

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BÖLÜTLENMİŞ HİSTOPATOLOJİK GÖRÜNTÜLER
ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE
KOLON KANSERİ TESPİTİ**

DOKTORA TEZİ

Ulaş YURTSEVER

Enstitü Anabilim Dalı : **BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**
Tez Danışmanı : **Dr. Öğr. Üyesi Hayrettin EVİRGEN**

Temmuz 2019

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

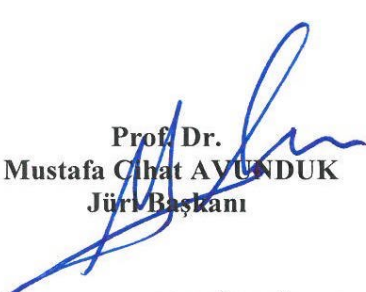
**BÖLÜTLENMİŞ HISTOPATOLOJİK GÖRÜNTÜLER
ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE
KOLON KANSERİ TESPİTİ**

DOKTORA TEZİ

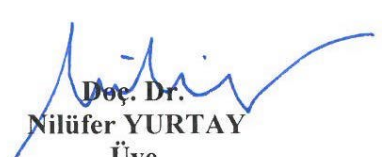
Ulaş YURTSEVER


Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ

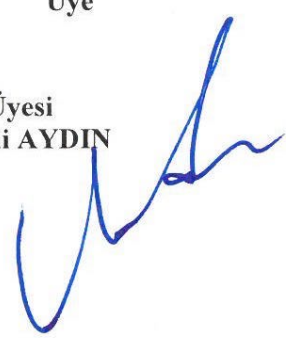
Bu tez 26 / 07 /2019 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.


Prof. Dr.
Mustafa Cihat AYÜNDÜK
Jüri Başkanı


Prof. Dr.
Cemil ÖZ
Üye


Doç. Dr.
Nilüfer YURTAY
Üye


Dr. Öğr. Üyesi
Hayrettin EVİRGEN
Üye


Dr. Öğr. Üyesi
Muhammed Ali AYDIN
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Bu tez içinde Karar Sayısı: 2015/116 olan Necmettin Erbakan Üniversitesi, İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurulu Belgesi ile izin verilmiş olan patoloji arşivinde sakalanan boyalı preparatlardan elde edilen kolon tümörü mikroskop görüntülerinin kullanıldığını, ayrıca Warwick Üniversitesi, Bilgisayar Bilimleri bölümü, <https://warwick.ac.uk/fac/sci/dcs/research/tia/glascontest/> web sayfasında araştırma amaçlı kullanım için izin verilmiş olan kolon tümörü mikroskop görüntülerinin kullanıldığını beyan ederim.

Ulaş YURTSEVER

26.07.2019

TEŞEKKÜR

Doktora eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Dr. Öğr. Üyesi Hayrettin EVİRGEN'e teşekkürlerimi sunarım.

Tez çalışmasında desteğini esirgemeyen, beni yönlendiren ve tez izleme komitesinde yer alan değerli hocalarım Prof. Dr. Mustafa Cihat AVUNDUK ve Doç. Dr. Nilüfer YURTAY'a teşekkür ederim. Ayrıca tezimde kullanılan mikroskobik kolon tümör görüntülerinin sağlanmasında yardımlarını esirgemeyen, görüntülerin etiketlenmesi ve analizi konusunda bilgi ve deneyimlerinden yararlandığım, tezimde kullandığım tıbbi terminoloji konusunda destek olan Necmettin Erbakan Üniversitesi, Cerrahi Tıp Bilimleri Bölümü, Tıbbi Patoloji Anabilim Dalı öğretim üyesi Prof. Dr. Mustafa Cihat AVUNDUK'a teşekkür ederim.

Her zaman yanımda olan, beni destekleyen ve fedakarlık gösteren sevgili eşim Meral YURTSEVER'e, çocuklarım Bahar ve Ural YURTSEVER'e ve beni bu günlere getiren annem ve babama sonsuz teşekkürlerimi sunarım.

