doğruluğuna en yakın sonuç için karışıklık matrisi bulunmuş ve performans ölçütleri verilmiştir. Aynı zamanda İşlem Karakteristik (Receiver Operating Characteristic, ROC) eğrileri de çizdirilmiş ve AUC değerleri hesaplanmıştır. Şekil 5.7'de Alexnet mimarisinin eğitim süreci görülmektedir. Şekil 5.8'de ise Alexnet eğitim sürecinde eğitim doğruluğu ve hatası gözükmektedir. Görüldüğü üzere Alexnet modeli ezberleme yapmadan, sürekli artan doğruluk oranı ve azalan hata (kayıp-loss) değeri ile eğitim sürecini tamamlamıştır.



Şekil 5.7. Alexnet modeli eğitim süreci



Şekil 5.8. Alexnet eğitim doğruluk ve hata grafiği

Model eğitim aşamasından sonra kaydedilmiş olup eğitilmiş model 5 kez test edilmiştir. Tablo 5.11'den görüldüğü üzere ortalama %89,33 doğruluk oranı elde edilmiştir. Ortalama doğruluğuna en yakın sonuç olan 3. test deneme değeri %89,33 için karışıklık matrisi Tablo 5.12'de verilmiştir. Karışıklık matrisinden de anlaşılabileceği gibi meme metastazına ait örneklerin diğer gruplardan daha az olması sebebiyle modelin en başarısız olduğu grup olduğu ve akciğer metastazı ile karıştırıldığı görülmüştür. Toplamda 8 test verisi yanlış sınıflandırılmıştır.

Tablo 5.11. Denemeler sonucu elde edilen doğruluk ortalaması

1.Deneme	**2.Deneme**	**3.Deneme**	**4.Deneme**	**5.Deneme**	**Ortalama (%)**
86,67	90,67	89,33	92,00	88,00	89,33

Tablo 5.12. Alexnet mimarisi ile elde edilen karışıklık matrisi

Sınıflar		**Gerçek sınıf**		
		Akciğer Met.	Glioma	Meme Met.
Tahmin edilen sınıf	Akciğer Met.	31	0	0
	Glioma	0	31	0
	Meme Met.	8	0	5

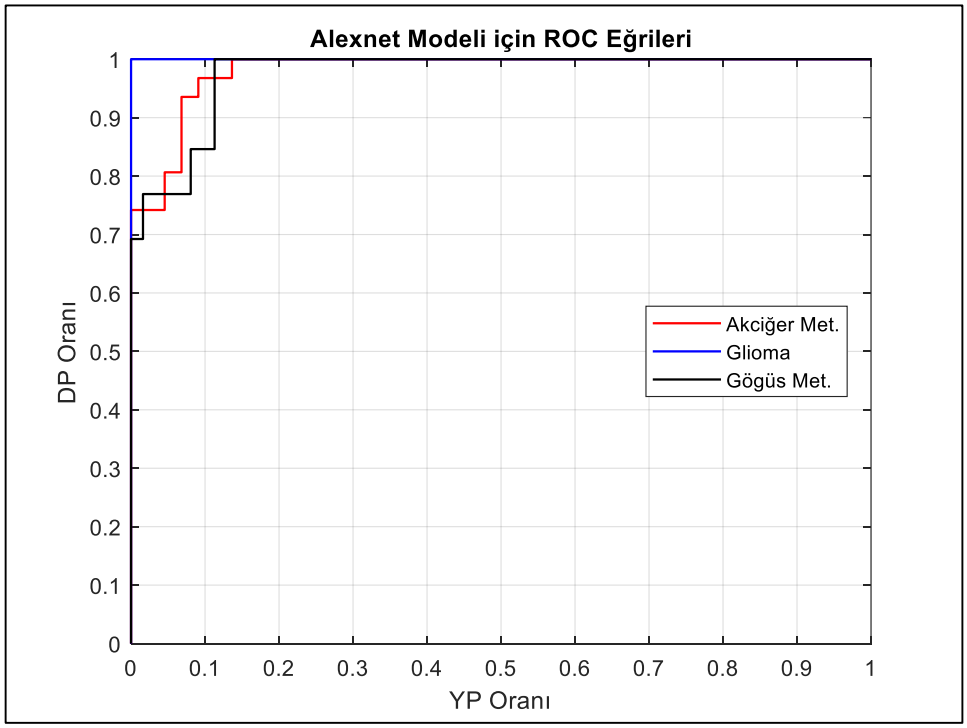
Karışıklık matrisi kullanılarak her bir sınıf için hassasiyet (R), kesinlik (P) ve f-ölçütü değerleri bulunmuştur. Bulunan değerler Tablo 5.13'te verilmiştir. Daha sonra sınıflarda bulunan sayılar dikkate alınarak ağırlıklı ortalama hesaplanmıştır. Tablo

5.13'e bakıldığında f-ölçütü değeri 0,877, hassasiyet 0,9148, kesinlik 0,8953 olarak hesaplanmıştır. Karışıklık matrisine bakıldığında glioma ve metastaz tip tümörler arasındaki ayrım net bir şekilde gerçekleştirilirken, akciğer ve meme metastaz tip tümörlerin arasındaki sınıflandırılmasında 8 örnek yanlış sınıflandırılmıştır.

Tablo 5.13. Alexnet için performans ölçütleri

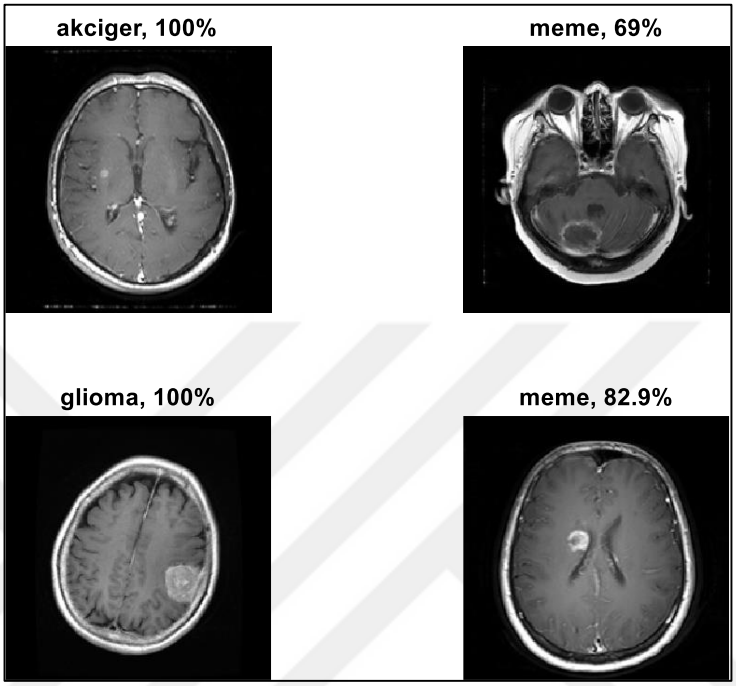
Sınıf	**Hassasiyet (R)**	**Kesinlik (P)**	**f-ölçütü**	**AUC Değeri**
Akciğer Met.	0,7949	1,0000	0,8857	0,9809
Glioma	1,0000	1,0000	1,000	1,000
Meme Met.	1,0000	0,3846	0,5556	0,9752
Ağırlıklı Ortalama	0,9148	0,8953	0,8770	0,9878

Şekil 5.9'daki ROC eğrilerine bakıldığında kırmızı renkli çizgi akciğer metastazını, mavi renkli çizgi glioma ve siyah renkli çizgi ise meme metastazı tümör tipine ait olan eğrileri temsil etmektedir. Sınıflara ait olan ROC eğrileri sol üst köşeye yakın olduğu için verilen test verisi için başarılı sınıflandırma gerçekleştirilmiştir. En başarısız sınıfın meme metastazına ait olduğu görülmüştür. Eğri altındaki kalan alanlara bakıldığında AUC değerleri akciğer metastazı, glioma ve meme metastazı için sırasıyla 0,9809, 1,0000, 0,9752 bulunmuş ve ağırlıklı ortalaması 0,9878 olarak hesaplanmıştır.



Şekil 5.9. Alexnet için ROC eğrileri

Şekil 5.10'da ise test veri setinden rastgele seçilen örnekler softmax katmanı çıkışı olasılık değerleri ile beraber gösterilmiştir. En düşük sınıflandırma doğruluğuna ait grubunun meme metastazı tip beyin tümör grubu olduğu örneklerden de anlaşılmaktadır.

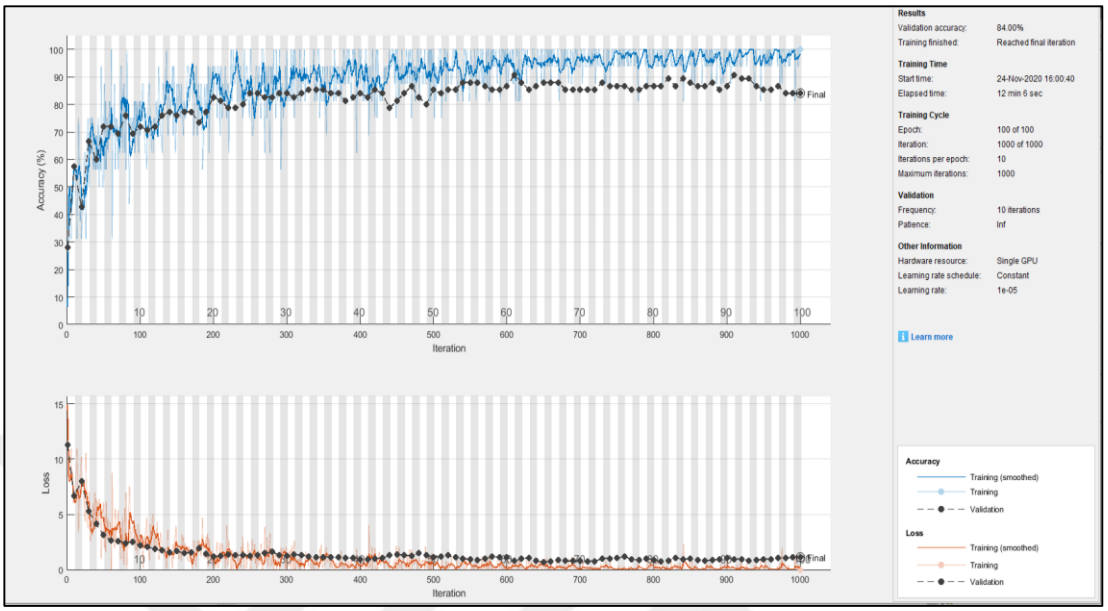


Şekil 5.10. Örnek sınıflandırma sonuçları

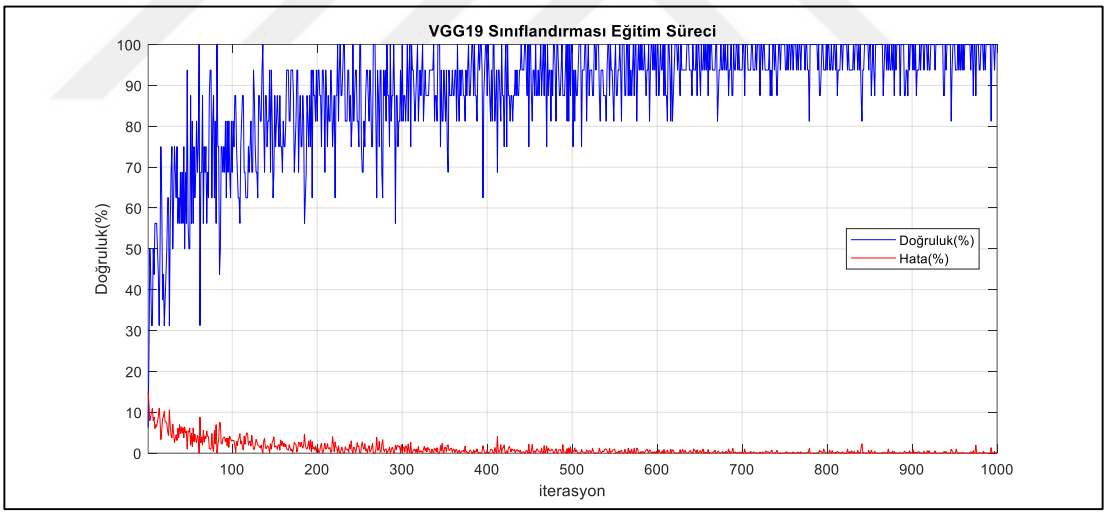
5.6. VGG19 Modeli ile Elde Edilen Sonuçlar

VGG19 modeli mimarisi giriş imgesi olarak 224×224×3 boyutlu görüntüleri kabul etmektedir. Modelde kullanılacak veriler ön işlemden geçirildikten sonra 224×224×3 boyuta dönüştürülmüştür. Daha sonra VGG19 modeli mimarisinde bulunan 1000 çıkışlı softmax katmanı yerine üç çıkışlı softmax sınıflandırma katmanı eklenmiştir. Model parametreleri ADAM optimizasyonu, 10^{-5} öğrenme oranı, epoch sayısı 100 ve batch boyutu 16 olarak ayarlanmıştır. Veri setinin %70'i eğitim için, %30'u test için kullanılmıştır. Eğitilmiş model kaydedildikten sonra 5 kez çalıştırılarak ortaklama test doğruluğu elde edilmiştir. Ortalama doğruluğa en yakın sonuç için karışıklık matrisi bulunmuş ve değerlendirme ölçütleri hesaplanmıştır. Farklı bir değerlerindirme ölçütü olan ROC eğrileri çizdirilmiş ve AUC değerleri hesaplanmıştır. Şekil 5.11'de VGG19 mimarisinin eğitim prosesi gösterilmiştir. Şekil 5.12'de ise VGG19 modelinin eğitim

doğruluğu ve hatası gözükmektedir. VGG19 modeli ezberleme yapmadan, sürekli artan doğruluk oranı ve azalan hata değeri ile eğitim sürecini tamamladığı görülmüştür.