Bu çalışmanın maddi açıdan desteklenmesine olanak sağlayan Sakarya Üniversitesi Bilimsel Araştırma Projeleri (BAP) Komisyon Başkanlığına (Proje No: 2014-50-01-027) teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ	xii
ÖZET	xiv
SUMMARY	xv
BÖLÜM 1.	
GİRİŞ	1
1.1. Literatür Özeti	7
1.1.1. Kümeleme algoritmaları için küme başlatma yöntemleri	7
1.1.2. Derin öğrenme yöntemleri ile kolon tümör görüntülerinin sınıflandırılması	13
1.2. Tezin Katkısı	22
1.3. Tezin Organizasyonu	23
BÖLÜM 2.	
GÖRÜNTÜ BÖLÜTLEME	25
2.1. Bölge Tabanlı Bölütleme	28
2.1.1. Bölge büyütme	29
2.1.2. Bölge ayırma ve birleştirme	31
2.2. Kenar/Sınır Temelli Bölütleme	33
2.2.1. Roberts	36
2.2.2. Sobel	37

2.2.3. Prewitt	38
2.2.4. Gauss'un laplası (LoG)	39
2.2.5. Canny	41
2.3. Eşikleme Temelli Bölütleme	43
2.3.1. Global eşikleme	45
2.3.2. Yerel eşikleme	46
2.4. Graf Tabanlı Bölütleme	46
2.5. Kümeleme Tabanlı Bölütleme	49
2.5.1. Hiyerarşik yöntemler	50
2.5.2. Bölünmeli yöntemler	51
2.5.2.1. Uzaklık ölçüleri	51
2.5.2.2. K-ortalamlar kümeleme algoritması	55
2.5.2.3. Ağırlıklı k-ortalamlar kümeleme algoritması	57
2.5.2.4. Geliştirilmiş yeni k-ortalamlar kümeleme algoritması	59
2.6. Histogram Tabanlı Benzerlik Fonksiyonu	61
BÖLÜM 3.	
DERİN ÖĞRENME	63
3.1. Yapay Sinir Ağları	68
3.1.1. Biyolojik sinir hücresi ve yapısı	68
3.1.2. Yapay sinir hücresi ve yapısı	69
3.1.3. YSA'nın yapısı	72
3.1.4. YSA'nın eğitilmesi	75
3.2. Evrişimli Sinir Ağları	77
3.2.1. Evrişim katmanı	78
3.2.2. Havuzlama katmanı	82
3.2.3. Tam bağlantı katmanı	83
3.3. Derin Öğrenme Modelleri	83
3.3.1. LeNet	84
3.3.2. AlexNet	85
3.3.3. GoogLeNet	86
3.4. Veri Artırımı	88

BÖLÜM 4.

UYGULAMALAR VE ARAŞTIRMA BULGULARI	89
4.1. Mikroskop Görüntüsü	89
4.2. Kolon Mikroskop Görüntülerinin Geliştirilmiş Yeni K-Ortalamlar Kümeleme Algoritması İle Bölütlenmesi	90
4.2.1. Önerilen yeni geliştirilmiş k-ortalamlar kümeleme algoritması	90
4.2.2. Uygulama	91
4.3. Mikroskopik Kolon Görüntülerinin Sınıflandırılması İçin Derin Öğrenme Tabanlı Yeni Bir Yaklaşım	101
4.3.1. Veri artırma	101
4.3.2. Uygulama	104

BÖLÜM 5.

SONUÇLAR VE ÖNERİLER	129
KAYNAKLAR	134
ÖZGEÇMİŞ	146

SİMGELER VE KISALTMALAR LİSTESİ

AUC	: Area Under Curve (Eğri Altında Kalan Alan)
BCNN	: Bilinear Convolutional Neural Network
BDE	: Boundary Displacement Error (Sınır Yer Değiştirme Hatası)
CMY	: Cyan Magenta Yellow (Camgöbeği Eflatun Sarı)
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağı)
DCNN	: Deep Convolutional Neural Network (Derin Evrışimli Sinir Ağı)
DL	: Deep Learning (Derin Öğrenme)
DN	: Doğru Negatif
DP	: Doğru Pozitif
ESA	: Evrışimli Sinir Ağı
FCM	: Fuzzy C-Mean
GCE	: Global Consistency Measure (Küresel Tutarlılık Ölçüsü)
GPU	: Graphics Processing Unit (Grafik İşlem Birimi)
H&E	: Hematoksilen ve Eozin
HSI	: Huge Saturation Intensity
IARC	: International Agency for Research on Cancer
ILSVRC	: ImageNet Large Scale Visual Recognition Challenge
LoG	: The Laplacian Of Gaussian (Gauss'un Laplası)
NEP	: Neighboring Ensemble Predictor
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
PRI	: Probabilistic Rand Index (Olasılıksal Rand İndeksi)
ReLU	: Rectified Linear Unit (Doğrutulmuş Doğrusal Birim)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
ROC	: Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
SGD	: Stochastic Gradient Descent (Rasgele Gradyan İnişi)
SRG	: Seeded Region Growing (Tohumlanmış Bölge Büyütme)