Şekil 5.11. VGG19 modeli eğitim süreci



Şekil 5.12. VGG19 eğitim doğruluk ve hata grafiği

Model eğitim aşamasından sonra kaydedilerek eğitilmiş model rastgele seçilen test verileri ile 5 kez test edilmiştir. Tablo 5.14'te 5 deneme sonucunda ortalama %94,66 doğruluk oranı elde edilmiştir. Ortalama doğruluğuna en yakın sonuç olan 3. test deneme değeri %94,67 için elde edilen karışıklık matrisi Tablo 5.15'te verilmiştir. Karışıklık matrisinden de anlaşılabileceği gibi meme metastazına ait örneklerin diğer gruplardan daha az olması sebebiyle modelin en başarısız olduğu grup olduğu ve

örneğin akciğer metastazı ile karıştırıldığı görülmüştür. Toplamda 4 örnek yanlış sınıflandırılmıştır.

Tablo 5.14. Denemeler sonucu elde edilen doğruluk ortalaması

1.Deneme	2.Deneme	3.Deneme	4.Deneme	5.Deneme	Ortalama (%)
96,00	93,33	94,67	97,33	92,00	94,66

Tablo 5.15. VGG19 mimarisi ile elde edilen karışıklık matrisi

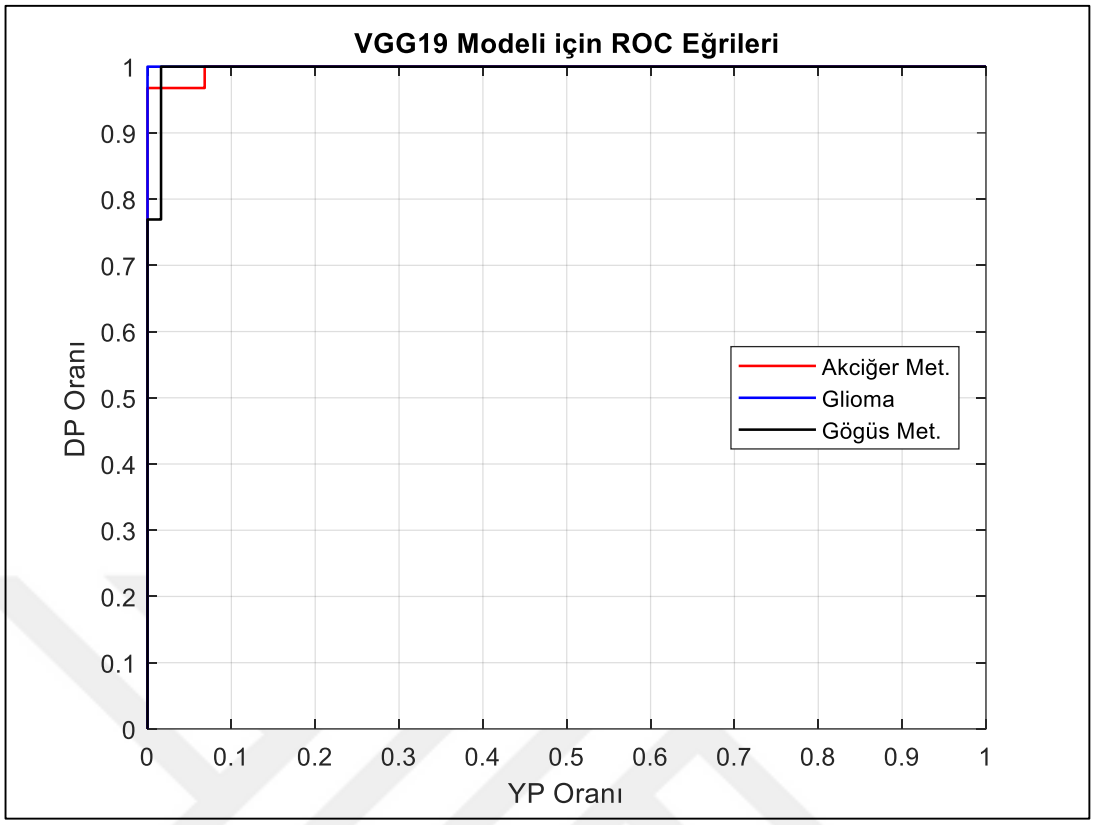
Sınıflar		Gerçek sınıf		
		Akciğer Met.	Glioma	Meme Met.
Tahmin edilen sınıf	Akciğer Met.	30	0	1
	Glioma	0	31	0
	Meme Met.	3	0	10

Karışıklık matrisi kullanılarak her bir sınıf için hassasiyet (R), kesinlik (P) ve f-ölçütü değerleri bulunmuştur. Bulunan değerler Tablo 5.16'da verilmiştir. Daha sonra sınıflarda bulunan sayılar dikkate alınarak ağırlıklı ortalama hesaplanmıştır. Tablo 5.16'ya bakıldığında f-ölçütü değeri 0,9457, hassasiyet 0,9468, kesinlik 0,9473 olarak hesaplanmıştır. Karışıklık matrisine bakıldığında glioma ve metastaz tip tümörler arasındaki ayrım net bir şekilde gerçekleştirilirken, akciğer ve meme metastaz tip tümörlerin arasındaki sınıflandırılmasında 8 örnek yanlış sınıflandırılmıştır.

Tablo 5.16. VGG19 için performans ölçütleri

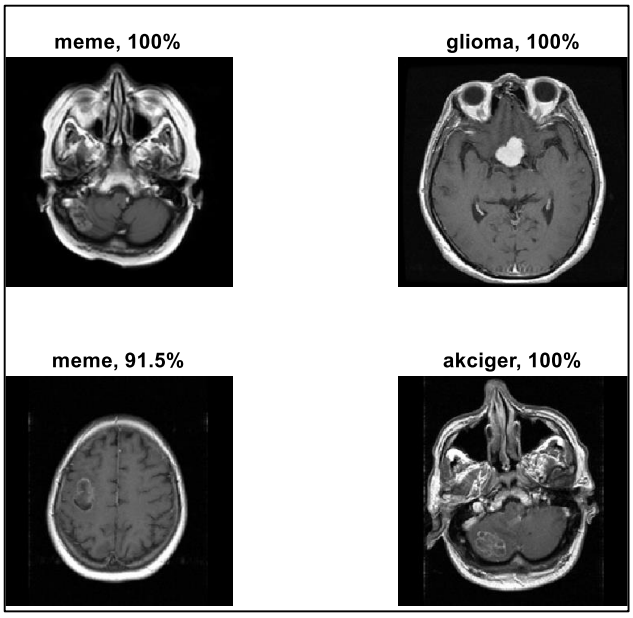
Sınıf	Hassasiyet (R)	Kesinlik (P)	f-ölçütü	AUC Değeri
Akciğer Met.	0,9091	0,9677	0,9375	0,9978
Glioma	1,0000	1,0000	1,0000	1,0000
Meme Met.	0,9091	0,7692	0,8333	0,9963
Ağırlıklı Ortalama	0,9468	0,9473	0,9457	0,9984

Şekil 5.13'teki ROC eğrilerine bakıldığında kırmızı renkli çizgi akciğer metastazını, mavi renkli çizgi glioma ve siyah renkli çizgi ise meme metastazı tümör tipine ait olan eğrileri göstermektedir. Sol üst köşeye yakın olan ROC eğirileri için verilen test verisi ile başarılı sınıflandırma gerçekleştirilmiştir. Sınıflar içerisinde en başarısız sınıfın meme metastazına ait olduğu görülmüştür. Eğri altındaki kalan alanlara bakıldığında AUC değerleri akciğer metastazı, glioma ve meme metastazı için sırasıyla 0,9978, 1,0000, 0,9963 olarak hesaplanmış ve ağırlıklı ortalaması 0,9984 olarak bulunmuştur.



Şekil 5.13. VGG19 için ROC eğrileri

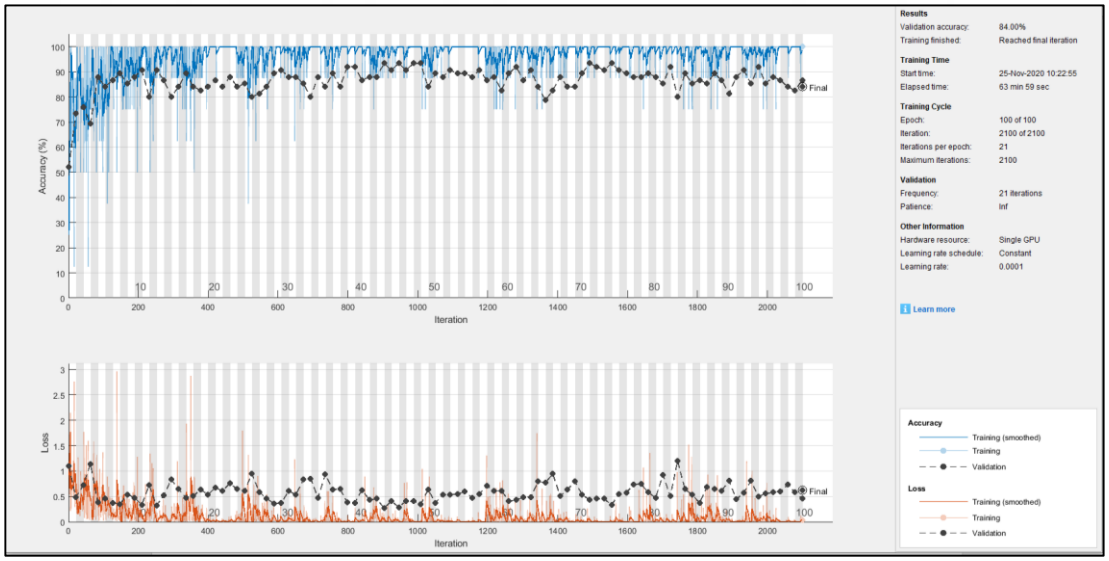
Şekil 5.14'te ise test veri setinden rastgele seçilen örnekler doğrulukları ile beraber verilmiştir. En düşük sınıflandırma doğruluğuna ait sınıfın bu modelde de meme metastazı tip beyin tümör grubu olduğu görülmüştür.



Şekil 5.14. Örnek sınıflandırma sonuçları

5.7. Resnet101 Modeli ile Elde Edilen Sonuçlar

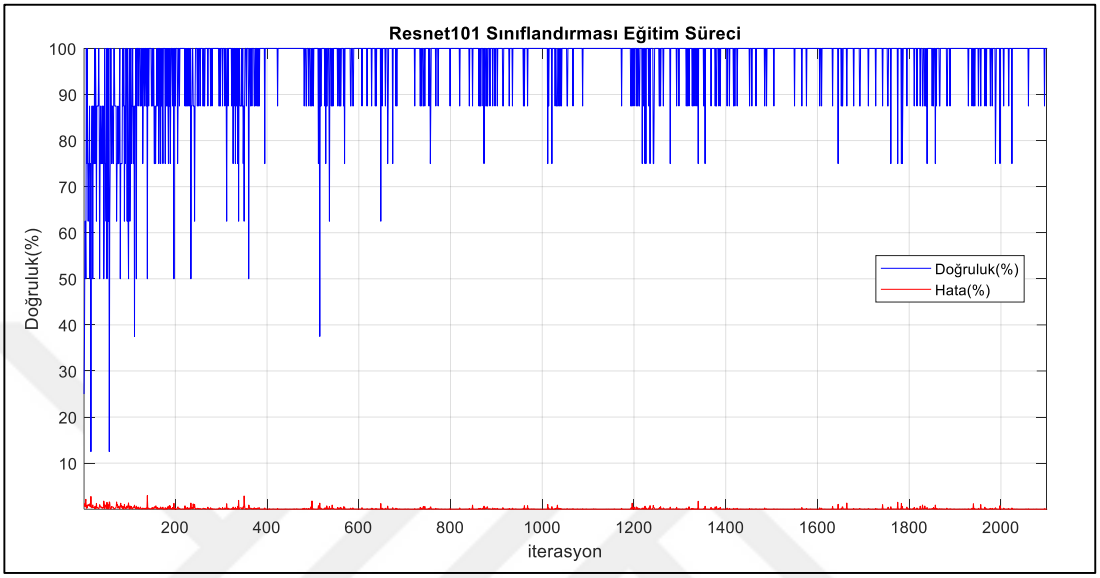
Resnet101 model mimarisi ise giriş imgesi olarak VGG19 mimarisinden esinlenildiği için 224×224×3 boyutlu görüntüleri kabul etmektedir. Modelde kullanılacak veriler ön işlemden geçirildikten sonra 224×224×3 boyuta dönüştürülmüştür. Daha sonra Resnet101 modeli mimarisinde bulunan 1000 çıkışlı softmax katmanı üç çıkışlı softmax sınıflandırma katmanı ile değiştirilmiştir. Model parametreleri ADAM optimizasyonu, 10^{-5} öğrenme oranı, epoch sayısı 100 ve batch boyutu 8 olarak ayarlanmıştır. Veri setinin %70'i eğitim için, %30'u test için kullanılmıştır. Eğitim aşamasından sonra kaydedilen eğitilmiş model 5 kez çalıştırılarak ortaklama test doğruluğu elde edilmiştir. Ortalama doğruluğuna en yakın sonuç için karışıklık matrisi bulunmuş ve performans ölçütleri hesaplanmıştır. Ayrıca ROC eğrileri de çizdirilmiş ve AUC değerleri bulunmuştur. Daha sonra modelin eğitim aşamasına geçilmiştir. Şekil 5.15'te Resnet101 mimarisinin eğitim prosesi ve Şekil 5.16'da ise modelinin eğitim doğruluğu ile hatası verilmiştir. Resnet 101 modeli ezberleme yapmadan ve test doğruluğunu düşürmeden aynı zamanda sınıflandırma hatasını azaltarak eğitim aşaması tamamlamıştır.



Şekil 5.15. Resnet101 modeli eğitim süreci

Model eğitim aşamasın sonrasında kaydedilerek eğitilmiş model 5 kez test edilmiştir. Model Tablo 5.17'den görüldüğü üzere ortalama %94,66 doğruluk oranı elde etmiştir. Ortalama doğruluğuna en yakın sonuç olan 2. test deneme değeri %94,67 için

karışıklık matrisi Tablo 5.18'de gösterilmiştir. Karışıklık matrisinden de anlaşılabileceği gibi meme metastazına ait örneklerin diğer gruplardan daha az olması sebebiyle modelin en başarısız olduğu grup olduğu ve ve 4 örneğin akciğer metastazı ile karıştırıldığı görülmüştür.



Şekil 5.16. Resnet101 eğitim doğruluğu ve hatası

Tablo 5.17. Denemeler sonucu elde edilen doğruluk ortalaması

1.Deneme	2.Deneme	3.Deneme	4.Deneme	5.Deneme	Ortalama (%)
96,00	94,67	92,00	93,33	97,33	94,66

Tablo 5.18. Resnet101 mimarisi ile elde edilen karışıklık matrisi

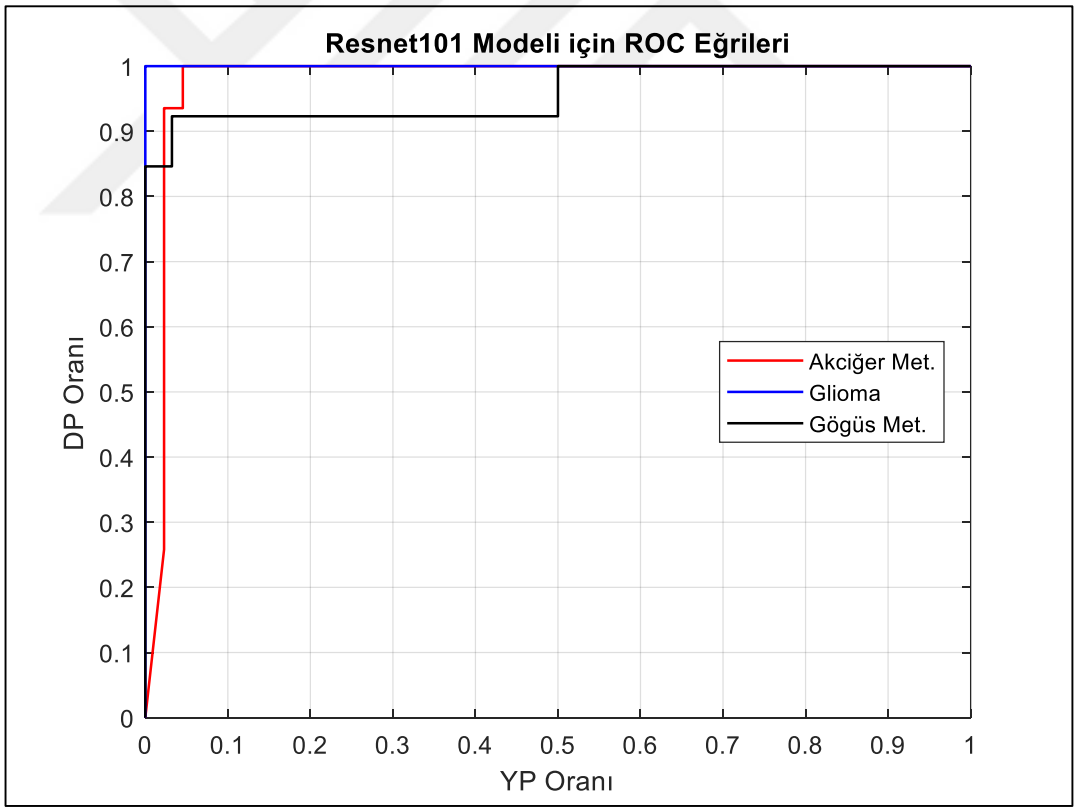
Sınıflar		Gerçek sınıf		
		Akciğer Met.	Glioma	Meme Met.
Tahmin edilen sınıf	Akciğer Met.	31	0	0
	Glioma	0	31	0
	Meme Met.	4	0	9

Karışıklık matrisi kullanılarak her bir sınıf için hassasiyet (R), kesinlik (P) ve f-ölçütü değerleri ve ağırlıklı ortalamaları Tablo 5.19'da verilmiştir. Tablo 5.19'a bakıldığında f-ölçütü değeri 0,9439, hassasiyet 0,9525, kesinlik ise 0,9479 olarak bulunmuştur. Karışıklık matrisinden görüleceği üzere glioma ve metastaz tip tümörler arasındaki ayrım net bir şekilde gerçekleştirilirken, akciğer ve meme metastazı tip tümörlerin arasındaki sınıflandırılmasında 4 örnek yanlış sınıflandırılmıştır.

Tablo 5.19. Resnet101 için performans ölçütleri

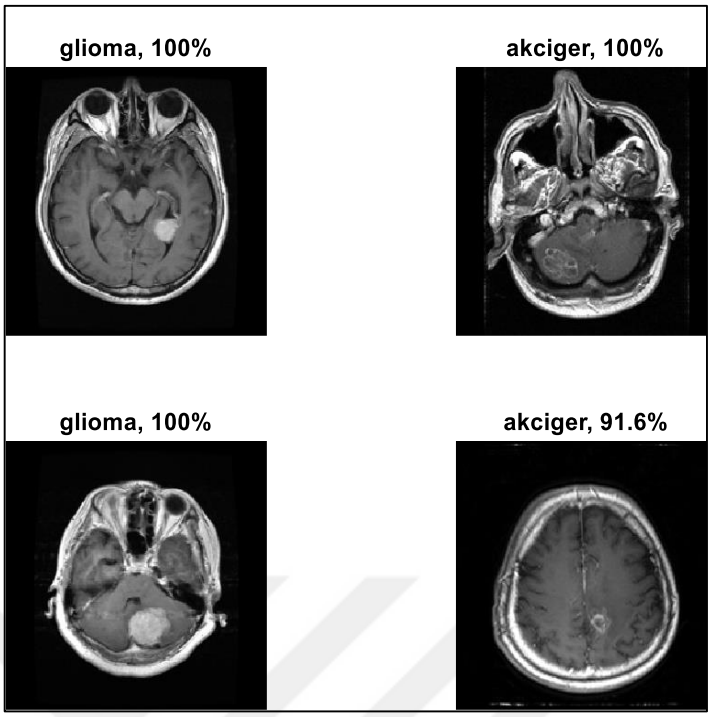
Sınıf	Hassasiyet (R)	Kesinlik (P)	f-ölçütü	AUC Değeri
Akciğer Met.	0,8857	1,0000	0,9394	0,9789
Glioma	1,0000	1,0000	1,0000	1,0000
Meme Met.	1,0000	0,6923	0,8182	0,9591
Ağırlıklı Ortalama	0,9525	0,9476	0,9439	0,9842

Şekil 5.17'deki ROC eğrilerinden kırmızı renkli çizgi akciğer metastazını, mavi renkli çizgi glioma ve siyah renkli çizgi ise meme metastazı tümör tipine ait olan eğrileri göstermektedir. Tüm sınıflarda ROC eğrileri sol üst köşeye yakın olduğundan verilen test verisi için başarılı bir sınıflandırma gerçekleştirilmiştir. En başarısız sınıfın meme metastazına ait olduğu görülmüştür. Eğri altındaki kalan alanlara bakıldığında AUC değerleri akciğer metastazı, glioma ve meme metastazı için sırasıyla 0,9789, 1,0000, 0,9591 bulunmuş ve ağırlıklı ortalaması 0,9842 olarak hesaplanmıştır.



Şekil 5.17. Resnet101 için ROC eğrileri

Şekil 5.18'de ise test veri setinden rastgele seçilen örnekler doğrulukları ile beraber verilmiştir. En düşük sınıflandırma doğruluğuna ait grubunun bu modelde de meme metastazı tip beyin tümör grubu olduğu görülmüştür.



Şekil 5.18. Örnek sınıflandırma sonuçları

5.8. Karşılaştırmalı Sonuçlar

Deneysel çalışmalar sonucunda elde edilen doğruluk oranları Tablo 5.20'de verilmiştir. Tablodan da anlaşılacağı üzere makine öğrenmesi modelleri ile en etkin doğruluk oranı dYİÖ öznitelik çıkarılması ile elde edilmiştir. Aynı zamanda kullanılan hazır modeller makine öğrenmesi modellerin performanslarını geçerek başarılı doğruluk oranları elde etmişlerdir.