SVM	: Support Vector Machine (Destek Vektör Makinesi)
uSRG	: Unseeded Region Growing (Tohumlanmamış Bölge Büyütme)
VGG	: Visual Geometry Group
VoI	: Variation of Information (Bilgi Değişimi)
WHO	: World Health Organization (Dünya Sağlık Örgütü)
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları



ŞEKİLLER LİSTESİ

Şekil 1.1. GLOBOCAN veritabanı verilerine göre yıl bazında yeni görülen vaka sayısı.....	2
Şekil 1.2. GLOBOCAN veritabanı verilerine göre yıl bazında kanserden kaynaklı ölüm sayısı	2
Şekil 1.3. Kolon ve rektumdan oluşan kalın bağırsak ve bölümleri	3
Şekil 1.4. Mikroskopik kolon doku görüntüleri: (a) iyi huylu kolon tümör görüntüsü, (b) kötü huylu kolon tümör görüntüsü.....	4
Şekil 2.1. Görüntü bölütleme yöntemleri.....	27
Şekil 2.2. Bölge ayırma ve birleştirme	32
Şekil 2.3. (a) Orijinal iyi huylu tümör görüntüsü (b) Canny operatörü uygulanmış görüntü (c) LoG operatörü uygulanmış görüntü (d) Sobel operatörü uygulanmış görüntü (e) Roberts operatörü uygulanmış görüntü (f) Prewitt operatörü uygulanmış görüntü	34
Şekil 2.4. (a) Orijinal kötü huylu tümör görüntüsü (b) Canny operatörü uygulanmış görüntü (c) LoG operatörü uygulanmış görüntü (d) Sobel operatörü uygulanmış görüntü (e) Roberts operatörü uygulanmış görüntü (f) Prewitt operatörü uygulanmış görüntü	35
Şekil 2.5. Roberts operatör maskesi.....	37
Şekil 2.6. Sobel operatör maskesi.....	38
Şekil 2.7. Prewitt operatör maskesi	38
Şekil 2.8. LoG fonksiyonunun 3 boyutlu çizimi.....	40
Şekil 2.9. The laplacian of gaussian operatör maskesi	40
Şekil 2.10. Örnek bir Gauss eğrisinin görünümü.....	42
Şekil 2.11. Örnek bir yönsüz graf görünümü.....	47
Şekil 2.12. İki boyutlu uzayda P ve Q arasındaki d uzaklığı	52

Şekil 2.13. Uzaklık ölçüleri iki boyutlu gösterimi: (a) Öklid, (b) Manhattan, (c) Chebyshev, (d) Mahalanobis.....	54
Şekil 2.14. K-ortalamlar algoritmasının akış şeması	56
Şekil 3.1. Yapay zeka, makine öğrenmesi, derin öğrenme ve veri arasındaki ilişkiyi gösteren venn şeması.....	64
Şekil 3.2. Derin öğrenme kronoloji grafiği.....	66
Şekil 3.3. Yıllara göre derin öğrenme ve evrişimli sinir ağlarının eğilim grafiği.....	67
Şekil 3.4. Sinir hücresinin biyolojik gösterimi	69
Şekil 3.5. Sinir sisteminin blok diyagram olarak gösterimi.....	69
Şekil 3.6. Sinir hücresinin matematiksel modeli	70
Şekil 3.7. Örnek aktivasyon fonksiyonu grafikleri: (a) doğrusal fonksiyon, (b) sigmoid fonksiyonu, (c) basamak fonksiyonu, (d) hiperbolik tanjant fonksiyonu, (e) eşik değeri fonksiyonu, (f) rampa fonksiyonu	72
Şekil 3.8. Tek katmanlı ileri beslemeli ağ topolojisi	73
Şekil 3.9. Çok katmanlı ileri beslemeli ağ topolojisi.....	74
Şekil 3.10. Örnek çok katmanlı ileri beslemeli YSA.....	75
Şekil 3.11. Geleneksel bir sinir düğümü.....	77
Şekil 3.12. ESA sinir düğümü	78
Şekil 3.13. Temel bir ESA modeli.....	78
Şekil 3.14. 3x3'lük bir filtre ile evrişim işlemi.....	79
Şekil 3.15. Sıfır dolgulama işlemi	81
Şekil 3.16. Maksimum havuzlama işlemi.....	82
Şekil 3.17. Örnek tam bağlantı katmanı	83
Şekil 3.18. LeNet modeli	84
Şekil 3.19. AlexNet modeli.....	85
Şekil 3.20. Örnek GoogLeNet mimarisi blok şeması	86
Şekil 3.21. Basit inception modülü.....	87
Şekil 3.22. Inception modülü.....	87