Tablo 5.20. Karşılaştırmalı model doğrulukları

Modeller	**αYİÖ**	**dYİÖ**	**YİÖ**	**Alexnet**	**VGG19**	**Resnet101**
Doğruluk (%)	82,66	93,54	83,46	89,33	94,66	94,66

Tablo 5.21'de ise literatürde bulunan beyin tümör sınıf modelleri ile ile karşılaştırma yapılmıştır. Tablodan da görüldüğü üzere literatür arasında başarılı bir sınıflandırma sonucu elde edilmiştir. Literatürde bulunan çalışmalar genelde online verisetleri ile gerçekleştirilmiştir. Tez kapsamında kullanılan verilerden metastatik tip beyin tümör verileri orijinal veriler olup radyoloji doktorları tarafından ayırt edilmiştir. Aynı zamanda metastatik ve birincil tip tümörler arasında yapılan çalışmalar genelde çok yüksek başarı oranları vermiştir. Bu çalışmada kullanılan bütün modeller glioma ve

metastaz ayrımını net bir şekilde gerçekleştirmiştir. Ayrıca tez kapsamında kullanılan metastatik tiplerinden akciğer ve meme metastazları arasındaki sınıflandırma problemi literatürde neredeyse hiç çalışılmamış bir konu olmasına rağmen önerilen modeller içerisinde etkin ve geçerli sonuçlar vermiştir.

Tablo 5.21. Karşılaştırmalı literatür sonuçları

Yazar(lar)	**Beyin tümör Tipi**	**Sınıflandırıcı veya Mimariler**	**Doğruluk (%)**
Sachdeva ve ark. [4]	- Astrositom (AS) - Glioblastoma multiforme (GBM) - Çocuk tümörü (medulloblastoma, MED) - Meninjiyom (MEN) - Metastatik tümör (MET) - Normal bölgeler (NB)	Yoğunluk ve doku öznitelikleri + PCA + YSA	%91
Cheng ve ark. [6]	- Meninjiyom - Glioma - Hipofiz tümörü	Yoğunluk histogramı, GLCM, BoW+DVM	%91,14
Ismael ve Abdel-Qader [7]	- Meninjiyom - Glioma - Hipofiz tümörü	2D Ayrık Dalgacık Dönüşümü (ADD) ve 2B Gabor filtre	%95,66
Thejaswini ve ark. [8]	- Normal - Iyi huylu - Kötü huylu	ARKFCM ile segmentasyon + birinci ve ikinci dereceden istatistiksel öznitelikler + DVM	%91,4
Gumaei ve arkadaşları [9]	- Meninjiyom - Glioma - Hipofiz tümörü	Hibrit PCA-NGIST + RELM	%94,233
Yin ve ark. [10]	- Normal - Tumor	Doku, İstatistiksel ve geometril öznitelikler + MLP	%87

Tablo 5.21. (Devam) Karşılaştırmalı literatür sonuçları

Yazar(lar)	**Beyin tümör Tipi**	**Sınıflandırıcı veya Mimariler**	**Doğruluk (%)**
Zacharaki ve ark. [12]	- Metastatik tümörler - Meningiomalar - Derece II gliomalar - Derece III gliomalar - Glioblastomaları (GBMs)	Hasta yaşı, tümör şekil özellikleri, bazı ilgi alanlarındaki görüntü yoğunluğu özellikleri ve Gabor doku özelliklerini öznitelikleri + DVM	%91,2
Larroza ve ark. [14]	- Beyin metastazı (MET) - Radyasyon nekrozu	Histogram, mutlak gradyan, eş-oluşum matrisi, çalışma uzunluğu matrisi, otoregresif model, dalgacık dönüşümünü + DVM	%94
Artzi ve ark. [15]	- Glioblastoma - Beyin metastazı (göğüs, akciğer ve diğer beyin metastazları)	Klinik bilgileri, tümör konumu, birinci ve ikinci derece istatistiksel öznitelikler, morfolojik, dalgacık özellikleri ve özellik çantası + DVM	%85
Lukas ve ark. [16]	- Menenjiyomlar - Glioblastomlar - Derece II astrositomalar - Beyin metastazı	Doğrusal çekirdek içeren en küçük kareler + DVM	%83,57
Qian ve ark. [17]	- Beyin metastazları - Glioblastomu (GBM)	Birinci derece istatistiksel öznitelikler, şekil tanımlayıcıları ve doku özellikleri (gri seviye eş oluşum matrisi, gri seviye çalışma uzunluğu matrisi ve gri seviye boyutu bölge matrisi) + DVM	%83
Mohsen ve ark. [18]	- Glioblastoma - Sarcoma - Metastazik tümörler	Bulanık C-ortalamalar ve K-ortalama (K-Means) metodları ile görüntüleri segmentasyon + GLCM ve DWT + PCA + DVM	%93,94
Sriramakrishnan ve ark. [19]	- Normal - Tümörlü	YİÖ + Heralick öznitelikleri + DVM	%97,49
Thirumurugan ve Shanthakumar [21]	- Derece II - Derece III - Derece IV glioma	YİÖ + ANFIS	%99,6

Tablo 5.21. (Devam) Karşılaştırmalı literatür sonuçları

Yazar(lar)	**Beyin tümör Tipi**	**Sınıflandırıcı veya Mimariler**	**Doğruluk (%)**
Khalil ve ark. [22]	- Normal - Tümörlü	GLCM, YİÖ, yönlendirilmiş gradyan histogramı (HOG) + k-NN	%100
Gupta ve ark. [23]	- Derece I - Derece II - Derece III - Derece IV glioma	DWT-LBP+istatistiksel öznitelikler + Naif Bayes	%96
Arı ve hanbay [25]	- Normal - Tümörlü	konvolüsyonel özellikler + extreme learning machine (ELM)	%97,18
Widhiarso ve ark. [127]	- Meninjiyom - Glioma - Hipofiz tümörü	GLCM+ CNN	%82
Abiwinanda ve ark. [26]	- Meninjiyom - Glioma - Hipofiz tümörü	CNN	%84,19
Pashai ve ark. [27]	- Meninjiyom - Glioma - Hipofiz tümörü	CNN + kernel ELM	%93,68
Sultan vd. [28]	- Derece II - Derece III - Derece IV	CNN	%98,7
Paul vd. [29]	- Meninjiyom, - Glioma - Hipofiz tümörü	CNN	%91,43
Özyurt ve ark. [30]	- Iyi huylu - Kötü huylu	Alexnet + DVM	%95,62
Özyurt ve ark. [31]	- Iyi huylu - Kötü huylu	Squeeze + ELM	%98,33
Toğaçar ve ark. [32]	- Normal - Tümörlü	AlexNet, GoogleNet, VGG16	%96,05
Toğaçar ve ark. [33]	- Normal - Tümörlü	AlexNet, VGG16 + DVM	%96,77
Sert vd. [34]	- Iyi huylu - Kötü huylu	Resnet + DVM	%95
Mehrotra ve ark. [35]	- Iyi huylu - Kötü huylu	AlexNet, GoogleNet ve SqueezeNet	%99,04

Tablo 5.21. (Devam) Karşılaştırmalı literatür sonuçları

Yazar(lar)	**Beyin tümör Tipi**	**Sınıflandırıcı veya Mimariler**	**Doğruluk (%)**
Kaur ve Gandhi [36]	- Normal - Tümörlü	Alexnet, GoogLeNet, VGG16, VGG19, Resnet50, Resnet101, Inceptionv3, InceptionResNetV2	%100
Talo ve ark. [37]	- Normal - Tümörlü	ResNet34	%100
Chelghoum ve ark. [39]	- Meninjiyom - Glioma - Hipofiz tümörü	AlexNet, GoogleNet, VGG16, VGG19, ResNet18, ResNet50, ResNet101, ResNet-Inception-v2, SENet	%98,71 (VGG16)
Deepak ve Amer [40]	- Meninjiyom - Glioma - Hipofiz tümörü	GoogleNet	%98 (GoogleNet)
Rehman ve ark. [41]	- Meninjiyom - Glioma - Hipofiz tümörü	AlexNet, GoogLeNet, and VGGNet	%98,69 (VGG19)
Swati ve ark. [42]	- Meninjiyom - Glioma - Hipofiz tümörü	VGG19	%94,82 (VGG19)
Ghosal ve ark. [43]	- Meninjiyom - Glioma - Hipofiz tümörü	SENet	%93,83 (SEnet)
Sajjad ve ark. [44]	- Meninjiyom - Glioma - hipofiz tümörü	VGG19 ve veri arttırma (data augmentation)	%94,58 (VGG19)
Önerilen	- Glioma - Akciğer Metastazı - Meme Metastazı	YİÖ, dYİÖ, αYİÖ, Alexnet, VGG19, Resnet101	%82,66 - %94,66 (VGG19, Resnet101)

6. SONUÇLAR VE ÖNERİLER

Beyin, omurilik ile beraber insan vücudunun tüm fonksiyonlarını kontrol etmekten sorumludur. Beyinde meydana gelen bir hastalık insan hayatını olumsuz etkileyebilir. Beyin tümörü, beyindeki hücrelerin anormal büyümesinden kaynaklanan kritik hastalıklardan biridir. Otomatik beyin tümörü sınıflandırması, tümör tespitinin erken aşamasında önemli bir rol oynar ve bu sistem hastaların zamanında teşhis edilmesini ile hayatta kalma şansını arttırabilir. Ayrıca bu sistem radyologların hastalık tipine karar sürecinde ve tedavi planlamasına yardımcı olabilir.

Tez çalışması kapsamında MR görüntüleri kullanılarak birincil tip glioma ve ikincil tiplerden olan akciğer ve meme metastazlarından oluşan üç sınıflı beyin tümör sınıflandırması gerçekleştirilmiştir. Çalışma kapsamında kullanılan glioma tip beyin tümör verileri Nanfang Hastanesi ve Tianjin Tıp Üniversitesi Genel Hastanelerinden toplanan online veri setinden, akciğer ve meme kaynaklı metastatik tip beyin tümör görüntüleri ise Kocaeli Üniversitesi Tıp Fakültesi PACS sisteminden elde edilmiştir. Geliştirilen Yerel İkili Örüntüler (YİÖ) tabanlı makine öğrenmesi modelleri ve önceden eğitilmiş modeller (Alexnet, VGG19, Resnet101) kullanılarak üç tip beyin tümörü sınıflandırma başarıları değerlendirilmiştir.

Görüntüleri standart hale getirmek için yeniden boyutlandırma ve gama düzeltmesinden oluşan bir dizi ön işlem (pre-processing) uygulanmıştır. Daha sonra ilk yöntem olarak makine öğrenmesi yöntemleri denenmiştir. Görüntülerden farklı türde YİÖ örüntü matrisleri YİÖ, dYİÖ ve αYİÖ öznitelik çıkarma yöntemleri kullanılarak oluşturulmuştur. Önerilen YİÖ metotları temel, uygulanabilir, düşük maliyetli ve hızlı cevap veren yöntemlerdir. Daha sonra, oluşturulan YİÖ, dYİÖ ve αYİÖ tümör görüntülerinin histogramları oluşturulmuş ve özellik matrisleri elde edilmiştir. Elde edilen özellik matrisleri ile k-NN, DVM, RO, LR ve YSA modelleri kullanılarak sınıflandırma işlemi yapılmıştır. Beyin tümörü sınıflandırmasında en yüksek başarı oranı $dYİÖ_{d=1}$ özellik çıkarma yöntemi ve YSA modeli ile %93,54 olarak bulunmuştur. İkinci yöntem olarak derin öğrenme yöntemlerinden transfer

öğrenmesi modelleri kullanılmıştır. Alexnet, VGG19 ve Resnet101 mimarileri ele alınan üç sınıflı beyin tümör sınıflandırması için uygun hale getirilerek eğitilmiştir. Daha sonra girilen test verileri ile sistemin performansı ölçülmüştür. Elde edilen sonuçlar neticesinde en yüksek başarı oranları VGG19 ve Resnet101 mimarileri %94,66 olarak hesaplanmıştır. Genel bir değerlendirme yapıldığında transfer öğrenmesi modelleri daha başarılı olmuştur.

Karşılaştırmalı literatür bölümünde görüldüğü gibi geliştirilen YİÖ özellik çıkarma tabanlı modelleri, makine öğrenmesi sınıflandırma modelleri arasında etkin bir performans göstermiştir. Düşük hesaplama maliyeti, basitliği, uygulanabilirliği kolay olması ve hızlı cevap vermesi nedeniyle nedeni ile radyologlara karar destek sistemi oluşturabilmek için önerilen model olarak tercih edilebilir. Aynı zamanda farklı d ve α değerleri denenerek modellerin başarısını etkileyecek farklı örüntüler elde edilebilir.