Şekil 4.1.	Orijinal kolon tümör görüntüleri: (a) iyi huylu tümör görüntüsü, (b) iyi huylu tümör görüntüsünün çekirdek bölütlemesi için altın standart, (c) orijinal kötü huylu tümör görüntüsü, (d) kötü huylu tümör görüntüsünün çekirdek bölütlemesi için altın standart	92
Şekil 4.2.	Yazılım ekran görüntüsü: (a) küme sayısı seçim ekranı, (b) k-ortalamlar algoritması uygulama menüsü, (c) görüntü işlemleri uygulama menüsü	93
Şekil 4.3.	Ağırlıklı k-ortalamlar kümeleme algoritması ile iyi huylu tümör görüntülerinin bölütlenmesi: (a) 3 küme, (b) 4 küme, (c) 5 küme, (d) 6 küme.....	94
Şekil 4.4.	Ağırlıklı k-ortalamlar kümeleme algoritması ile kötü huylu tümör görüntülerinin bölütlenmesi: (a) 3 küme, (b) 4 küme, (c) 5 küme, (d) 6 küme.....	95
Şekil 4.5.	Geliştirilmiş yeni k-ortalamlar kümeleme algoritması ile iyi huylu tümör görüntülerinin bölütlenmesi: (a) 3 küme, (b) 4 küme, (c) 5 küme, (d) 6 küme	96
Şekil 4.6.	Geliştirilmiş yeni k-ortalamlar kümeleme algoritması ile kötü huylu tümör görüntülerinin bölütlenmesi: (a) 3 küme, (b) 4 küme, (c) 5 küme, (d) 6 küme	97
Şekil 4.7.	Bölütleme işleminde ağırlıklı k-ortalamlar kümeleme algoritması ile geliştirilmiş yeni k-ortalamlar kümeleme algoritması arasındaki iterasyon farkı.....	99
Şekil 4.8.	Bölütleme işleminde ağırlıklı k-ortalamlar kümeleme algoritması ile geliştirilmiş yeni k-ortalamlar kümeleme algoritması arasındaki zaman farkı.....	99
Şekil 4.9.	İyi huylu tümör görüntüsü için uygulanan veri artırım işlemleri: (a) orijinal görüntü, (b) yatay çevirme, (c) dikey çevirme, (d) 90° döndürme, (e) 180° döndürme, (f) 270° döndürme, (g) gauss gürültüsü	102

Şekil 4.10. Kötü huylu tümör görüntüsü için uygulanan veri artırım işlemleri: (a) orijinal görüntü, (b) yatay çevirme, (c) dikey çevirme, (d) 90° döndürme, (e) 180° döndürme, (f) 270° döndürme, (g) gauss gürültüsü	103
Şekil 4.11. Digits 6.0 web tabanlı uygulama arayüzü	105
Şekil 4.12. Önerilen ESA sınıflandırma yaklaşımı	107
Şekil 4.13. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par” veri kümelerinin AlexNet model doğruluklarının karşılaştırması	109
Şekil 4.14. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par_ozel” veri kümelerinin AlexNet model doğruluklarının karşılaştırması	110
Şekil 4.15. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir” veri kümelerinin AlexNet model doğruluklarının karşılaştırması	110
Şekil 4.16. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir_ozel” veri kümelerinin AlexNet model doğruluklarının karşılaştırması	111
Şekil 4.17. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par” veri kümelerinin GoogLeNet model doğruluklarının karşılaştırması....	113
Şekil 4.18. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par_ozel” veri kümelerinin GoogLeNet model doğruluklarının karşılaştırması	113
Şekil 4.19. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir” veri kümelerinin GoogLeNet model doğruluklarının karşılaştırması....	114
Şekil 4.20. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir_ozel” veri kümelerinin GoogLeNet model doğruluklarının karşılaştırması	114
Şekil 4.21. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par” veri setleri üzerinde eğitilen AlexNet modelinin tahmin gücünü gösteren ROC eğrileri	116
Şekil 4.22. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par_ozel” veri setleri üzerinde eğitilen AlexNet modelinin tahmin gücünü gösteren ROC eğrileri	116

Şekil 4.23. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir” veri setleri üzerinde eğitilen AlexNet modelinin tahmin gücünü gösteren ROC eğrileri	117
Şekil 4.24. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir_ozel” veri setleri üzerinde eğitilen AlexNet modelinin tahmin gücünü gösteren ROC eğrileri	117
Şekil 4.25. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par” veri setleri üzerinde eğitilen GoogLeNet modelinin tahmin gücünü gösteren ROC eğrileri	118
Şekil 4.26. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par_ozel” veri setleri üzerinde eğitilen GoogLeNet modelinin tahmin gücünü gösteren ROC eğrileri	119
Şekil 4.27. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir” veri setleri üzerinde eğitilen GoogLeNet modelinin tahmin gücünü gösteren ROC eğrileri	119
Şekil 4.28. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir_ozel” veri setleri üzerinde eğitilen GoogLeNet modelinin tahmin gücünü gösteren ROC eğrileri	120
Şekil 4.29. K-katlı çapraz doğrulama yöntemi	121

TABLolar LİSTESİ

Tablo 2.1. Denetimsiz Graf Kesim algoritmalarının fonksiyonları	48
Tablo 3.1. Toplama fonksiyonları.....	71
Tablo 4.1. Ağırlıklı k-ortalamlar kümeleme algoritması ile 3 kere tekrarlanan bölütleme işlemlerinin iterasyon sayısı ve işlem zamanı parametrelerinin korelasyon analizi	98
Tablo 4.2. Geliştirilmiş k-ortalamlar kümeleme algoritması ile 3 kere tekrarlanan bölütleme işlemlerinin iterasyon sayısı ve işlem zamanı parametrelerinin korelasyon analizi	98
Tablo 4.3. Geliştirilmiş yeni k-ortalamlar kümeleme algoritmasının ağırlıklı k-ortalamlar kümeleme algoritmasına göre iterasyon sayısı ve işlem zamanı parametreleri açısından performans analizi.....	100
Tablo 4.4. Bölütlenmiş görüntülerin orijinal görüntüye benzerliğinin, histogram tabanlı benzerlik yöntemi ile analizi.....	101
Tablo 4.5. Orijinal ve k3, k4, k5, k6 bölütlenmiş görüntülerin olduğu 20 adet farklı veri kümesi için eğitim, doğrulama ve test veri seti görüntü sayısı	107
Tablo 4.6. AlexNet modeli kullanılarak oluşturulan ağırlıklı test kümesi ile test edilmesi sonucunda elde edilen karışıklık matrisi.....	108
Tablo 4.7. GoogLeNet modeli kullanılarak oluşturulan ağırlıklı test kümesi ile test edilmesi sonucunda elde edilen karışıklık matrisi	112
Tablo 4.8. K-katlı çapraz doğrulama ile oluşturulan, orijinal görüntülerin olduğu “par” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları	122
Tablo 4.9. K-katlı çapraz doğrulama ile oluşturulan, orijinal görüntülerin olduğu “par_ozel” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları	122

Tablo 4.10. K-katlı çapraz doğrulama ile oluşturulan, orijinal görüntülerin olduğu “bir” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları	123
Tablo 4.11. K-katlı çapraz doğrulama ile oluşturulan, orijinal görüntülerin olduğu “bir_ozel” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları	124
Tablo 4.12. K-katlı çapraz doğrulama ile oluşturulan, 3 kümeye bölütlenmiş görüntülerin olduğu “par” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları	124
Tablo 4.13. K-katlı çapraz doğrulama ile oluşturulan, 3 kümeye bölütlenmiş görüntülerin olduğu “par_ozel” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları.....	125
Tablo 4.14. K-katlı çapraz doğrulama ile oluşturulan, 3 kümeye bölütlenmiş görüntülerin olduğu “bir” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları	126
Tablo 4.15. K-katlı çapraz doğrulama ile oluşturulan, 3 kümeye bölütlenmiş görüntülerin olduğu “bir_ozel” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları.....	127
Tablo 4.16. Orijinal ve 3 kümeye bölütlenmiş görüntülerin GoogLeNet ortalama performans sonuçları karşılaştırması	127
Tablo 4.17. K-katlı çapraz doğrulama sonucunda elde edilen GoogLeNet ortalama performans sonuçları ile 3 kümeye bölütlenmiş görüntülerin GoogLeNet performans sonuçları karşılaştırması	128