En iyi performans değerleri transfer öğrenmesi tabanlı modeller ile elde edilmiştir. Önceden eğitilmiş modeller olması nedeni ile genel öznitelikler eğitilmiş olduğundan yüksek başarı oranları elde edilebilmiştir. Geleneksel CNN yapılarına göre daha az verisetleri ile başarılı sonuçlar elde edilebilmesi transfer öğrenmesi modellerini daha etkin bir şekilde kullanılabilmesini sağlamaktadır.

Sınıflandırma sonuçlarına genel olarak bakıldığında modellerin grup sayısı çok olan glioma ve akciğer metastazı kaynaklı beyin tümörlerinin daha kolay ayırt edebildiği, meme metastazı kaynaklı beyin tümör sınıfını ise grup sayısı nispeten daha az olduğu için modellerin bu grubu öğrenmede daha çok zorlandığı görülmüştür. Genelleme yapılacak olursa modellerin glioma ve metastatik tip tümör sınıflandırmasında çok yüksek başarı elde edebildiği, akciğer ve meme metastazı arasındaki sınıflandırma da zorlandığı fakat geçerli sınıflandırma gerçekleştirdiği görülmüştür.

Gelecek çalışmalar için yeni hasta verileri toplanarak üç veya daha fazla sınıfın sınıflandırılması gerçekleştirilebilir. Özellikle az sayıda örnek içeren hasta grupları arttırılarak modellerin daha başarılı bir eğitim süreci geçirmesi sağlanabilir. Yeni hasta verileri de farklı hastanelerden de elde edilebilir. Literatürde çok az çalışılan metastatik tip beyin tümör verilerinin çoğaltılmasıyla standart hale getirilmiş metastatik tip beyin tümör veritabanı oluşturarak araştırmacılar için sunulabilir. Gelecekteki diğer

çalışmalarda diğer sekanslar da çalışmaya eklenerek daha kapsamlı bir çalışma gerçekleştirilebilir. Aynı zamanda sadece aksiyel eksende çekilmiş veriler değil koronal ve sagital eksende çekilmiş görüntülerde çalışmaya eklenerek çalışma zenginleştirilebilir.

Daha kapsamlı veriler ile üst düzey bir çalışma yapılarak tıp doktorlarına karar destek mekanizması sağlamak için bir arayüz geliştirilebilir. Arayüz geliştirilmesi için açık kaynaklı programlar kullanılarak gelişime açık bir yazılım sağlanabilir. Uzmanlara destek veren bu program ile hastalıkların teşhisi, tedavi planlaması vb. süreçler daha iyi yönetilebilir. Aynı zamanda önerilen modeller kullanılarak farklı organlarında görülen tümör, kanser hastalıklarının teşhisi ve sınıflandırılması gerçekleştirilebilir. Ayrıca hastalardan tedavi sürecinde alınan görüntüler ile iyileşme süreçleri kontrol edilerek tedavi planlaması iyileştirilebilir.

KAYNAKLAR

[1] İlçe A., Totur B., Özbayır T., Beyin tümörlü hastaların uluslararası NANDA hemşirelik tanılarına göre değerlendirilmesi: bakım önerileri, *Journal of Neurological Sciences*, 2010, **27**(2), 178-184.

[2] Işın A., Direkoğlu C., Şah M., Review of MRI-based brain tumor image segmentation using deep learning methods, *Procedia Computer Science*, 2016, **102**, 317-324.

[3] Abd-Ellah M. K., Awad A. I., Khalaf A. A., Hamed H. F., A review on brain tumor diagnosis from MRI images: Practical implications, key achievements, and lessons learned, *Magnetic resonance imaging*, 2019, **61**, 300-318.

[4] Sachdeva J., Kumar V., Gupta I., Khandelwal N., Ahuja C. K., A package-SFERCB - "Segmentation, feature extraction, reduction and classification analysis by both SVM and ANN for brain tumors", *Applied soft computing*, 2016, **47**, 151-167.

[5] Mohan G., Subashini, M. M., MRI based medical image analysis: Survey on brain tumor grade classification, *Biomedical Signal Processing and Control*, 2018, **39**, 139-161.

[6] Cheng J., Huang W., Cao S., Yang R., Yang W., Yun Z., Wang Z., Feng, Q., Enhanced performance of brain tumor classification via tumor region augmentation and partition, *Plos One*, 2015, **10**(10), 1-13.

[7] Ismael M. R., Abdel-Qader I., Brain tumor classification via statistical features and back-propagation neural network. *In 2018 IEEE International Conference on Electro/Information Technology (EIT)*, Rochester, USA, 3-5 May 2018.

[8] Thejaswini P., Bhat B., Prakash K., Detection and classification of tumour in brain MRI, *Int. J. Eng. Manufact.(IJEM)*, 2019, **9**(1), 11-20.

[9] Gumaei A., Hassan M. M., Hassan M. R., Alelaiwi A., Fortino G., A hybrid feature extraction method with regularized extreme learning machine for brain tumor classification, *IEEE Access*, 2019, **7**, 36266-36273.

[10] Yin B., Wang C., Abza F., New brain tumor classification method based on an improved version of whale optimization algorithm, *Biomedical Signal Processing and Control*, 2020, **56**, 1-10.

[11] Sachdeva J., Kumar V., Gupta I., Khandelwal N., Ahuja C. K., Segmentation, feature extraction, and multiclass brain tumor classification, *Journal of digital imaging*, 2013, **26**(6), 1141-1150.

[12] Ortiz-Ramon R., Larroza A., Ruiz-Espana S., Arana E., Moratal D., Member S., Identifying the Primary Site of Origin of MRI Brain Metastases From Lung and Breast Cancer Following a 2D Radiomics Approach, *2017 IEEE 14th International Symposium on Biomedical Imaging*, Melbourne, Australia, 18-21 April 2017.

[13] Skogen K., Schulz A., Helseth E., Ganeshan B., Dormagen J. B., Server A. Texture analysis on diffusion tensor imaging: discriminating glioblastoma from single brain metastasis, *Acta Radiologica*, 2019, **60**(3), 356-366.

[14] Larroza A., Moratal D., Paredes-Sánchez A., Soria-Olivas E., Chust M. L., Arribas L. A., Arana E., Support vector machine classification of brain metastasis and radiation necrosis based on texture analysis in MRI, *Journal of magnetic resonance imaging*, 2015, **42**(5), 1362-1368.

[15] Artzi M., Bressler I., Ben Bashat D., Differentiation between glioblastoma, brain metastasis and subtypes using radiomics analysis, *Journal of Magnetic Resonance Imaging*, 2019, **50**(2), 519-528

[16] Lukas L., Devos A., Suykens J. A., Vanhamme L., Howe F. A., Majós C., Moreno-Torres A., Van Der Graaf M., Tate A. R., Arus C., Van Huffel S., Brain tumor classification based on long echo proton MRS signals, *Artificial intelligence in medicine*, 2004, **31**(1), 73-89.

[17] Qian Z., Li Y., Wang Y., Li L., Li R., Wang K., Li S., Tang K. Zhang C., Fan X., Chen B., Li W., Differentiation of glioblastoma from solitary brain metastases using radiomic machine-learning classifiers, *Cancer Letters*, 2019, **451**, 128-135

[18] Mohsen H., El-Dahshan E. S. A., M El-Horbaty E. S., Salem A. B. M., Brain Tumor Type Classification Based on Support Vector Machine in Magnetic Resonance Images, *Annals of Dunarea de Jos University of Galati*, 2017, **9**, 75-88.

[19] Sriramakrishnan P., Kalaiselvi T., Rajeswaran R., Modified local ternary patterns technique for brain tumour segmentation and volume estimation from mri multi-sequence scans with gpu cuda machine, *Biocybernetics and Biomedical Engineering*, 2019, **39**(2), 470-487.

[20] Abbasi S., Tajeripour F., Detection of brain tumor in 3D MRI images using local binary patterns and histogram orientation gradient, *Neurocomputing*, 2017, **219**, 526-535.

[21] Thirumurugan P., Shanthakumar P., Brain tumor detection and diagnosis using ANFIS classifier, *International Journal of Imaging Systems and Technology*, 2016, **26**(2), 157-162.

[22] Khalil M., Ayad H., Adib A., Performance evaluation of feature extraction techniques in MR-Brain image classification system, *Procedia Computer Science*, 2018, **127**, 218-225.

[23] Gupta M., Rajagopalan V., Rao B. P., Glioma grade classification using wavelet transform-local binary pattern based statistical texture features and geometric measures extracted from MRI, *Journal of Experimental & Theoretical Artificial Intelligence*, 2019, **31**(1), 57-76.

[24] Siva Raja P. M., Rani A. V., Brain tumor classification using a hybrid deep autoencoder with Bayesian fuzzy clustering-based segmentation approach, *Biocybernetics and Biomedical Engineering*, 2020, **40**(1), 440-453.

[25] Ari A., Hanbay D., Deep learning based brain tumor classification and detection system, *Turkish Journal of Electrical Engineering & Computer Sciences*, 2018, **26**(5), 2275-2286.

[26] Abiwinanda N., Hanif M., Hesaputra S. T., Handayani A., Mengko T. R., Brain tumor classification using convolutional neural network, *In World Congress on Medical Physics and Biomedical Engineering*, Prague, Czech Republic, 3-8 June 2018.

[27] Pashaei A., Sajedi H., Jazayeri N., Brain tumor classification via convolutional neural network and extreme learning machines, *In 2018 8th International Conference on Computer and Knowledge Engineering (ICCKE)*, Mashhad, Iran, 25 October 2018.

[28] Sultan H. H., Salem N. M., Al-Atabany W., Multi-Classification of Brain Tumor Images Using Deep Neural Network, *IEEE Access*, 2019, **7**, 69215-69225.

[29] Paul J. S., Plassard A. J., Landman B. A., Fabbri D., Deep learning for brain tumor classification. *In Medical Imaging 2017: Biomedical Applications in Molecular, Structural, and Functional Imaging*, Florida, USA, 13 March 2017.

[30] Özyurt F., Sert E., Avci E., Dogantekin E., Brain tumor detection based on Convolutional Neural Network with neutrosophic expert maximum fuzzy sure entropy, *Measurement*, 2019, **147**, 1-7.

[31] Özyurt F., Sert E., Avcı D., An expert system for brain tumor detection: Fuzzy C-means with super resolution and convolutional neural network with extreme learning machine, *Medical Hypotheses*, 2020, **134**, 1-8.

[32] Toğaçar M., Ergen B., Cömert Z., BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model, *Medical Hypotheses*, 2020, **134**, 1-8.

[33] Toğaçar M., Cömert Z., Ergen B., Classification of brain MRI using hyper column technique with convolutional neural network and feature selection method, *Expert Systems with Applications*, 2020, **149**, 1-8.

[34] Sert E., Özyurt F., Doğantekin A., A new approach for brain tumor diagnosis system: Single image super resolution based maximum fuzzy entropy segmentation and convolutional neural network, *Medical Hypotheses*, 2019, **133**, 1-9.

[35] Mehrotra R., Ansari M. A., Agrawal R., Anand R. S., A Transfer Learning approach for AI-based classification of brain tumors, *Machine Learning with Applications*, 2020, **2**, 1-12.

[36] Kaur T., Gandhi T. K., Deep convolutional neural networks with transfer learning for automated brain image classification, *Machine Vision and Applications*, 2020, **31**, 1-16.

[37] Talo M., Baloglu U. B., Yıldırım Ö., Acharya U. R. Application of deep transfer learning for automated brain abnormality classification using MR images, *Cognitive Systems Research*, 2019, **54**, 176-188.

[38] https://figshare.com/articles/brain_tumor_dataset/1512427, (Ziyaret tarihi: 27.11.2020).

[39] Chelghoum R., Ikhlef A., Hameurlaine A., Jacquir S., Transfer Learning Using Convolutional Neural Network Architectures for Brain Tumor Classification from MRI Images, *In IFIP International Conference on Artificial Intelligence Applications and Innovations*, Neos Marmaras, Greece, 5-7 June 2020.

[40] Deepak S., Ameer P. M., Brain tumor classification using deep CNN features via transfer learning, *Computers in Biology and Medicine*, 2019, **111**, 1-7.

[41] Rehman A., Naz S., Razzak M. I., Akram F., Imran M., A deep learning-based framework for automatic brain tumors classification using transfer learning, *Circuits, Systems, and Signal Processing*, 2020, **39**(2), 757-775.

[42] Swati Z. N. K., Zhao Q., Kabir M., Ali F., Ali Z., Ahmed S., Lu, J., Brain tumor classification for MR images using transfer learning and fine-tuning, *Computerized Medical Imaging and Graphics*, 2019, **75**, 34-46.

[43] Ghosal P., Nandanwar L., Kanchan S., Bhadra A., Chakraborty J., Nandi D., Brain tumor classification using ResNet-101 based squeeze and excitation deep neural network, *In 2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP)*, Gangtok, India, 25 – 28 February 2019.

[44] Sajjad M., Khan S., Muhammad K., Wu W., Ullah A., Baik S. W., Multi-grade brain tumor classification using deep CNN with extensive data augmentation, *Journal of Computational Science*, 2019, **30**, 174-182.

[45] https://www.visiblebody.com/learn/nervous/brain (Ziyaret tarihi: 27 Kasım 2020).

[46] Damasio H., *Human Brain Anatomy in Computerized Images*. 2nd ed., Oxford university press, China, 2005.

[47] Nolte J., *An Introduction to its Functional Anatomy*, 6th ed., Mosby/Elsevier , Philadelphia, USA, 2009.

[48] Tiwari A., Srivastava S., Pant M., Brain tumor segmentation and classification from magnetic resonance images: Review of selected methods from 2014 to 2019, *Pattern Recognition Letters*, 2020, **131**, 244-260.

[49] Özduman K., Hacıhanefioğlu M., Pamir M. N., Glioblastom, *Türk Nöroşirürji Derg.*, 2019, **29**(3), 305-334.

[50] Black P. M., Brain tumors, *New England Journal of Medicine*, 1991, **324**(22), 1555-1564.

[51] Osborn A. G., *Beyin Görüntüleme*, Patoloji ve Anatomi, 1. baskı , Dünya Kitapevi, Ankara, 2015.

[52] Jalali V., Kaur, D., A study of classification and feature extraction techniques for brain tumor detection, *International Journal of Multimedia Information Retrieval*, 2020, **9**, 271-290.

[53] John P., Brain tumor classification using wavelet and texture based neural network, *International Journal of Scientific & Engineering Research*, 2012, **3**(10), 1-7.

[54] Fletcher-Heath L. M., Hall L. O., Goldgof D. B., Murtagh F. R., Automatic segmentation of non-enhancing brain tumors in magnetic resonance images, *Artificial Intelligence in Medicine*, 2001, **21**(1-3), 43-63.

[55] Chaplot S., Patnaik L. M., Jagannathan N. R., Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network, *Biomedical signal processing and control*, 2006, **1**(1), 86-92.

[56] Gorunescu, F., Data mining techniques in computer-aided diagnosis: non-invasive cancer detection, *Pwaset*, 2007, **25**, 427-430.

[57] El-Dahshan E. S. A., Hosny T., Salem A. B. M., Hybrid intelligent techniques for MRI brain images classification, *Digital Signal Processing*, 2010, **20**(2), 433-441.

[58] Işık B., Manyetik Rezonans Görüntüleme ve Anestezi, *Marmara Medical Journal*, 2006, **19**(2), 98-103.

[59] https://sternmed.de/en/product_detail/5/marcom-15t-superconductive-mri-scanner (Ziyaret tarihi: 27 Kasım 2020).

[60] https://www.memorial.com.tr/saglik-rehberleri/daha-sessiz-genis-ve-konforlu-bir-mr-deneyimi/ (Ziyaret tarihi: 27 Kasım 2020).

[61] Damdıl E., MR Görüntüleri ve MR Spektroskopi Verileri ile Yapay Öğrenme Tabanlı Beyin Tümörü Tespit Yöntemi ve Uygulaması, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya, 2015, 382339.

[62] Huettel S. A., Song A. W., McCarthy G., *Functional magnetic resonance imaging*, 2nd ed., Sinauer Associates, Sunderland, Massachusetts, 2004.

[63] https://www.teslasociety.com/mri.htm (Ziyaret tarihi: 27 Kasım 2020).

[64] https://two-views.com/mri-imaging/history.html (Ziyaret Tarihi: 26 Kasım 2020).

[65] Yüksel Z., Manyetik Rezonans Görüntüleme Fizik Temelleri ve Sistem Bileşenleri, *Black Sea Journal of Engineering and Science*, 2019, **2**(2), 57-65.

[66] Paschal C. B., Morris H. D., K-space in the clinic. *Journal of Magnetic Resonance Imaging*, 2004, **19**(2), 145-159.

[67] https://en.wikipedia.org/wiki/Magnetic_resonance_imaging (Ziyaret tarihi: 27 Kasım 2020).

[68] Elmaoğlu M., Çelik A., *MRI handbook: MR physics, patient positioning, and protocols*, 1st ed., Springer Science & Business Media, New York, USA, 2012.

[69] Cuşkun Y., Beyin metastazlarının derin öğrenmeyle sınıflandırılması, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli, 2019, 575267.

[70] Cheng J., Yang W., Huang M., Huang W., Jiang J., Zhou Y., Yang R, Zhao J., Feng Y., Feng Q., Chen, W., Retrieval of brain tumors by adaptive spatial pooling and fisher vector representation, *Plos one*, 2016, **11**(6), 1-15.

[71] Guan X., Jian S., Hongda P., Zhiguo Z., Haibin G., An image enhancement method based on gamma correction, *In 2009 Second International Symposium on Computational Intelligence and Design*, Hunan, China, 12-14 December 2009.

[72] Ojala T., Pietikinen M., Harwood D., A comparative study of texture measures with classification based on featured distrubition, *Pattern Recognition*, 1996, **29**(1), 51-59.

[73] Ojala T., Pietikinen M., Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Trans.Pattern Anal. Mach. Intell*, 2002, **27**(7), 971-987.

[74] Liu L., Fieguth P., Zhao G., Pietikäinen M., Hu D., Extended local binary patterns for face recognition, *Information Sciences*, 2016, **358**, 56-72.

[75] El Khadiri I., Kas M., El Merabet Y., Ruichek Y., Touahni, R., Repulsive-and-attractive local binary gradient contours: New and efficient feature descriptors for texture classification, *Information Sciences*, 2018, **467**, 634-653.

[76] Liu L., Zhao L., Long Y., Kuang G., Fieguth P., Extended local binary patterns for texture classification, *Image and Vision Computing*, 2012, **30**(2), 86-99.

[77] Kaya Y., Ertuğrul Ö. F. and Tekin R., Two novel local binary pattern descriptors for texture analysis, *Applied Soft Computing*, 2015, **34**, 728-735.

[78] Smolka B., Nurzynska K., Power LBP: A novel texture operator for smiling and neutral facial display classification, *Procedia Computer Science*, 2015, **51**, 1555-1564.

[79] Lumini A., Nanni L., Brahnam S., Ensemble of texture descriptors and classifiers for face recognition, *Applied Computing and Informatics*, 2017, **13**(1), 79-91.

[80] Kim P., *MATLAB Deep Learning With Machine Learning, Neural Networks and Artificial Intelligence*, 1st ed., Apress/Springer, Ney York, USA, 2017.

[81] Alpaydın E., *Introduction to Machine Learning*, 2nd ed., The MIT Press, London, 2010.

[82] Cover T., Hart P., Nearest neighbor pattern classification, *IEEE transactions on information theory*, 1967, **13**(1), 21-27.

[83] Peterson L. E., K-nearest neighbor, *Scholarpedia*, 2009, **4**(2), 1883-1883.

[84] https://www.datacamp.com/community/tutorials/k-nearest-neighbor-classification-scikit-learn? (Ziyaret tarihi: 27 Kasım 2020).

[85] http://bilgisayar.kocaeli.edu.tr/files/49_KNN.pptx (Ziyaret tarihi: 27 Kasım 2020).

[86] Breiman L., Random forests, *Machine learning*, 2001, **45**, 5–32.

[87] Ji X., Yang B., Tang Q., Seabed sediment classification using multibeam backscatter data based on the selecting optimal random forest model, *Applied Acoustics*, 2020, **167**, 1-12.

[88] Cortes C., Vapnik V., Support vector networks, *Machine learning*, 1995, **20**(3), 273-297.

[89] Burges C. J., A tutorial on support vector machines for pattern recognition, *Data mining and knowledge discovery*, 1998, **2**(2), 121-167.

[90] www.math.cornell.edu/~numb3rs/kostyuk/num219.htm (Ziyaret tarihi: 27 Kasım 2020).

[91] Gunn S. R., Support vector machines for classification and regression, *ISIS technical report*, 1998, **14**(1), 5-16.

[92] Lemeshow S., Hosmer J. D. W., A review of goodness of fit statistics for use in the development of logistic regression models, *American journal of epidemiology*, 1982, **15**(1), 92-106.

[93] Özdamar K., *Paket Programlar İle İstatistiksel Veri Analizi*, 10. baskı, Pegem Akademi, Ankara, Turkiye, 2015.

[94] Stock J. H., Watson M. W., *Introduction to econometrics*, 3rd ed., Pearson, London, UK, 2015.

[95] Hosmer J. D. W., Lemeshow S., Sturdivant R. X., *Applied logistic regression*, John Wiley & Sons, New Jersey, USA, 2013.

[96] Bircan H., Lojistik regresyon analizi: Tıp verileri üzerine bir uygulama, *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 2004, **2**, 185-208.

[97] https://towardsdatascience.com/logistic-regression-detailed-overview-46c4da4303bc (Ziyaret tarihi: 27 Kasım 2020).

[98] http://iibf.erciyes.edu.tr/dergi/sayi40/ERUJFEAS_Jun2012_167to187.pdf (Ziyaret tarihi: 27 Kasım 2020).

[99] Fausett L., *Fundamentals Of Neural Networks*, 1rd ed., Prentice-Hall, New Jersey, USA, 1994.

[100] Haykin S., *Neural networks—A Comprehensive Foundation*, 2nd ed., Prentice Hall, New Jersey, 1998.

[101] Yurtoğlu H., Yapay sinir ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği, Uzmanlık Tezi, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, Ankara, 2005, DPT:2683.

[102] Öztemel E., *Yapay sinir ağlari*, 4. baskı, Papatya Yayincilik, Istanbul, Türkiye, 2012.

[103] https://cs231n.github.io/neural-networks-1/ (Ziyaret tarihi: 27 Kasım 2020).

[104] Elmas Ç., *Yapay sinir ağları:(kuram, mimari, eğitim, uygulama)*, 1. baskı, Seçkin Yayıncılık, Ankara, Türkiye, 2003.

[105] Zurada J. M., *Introduction to artificial neural systems*, West, Minnesota, USA, 1992.

[106] Jain A. K., Mao J., Mohiuddin K. M., Artificial neural networks: A tutorial, *Computer*, **29**(3), 31-44, 2016.

[107] Zhang G., Patuwo B. E., Hu M. Y. , Forecasting with artificial neural networks: The state of the art., *International journal of forecasting*, 1998, **14**(1), 35-62.

[108] Goodfellow I., Bengio Y., Courville A., Bengio Y., 1st ed., *Deep learning*, MIT press, Cambridge, U.K., 2016.

[109] https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html (Ziyaret tarihi: 27 Kasım 2020).

[110] Yamashita R., Nishio M., Do R. K. G., Togashi K., Convolutional neural networks: an overview and application in radiology, *Insights into imaging*, 2018, **9**(4), 611-629.

[111] Salçın K., Derin öğrenme ve görüntü iyileştirme teknikleri ile beyin tümörlerinin mr görüntüleri kullanılarak sınıflandırılması, Yüksek Lisans Tezi, Çukuroava Üniversitesi, Fen Bilimleri Enstitüsü, Adana, 2019, 570165.

[112] https://missinglink.ai/guides/neural-network-concepts/7-types-neural-network-activation-functions-right/ (Ziyaret tarihi: 27 Kasım 2020).