ÖZET

Anahtar kelimeler: K-ortalamalar, görüntü bölütleme, derin öğrenme, evrişimli sinir ağı, kolon kanseri

Bu çalışmada, mikroskoba monte edilmiş kamera ile çekilmiş ve Hematoksilen ve Eozin boyama tekniğiyle boyanmış, insana ait renkli kolon doku görüntüleri üzerinde çalışılmıştır. Çalışma iki aşamadan oluşmaktadır. İlk aşamada kolon tümör görüntüleri üzerinde hücre ve hücre çekirdeklerinin bölütlenmesi için geliştirilmiş k-ortalamalar kümeleme algoritması önerilmiştir. Önerilen geliştirilmiş k-ortalamalar kümeleme algoritmasında başlangıç küme merkezleri, renk aralığının küme sayısına bölünmesi ile elde edilen değerlerin atanması ile belirlenmiştir. Önerilen algoritma ile ağırlıklı k-ortalamalar kümeleme algoritması karşılaştırılmıştır. Karşılaştırma sırasında tüm işlemler aynı şartlar altında 3 defa tekrarlanmış ve algoritmaların performansı ve kararlı olma durumları incelenmiştir. Yapılan deneyler sonucunda, geliştirilmiş k-ortalamalar kümeleme algoritmasının, iterasyon sayısını ve dolayısıyla da işlem zamanını kısalttığı tespit edilmiştir. Ayrıca ilk küme merkezlerinin rasgele belirlenmesi yerine önerilen yaklaşım ile belirlenmesi sonucunda daha kararlı olduğu görülmüştür. Buna ilave olarak bölütleme sonucunda elde edilen görüntülerin orijinal görüntülere olan benzerliği, histogram tabanlı benzerlik algoritması kullanılarak hesaplanmıştır. Bu hesaplama sonucunda, geliştirilmiş k-ortalamalar kümeleme algoritması orijinal görüntülere daha benzer olduğu tespit edilmiştir. İkinci aşamada ise evrişimli sinir ağları modellerinden AlexNet ve GoogLeNet modelleri kullanılarak kolon kanser sınıflandırması üzerine yeni bir yaklaşım önerilmiştir. Bu yaklaşımda evrişimli sinir ağlarının orijinal ham görüntüler kullanılarak eğitilmesi yerine ilk aşamada önerdiğimiz bölütleme yöntemi ile renk kümelerine bölütlenmiş görüntülerin kullanılarak eğitilmesi önerilmiştir. Bunun için orijinal-ham görüntülerin olduğu veri kümesi ile bölütlenmiş görüntülerin olduğu veri kümesinden 20 farklı yapıda ve farklı özellikte görüntü veri setleri elde edilmiştir. Oluşturulan veri setleri AlexNet ve GoogLeNet evrişimli sinir ağları modellerinde kullanılarak eğitilmiş ve test edilmiştir. Elde edilen test sonuçlarına göre karmaşıklık matrisleri oluşturulmuş, ROC eğrileri çizilmiş ve AUC değerleri hesaplanmıştır. Elde edilen sonuçlara göre, bölütlenmiş görüntüler kullanılarak eğitilen AlexNet modelinin %2 ile %23 arasında bir model performans artışı gösterdiği, GoogLeNet modelinin ise %2 ile %27 arasında bir model performans artışı gösterdiği tespit edilmiştir. Ayrıca veri dağılımının düzgün yapılmadığı veri setlerinde önerilen yaklaşımın daha yüksek performans artışı gösterdiği görülmüştür.