[113] https://deepai.org/machine-learning-glossary-and-terms/softmax-layer (Ziyaret tarihi: 27 Kasım 2020).

[114] Moured O., Derin öğrenme tabanlı çoklu nesne takipçilerinin değerlendirilmesi, Yüksek Lisans Tezi, Ortadoğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2020, 645347.

[115] https://towardsdatascience.com/understanding-rmsprop-faster-neural-network-learning-62e116fcf29a (Ziyaret tarihi: 27 Kasım 2020).

[116] Bozoğullarından E., Transfer öğrenme kullanılarak yapay arı koloni programlama, Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, 2020, 572866.

[117] https://www.mathworks.com/discovery/transfer-learning.html (Ziyaret tarihi: 27 Kasım 2020).

[118] https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html (Ziyaret tarihi: 27 Kasım 2020).

[119] Krizhevsky, A., Sutskever, I., & Hinton, G. E., Imagenet classification with deep convolutional neural networks, *Communications of the ACM*, 2017, **60**(6), 84-90.

[120] Simonyan K., Zisserman A. (2014). Very deep convolutional networks for large-scale image recognition, *6th International Conference on Learning Representations ICLR*, San Diego, USA, 7-9 May 2015.

[121] He K., Zhang X., Ren S., Sun J., Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, NV, USA, 27 - 30 June 2016

[122] Fawcett T., An Introduction to ROC Curve, *Pattern Recognition Letters*, 2006, **27**, 861-874.

[123] Kaplan K., Kaya Y., Kuncan M., Ertunç H. M., Brain tumor classification using modified local binary patterns (LBP) feature extraction methods. *Medical Hypotheses*, 2020, **139**, 1-12.

[124] https://dijitalhastane.saglik.gov.tr/TR,4876/pacs-picture-archiving-and-communication-systems---goruntu-saklama-ve-iletisim-sistemleri.html (Ziyaret tarihi: 27 Kasım 2020).

[125] Witten I. H., Frank E., Data mining: practical machine learning tools and techniques with Java implementations, *Acm Sigmod Record*, 2002, **31**(1), 76-77.

[126] Beale M., Hagan M., Demuth H., *Deep Learning Toolbox: User's Guide (R2019a)*, 1st. ed., The MathWorks, Inc., Natick, MA, USA, 2019.

[127] Widhiarso W., Yohannes Y., Prakarsah C., Brain tumor classification using gray level co-occurrence matrix and convolutional neural network, *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, 2018, **8**(2), 179-190.

EKLER

Ek-A

Tez çalışması kapsamında kullanılan veriler için alınan Etik Kurulu Onay Belgesi

T.C.
KOCAELİ ÜNİVERSİTESİ

GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR
ETİK KURULU

Etik Kurul Bilgileri	Adı	Kocaeli Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu
	Adres	Kocaeli Üniversitesi Tıp Fakültesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu Ara Kat 41380 Umuttepe Yerleşkesi /KOCAELİ
	Telefon	0262 303 74 50
	Faks	0262 303 74 63
	E-Posta	gokaetikkurul@kocaeli.edu.tr

Başvuru Bilgileri	Araştırmanın Adı	Derin Öğrenme Algoritmaları Kullanarak Manyetik Rezonans Görüntülerde Beyin Metastazlarının Tanınması, Segmentasyonu ve Sınıflandırılması			
	Araştırma Proje Numarası	KÜ GOKAEK 2018/382			
	Sorumlu Araştırmacı Unvanı/Adı/Soyadı	Dr. Öğretim Üyesi Burcu ALPARSLAN			
	Sorumlu Araştırmacının Uzmanlık Alanı	Radyoloji			
	Araştırma Merkezi	Kocaeli Üniversitesi Tıp Fakültesi Radyoloji AD ve Mühendislik Fakültesi Mekatronik Mühendisliği AD			
	Destekleyici	TÜBİTAK 1002			
	Araştırmanın Türü	**Bireysel Araştırma Projesi**			
	Araştırmaya Katılan Merkezler	Tek Merkezli ☒	Çok Merkezli ☐	Ulusal ☒	Uluslararası ☐

	Belge Adı	Var	Yok	Açıklama
Değerlendirilen Belgeler	Başvuru Dilekçesi	☐	☐	
	Başvuru Formu	☐	☐	
	Araştırmanın Türü	☒	☐	Dosya ve görüntü kayıtları gibi retrospektif arşiv taraması
	Araştırma Protokolü	☐	☐	
	Kullanılacak Form Örnekleri	☐	☐	
	Aydınlatılmış Onam Formu	☐	☐	
	Araştırma Bütçesi	☐	☐	
	Literatür Örneği	☐	☐	
	Taahhütname	☐	☐	
	Biyolojik Materyal Transfer Anlaşması	☐	☐	
	İzin Belgeleri	☐	☐	
	Başhekimlik Onayı	☐	☐	
	Özgeçmişler	☐	☐	
	Değişiklik Bilgi Formu	☐	☐	
	Proje Sonuç Formu	☐	☐	
	Diğer	☐	☐	

Karar Bilgileri	Karar No: KÜ GOKAEK 2019/01.04	Proje No: 2018/382	Tarih : 27/2/2019
	Dr. Öğretim Üyesi Burcu ALPARSLAN sorumluluğunda yapılan ve yukarıda bilgileri verilen araştırma başvuru dosyası ve ilgili belgeler, araştırmanın gerekçesi, amacı, yaklaşım ve yöntemleri, gönüllüler için beklenen yarar ve riskler dikkate alınarak değerlendirilmiş ve araştırmanın ilgili protokol doğrultusunda belirtilen merkezlerde yürütülmesi etik açıdan, ☒ Uygun bulunmuştur. ☐ Eksikliklerin tamamlanması koşulu ile uygun bulunmuştur.* ☐ Uygun bulunmamıştır.*		

Dayanakları	Hasta Hakları Yönetmeliği (01.08.1998/23420); Biyoloji ve Tıbbın Uygulanması Bakımından İnsan Hakları ve İnsan Haysiyetinin Korunması Sözleşmesi: İnsan Hakları ve Biyotıp Sözleşmesinin Uygun Bulunduğuna Dair Kanun (09.12.2003/25311); Biyotıp Araştırmalarına İlişkin İnsan Hakları ve Biyotıp Sözleşmesine Ek Protokolün Onaylanmasının Uygun Bulunduğuna Dair Kanun (29.03.2011/27899); İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik (13.04.2013/28617); Tıbbi Cihaz Klinik Araştırmaları Yönetmeliği (06.09.2014/29111); Dünya Tıp Birliği Helsinki Bildirgesi; İyi Klinik Uygulamaları Kılavuzu; Türk Tabipleri Birliği Hekimlik Meslek Etiği Kuralları; Türk Tabipleri Birliği Araştırma Etiği Bildirgesi

Etik Kurul Üyeleri

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet		Araştırma ile İlişki		Toplantıda Bulunma		İmza
			E	K	E	H	E	H	
Prof. Dr. Kadir Babaoğlu Başkan	Çocuk Sağlığı ve Hastalıkları	Kocaeli Üniversitesi Tıp Fakültesi	☒	☐	☐	☒	☐	☐	
Prof. Dr. İ. Erdem Okay Üye	Genel Cerrahi	Kocaeli Üniversitesi Tıp Fakültesi	☒	☐	☐	☒	☐	☐	
Prof. Dr. Haluk Emre Özel Üye	Restoratif Diş Tedavisi	Kocaeli Üniversitesi Diş Hekimliği Fakültesi	☒	☐	☐	☒	☐	☐	
Prof. Dr. Özlem Yıldız Gündoğdu Üye	Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları	Kocaeli Üniversitesi Tıp Fakültesi	☐	☒	☐	☒	☐	☐	
Prof. Dr. Canan Baydemir Üye	Biyoistatistik	Kocaeli Üniversitesi Tıp Fakültesi	☐	☒	☐	☒	☐	☐	
Doç. Dr. Semil Selcen Göçmez Üye	Farmakoloji	Kocaeli Üniversitesi Tıp Fakültesi	☐	☒	☐	☒	☐	☐	
Doç. Dr. Yusufhan Yazır Üye	Histoloji ve Embriyoloji	Kocaeli Üniversitesi Tıp Fakültesi	☒	☐	☐	☒	☐	☐	
Dr. Öğretim Üyesi Aslıhan Akpınar Raportör	Tıp Tarihi ve Etik	Kocaeli Üniversitesi Tıp Fakültesi	☐	☒	☐	☒	☐	☐	
Dr. Öğretim Üyesi Ceyla Eraldemir Üye	Biyokimya	Kocaeli Üniversitesi Tıp Fakültesi	☐	☒	☐	☒	☐	☐	

* Gerekçe ve öneriler:

KİŞİSEL YAYIN VE ESERLER

[1] **Kaplan K.,** Kaya Y., Kuncan M., Ertunç H. M., Brain Tumor Classification using Modified Local Binary Patterns (LBP) Feature Extraction Methods, Me*dical Hypotheses*, 2020, **139**, 1-12.

[2] **Kaplan K.**, Kaya Y., Kuncan M., Minaz M. R., Ertunç H. M., An improved feature extraction method using texture analysis with LBP for bearing fault diagnosis, *Applied Soft Computing*, 2020, **87**, 1-13.

[3] Kuncan M., **Kaplan K.**, Küçükates S., Ertunc H. M. Design, production and novel NC tool path generation of CNC tire mold processing machine, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 2018, **33**(3), 1183-1199.

[4] Kuncan M., **Kaplan K.**, Minaz M. R., Kaya Y., Ertunç H. M., A novel feature extraction method for bearing fault classification with one dimensional ternary pattern, *ISA Transactions*, 2020, **100,** 346-357.

[5] Kaya Y., Kuncan M., **Kaplan K.**, Minaz M. R., Ertunç H. M., Classification of bearing vibration speeds under 1D-LBP based on eight local directional filters, *Soft Computing*, 2020, **24**, 12175–12186.

[6] Kaya Y., Kuncan M., **Kaplan K.**, Minaz M. R., Ertunç H. M., A new feature extraction approach based on one dimensional gray level co-occurrence matrices for bearing fault classification, *Journal of Experimental & Theoretical Artificial Intelligence*, DOI: 10.1080/0952813X.2020.1735530.

[7] Ayvaz E., **Kaplan K.**, Kuncan, M., An Integrated LSTM Neural Networks Approach to Sustainable Balanced Scorecard-Based Early Warning System. *IEEE Access*, 2020, **8**, 37958-37966.

[8] Kuncan M., **Kaplan K.**, Ertunç H. M., Küçükateş S., 5 Axis CNC Precision Tire Side Machining, *European Journal of Technique*, 2016, **6**(2), 117-123..

[9] M. Kuncan, **K. Kaplan** (2016). Position Determination by Using Image Processing Method in Inverted Pendulum, *Middle East Journal of Technic MEJT*, 2016, **2**(1), 56-63.

[10] **Kaplan K.**, Kundakci I. M., Kuncan M., Toprak E., Izgu A., Ertunc H. M., Process Control Methods Application in Training Set, *International Journal of Natural & Engineering Sciences IJNES*, 2016, **10**(2), 35-42.

[11] Kuncan M., **Kaplan K.**, Acar F., Kundakçi I. M., Ertunç H. M., Fuzzy logic based ball on plate balancing system real time control by image processing.

International Journal of Natural and Engineering Sciences IJNES, 2016, **10**(3), 28-32.

[12] Vardar E., **Kaplan K.**, Ertunc H. M., Handwriting Character Recognision by using Fuzzy Logic, *Turkish Journal of Science & Technology TJST*, 2017, **12**(2): 71-77.

[13] Kuncan M., **Kaplan K.**, Guner H. E., Umucu A., Erdil A. Controlling of Water Temperature and Flow Rate, *International Journal of Natural and Engineering Sciences IJNES*, 2017, **11**(2), 44-46.

[14] **Kaplan K.,** Kuncan M., Nural O., Erdil A., Internet Controlled Mobile Robot, *International Journal of Natural and Engineering Sciences IJNES*, 2017, **11**(3), 19-23.

[15] Vardar E., **Kaplan K.**, Ertunç H. M., Ball and Beam Control based on NARMA L-2 Controller, *Kocaeli Universitesi Fen Bilimleri Dergisi*, 2018, **1**(2), 77-83.

[16] **Kaplan K.,** Kuncan M., Polat H., Tepe B., Ertunç H. M., PID ve Bulanık Mantık Tabanlı DC Motorun Gerçek Zamanlı Konum Kontrolü, *Journal of the Institute of Science and Technology*, 2020, **10**(2), 900-916.

[17] Kuncan M., Vardar E., **Kaplan K.**, Ertunç H. M., Turkish handwriting recognition system using multi-layer perceptron, *Journal Of Mechatronics and Artificial Intelligence In Engineering*, DOI: 10.21595/jmai.2020.21502.

[18] **Kaplan K.**, Bayram S., Kuncan M., Ertunc H. M., Feature Extraction Of Ball Bearings in Time-Space And Estimation of Fault Size with Method of ANN, *Proceedings Of The 16th Mechatronika 2014*, Brno, Czech Republic, 3-5 December 2014.

[19] Kuncan M., **Kaplan K.**, Ertunç H M., 5 Axis CNC Tire Surface Prototype Machine, *International Symposium on Innovative Technologies in Engineering and Science ISITES'2015*, Valencia, Spain, 3-5 June 2015.

[20] Çubukçu A., Öztürk S., Kuncan M., **Kaplan K.**, Kuncan F., The Implementation of DC Motor Speed Control Using Image Processing and OPC Interface in the S7-1200, *International Symposium on Innovative Technologies in Engineering and Science ISITES'2015*, Valencia, Spain, 3-5 June 2015.

[21] Dogan H., **Kaplan K.**, Kuncan M., Ertunc H. M., Fuzzy Logic Approach to Vehicle Suspension System Control in CAE Environment, *International Symposium on Innovative Technologies in Engineering and Science ISITES'2015*, Valencia, Spain, 3-5 June 2015.

[22] Kuncan M., **Kaplan K.**, Position Determination by Using Image Processing Method in Inverted Pendulum, *International Engineering, Science and*

Education Conference INESEC'2016, Diyarbakir, Turkey, 1-3 December 2016.

[23] Ciftci O., Kacar E., Yildirim M., Bilgin U., Yukseli T., **Kaplan K.**, Guner H. E., Kuncan M., Erdil A., Real Time PI Implementation on Flow Rate Control Using with PLC *International Congress on Natural and Engineering Sciences ICNES'2016,* Skopje, Macedonia, 1-5 September 2016.

[24] **Kaplan K.**, Kuncan M., Ertunç H. M., Classification of Bearing Fault Size by Using Support Vector Machines, *International Conference on Advances and Innovations in Engineering (ICAIE'17)*, Elazığ, Turkey, 10-12 May 2017.

[25] Karabulut B., Yagiz I. A., **Kaplan K.**, Erdil A., 2d Cartesian Robot Controlling By Eye Tracking, *5th International Symposium on Innovative Technologies in Engineering and Science (ISITES'17)*, Baku, Azerbaijan, 29-30 September 2017.

[26] Gokcedaglioglu A., Kersolar C., **Kaplan K.**, Erdil A., Pipe Inspection Robot, *5th International Symposium on Innovative Technologies in Engineering and Science (ISITES'17)*, Baku, Azerbaijan, 29-30 September 2017.

[27] Hosoz M., **Kaplan K.**, Suhermanto M., Aral N. C., Ertunc H. M., Artificial Neural Network Modelling of a Mobile Air Conditioning System Using Refrigerant R1234yf, *5th International Symposium on Innovative Technologies in Engineering and Science (ISITES'17)*, Baku, Azerbaijan, 29-30 September 2017.

[28] Kose F., **Kaplan K.**, Ertunc H. M., Designing of a Shooting System Using Ultrasonic Radar Sensor, *5th International Symposium on Innovative Technologies in Engineering and Science (ISITES'17)*, Baku, Azerbaijan, 29-30 September 2017.

[29] Hosoz M., **Kaplan K.**, Aral M. C., Suhermanto M., Ertunc H. M., ANFIS Modelling of an Automotive Air Conditioning System Using R1234yf, *the 8th International Advanced Technologies Symposium (IATS'17),* Elazığ, Turkey, 19-22 October 2017.

[30] Kuncan M., **Kaplan K.**, Hizarci B., Kuncan F., Finding Shortest Path by The A* Algorithm, *International Conference on Multidisciplinary, Science, Engineering and Technology (IMESET'17)*, Bitlis, Turkey, 27-29 October 2017.

[31] Köse F., **Kaplan K.**, Ertunç H. M., Real Time Position and Trajectory Control of Ball and Plate System Using Different Control Techniques, *6th International Conference on Control Engineering and Information Technologies, CEIT2018*, Istanbul, Turkey, 25-27 October 2018.

[32] **Kaplan K.**, Ertunç H. M., Gen İfadesi Verisi Kullanarak Prostat Kanseri Teşhisi, SİU2018, S*inyal İşleme ve İletişim Uygulamaları Kurultayı SIU'2018*, İzmir, Türkiye, 2-5 Mayıs 2018.

[33] Cuskun Y., **Kaplan K.**, Ertunc H. M., Diagnosis of Parkinson's Disease Using ANN and SVM Models, *International Conference on Data Science and Applications, ICONDATA 2018*, Yalova, Turkey, 4-7 October 2018.

[34] Hosöz M., **Kaplan K.**, Aral M. C., Suhermanto M., Ertunc H. M., Support vector regression modelling of the performance of an R1234yf automotive air conditioning system, *5th International Conference on Energy and Environment Research, ICEER 2018*, Prague, Czech Republic. 23-27 July 2018.

[35] **Kaplan K.,** Cuşkun Y., Ertunc H. M., Wavelet Decomposition Based Feature Extraction Of Brain MR Images. *The 10th International Conference On Image Processing, Wavelet And Applications (IWW2019)*, Kocaeli, Turkey, 28-30 Octorber 2019.

[36] **Kaplan K.**, Bayram S., Kuncan M., Ertunç H. M., Farklı Rulman Hatalarından Elde Edilen Titreşim Sinyalleri Üzerindeki Radyal Yüklerin Etkisi, *Otomatik Kontrol Türk Milli Komitesi Ulusal Toplantısı, TOK'2012*, Niğde, Türkiye, 11-13 Ekim 2012.

[37] Bayram S., **Kaplan K.**, Kuncan M., Ertunç H. M., Bilyeli Rulmanlarda Zaman Uzayında İstatistiksel Öznitelik Çıkarımı Ve Yapay Sinir Ağları Metodu İle Hata Boyutunun Kestirimi, *Otomatik Kontrol Türk Milli Komitesi Ulusal Toplantısı, Tok2013*, Malatya, Türkiye, 26-28 Eylül 2013.

[38] Köse F., **Kaplan K.**, Ertunç H. M., PID ve Bulanık Mantık İle Dc Motorun Gerçek Zamanda Stm32f407 Tabanlı Hız Kontrolü, *Otomatik Kontrol Türk Milli Komitesi Ulusal Toplantısı, Tok2013*, Malatya, Türkiye, 26-28 Eylül 2013.

[39] Bayram S., **Kaplan K.**, Kuncan M., Ertunç H. M., Rulman Hatalarının Dalgacık Dönüşümü Yöntemi Kullanarak Elde Edilen Katsayılara Etkisi, *IEEE 22. Sinyal İşleme Ve İletişim Uygulamaları Kurultayı, SIU2014*, Trabzon, Türkiye, 23-25 Nisan 2014.

[40] **Kaplan K.**, Kuncan M., Ertunç H. M., Rulman Hata Boyutunun Uyarlanabilir Sinirsel-Bulanık Çıkarımı, *Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SIU2015*, Malatya, Türkiye, 16-19 Mayıs 2015.

[41] Çubukçu A., Kuncan M., **Kaplan K.**, Ertunç H. M., Zigbee Modülü Kullanılarak Ses Kontrollü Ev Otomasyonu Geliştirilmesi, *Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SIU2015*, Malatya, Türkiye, 16-19 Mayıs 2015.

[42] Çubukçu A., Kuncan M., İmren M., Erol F., Ertunç H. M., Öztürk S., **Kaplan K.**, Görüntü İşleme ile 3 Eksenli Robot Mekanizması Üzerinde Nesne Ayırt Edilmesi ve Sıralanması, *Otomatik Kontrol Türk Milli Komitesi Ulusal Toplantısı, TOK2015*, Denizli, Türkiye, 10-12 Eylül 2015.

[43] Doğan H., **Kaplan K.**, Kuncan M., Ertunç H. M., Araç Süspansiyon Sistemi Kontrolüne PID ve Bulanık Mantık Yaklaşımları, *Otomatik Kontrol Türk Milli Komitesi Ulusal Toplantısı, TOK2015*, Denizli, Türkiye10-12 Eylül 2015.

[44] Karakoç H, Erin K., Çağıran R, Subaşı A., Kuncan M., **Kaplan K.**, Ertunç H. M., Uçak Yükseklik Kontrolünde PD Kontrolör ve Bulanık Mantık Kontrolör Performans Karşılaştırması, *Otomatik Kontrol Türk Milli Komitesi Ulusal Toplantısı, TOK2015*, Denizli, Türkiye, 10-12 Eylül 2015.

[45] Cuşkun Y., Duman F., Basik H., Gün F., **Kaplan K.**, Ertunc H. M., Image processing based multi-purpose 4-axis robot mechanism. *In Electrical, Electronics and Biomedical Engineering, ELECO'2016*, Bursa, Turkey, 1-3 December 2016.

[46] Çakar Y., Çakar Z., Yenioğlu O., **Kaplan K.**, Ertunç H. M., Araç Sürüş Simülatörü için 3 Serbestlik Dereceli Paralel Hareket Platformu, *Otomatik Kontrol Ulusal Toplantısı, TOK'2019*, Muğla, 11-14 Eylül 2019.

[47] Ceylan N., Kaçar S., Ertunç H. M., **Kaplan K.**, Diagnosis of Bearing with Signal Processing and Artificial Neural Networks, *4th International Conference on Computational and Experimental Science and Engineering (ICCESEN-2017)*, Antalya, Turkey, 4-8 October 2017.

[48] Kuncan M., **Kaplan K.**, Ertunç H. M., Küçükateş S., Experimental Investigation of Cutting Speed on the Surface Roughness for CNC Machine, *1st International Engineering and Technology Symposium, IETS'18*, Batman, Turkey, 3-5 May 2018.

[49] **Kaplan K.**, Aral M. C., Suhermanto M., Ertunc H. M., Hoşöz M., Gaussian Process Regression Modelling of The Performance Of An R1234yf Automobile Air Conditioning System, *International Conference on Data Science and Applications, ICONDATA 2018*, Yalova, Turkey, 4-7 October 2018.

[50] Vardar E., **Kaplan K.**, Ertunc H. M., Diagnosis Of Brain Tumours From Mr Images By Using Convolutional Neural Networks, *International Conference on Data Science and Applications, ICONDATA 2018*, Yalova, Turkey, 4-7 October.

[51] Kundakçı I. M., **Kaplan K.**, Ertunç H. M., Comparison of ANN and Random Forest Algorithms for Classification of Rolling Bearing Faults. *International Engineering and Science Symposium-IESS 2019*, Siirt, Turkey, 20-20 June 2019.

ÖZGEÇMİŞ

2003 yılında ilk ve ortaokulu Ankara - Ahmet Hızal İlköğretim Okulu'nda, lise öğrenimini ise Ankara - Öğretmen Necla Kızılbağ Lisesi'nde 2007 yılında tamamlamıştır. 2007 yılında girdiği ÖSS sınavında Kocaeli Üniversitesi Mekatronik Mühendisliği bölümünü kazanmıştır ve 2012 yılında Mekatronik Mühendisi olarak mezun olmuştur. 2013 yılı Şubat ayında, Cumhuriyet Üniversitesi Teknoloji Fakültesi Mekatronik Mühendisliği bölümü'nde araştırma görevlisi olarak göreve başlamıştır ve halen görevine devam etmektedir. 2013 yılı Şubat ayında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Anabilim Dalı'nda Yüksek Lisans eğitimine başlamıştır. 2015 yılında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Anabilim Dalı'nda Doktora eğitimine başlamıştır.