DETECTING COLON CANCER USING DEEP LEARNING ON SEGMENTED HISTOPATHOLOGICAL IMAGES

SUMMARY

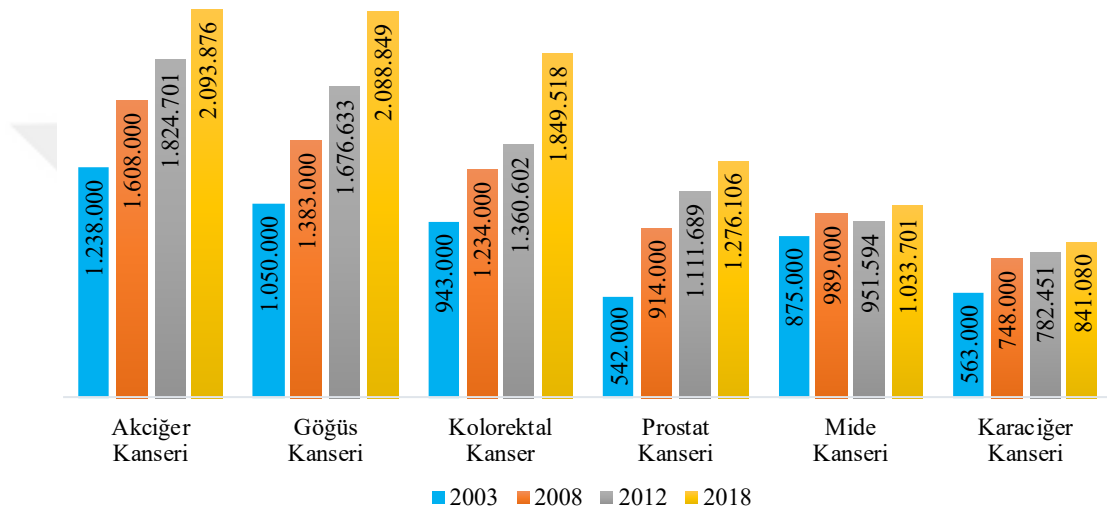
Keywords: K-means, image segmentation, deep learning, convolutional neural network, colon cancer

This study is based on color human colon tissue images, shot with a microscope mounted camera and dyed with the Hematoxylin and Eosin dye technique. The study is composed of two stages. The first stage led to the proposal of the augmented k-means clustering algorithm for the segmentation of cells and cell nuclei on colon tumor images. In the proposed augmented k-means clustering algorithm, the starting cluster centers were identified with the assignment of the values obtained by dividing the color range by the number of clusters. The proposed algorithm was then compared with the weighted k-means clustering algorithm. During the comparison, all processes were repeated 3 times under the same set of conditions, with a view to analyzing the performance and stability of the algorithms. The experiments revealed that the augmented k-means clustering algorithm reduced the iteration count and consequently the process time. Moreover, the use of the proposed approach instead of the random positioning of the initial cluster centers was observed to lead to higher stability. In addition, the similarity of the images obtained through segmentation with the original ones was assessed using the histogram-based similarity algorithm. The assessment found that the use of the augmented k-means clustering algorithm produced images which are more similar to the original images. In the second stage, on the other hand, two models of convolutional neural networks –AlexNet and GoogLeNet– were employed, culminating in a new approach towards the classification of colon cancer. In this context, for the purpose of training the convolutional neural networks, the images segmented into color clusters through the segmentation method proposed in the first stage, instead of the original-raw images, were employed. For this purpose, 20 datasets of images which are distinct in terms of their structure and characteristics were derived from the larger datasets comprised of the original-raw images, as well as the segmented images. The datasets thus produced were then employed with the AlexNet and GoogLeNet convolutional neural network models, to train them and for testing. The test results provided the input for the development of confusion matrices, drawing of ROC curves, and the calculation of AUC values. The results show that the AlexNet model trained through the use of the segmented images registered a 2% to 23% increase in the model performance, whereas the GoogLeNet model thus trained had a 2% to 27% increase in the model performance. Furthermore, the proposed approach was found to lead to higher performance with the datasets in which the data was not homogenous.


BÖLÜM 1. GİRİŞ

Kanser, dünya genelinde ve Türkiye’de ölüm nedenleri içinde ikinci sırada yer alan bir hastalık grubudur. Kara ve arkadaşlarının 2018 yılında yayınladıkları rapora göre, özellikle dünya nüfusunda görülen artış, yaşlı nüfusunun artması, çevresel etkilere ve kansere sebep olabilecek etkilere olan maruziyetin yüksek olması yeni kanser olgularının sayısında artışa neden olmaktadır ve bu artışın gelecekteki kanser yükünü de arttıracak beklenmektedir (Kara ve ark., 2018). Yıllara göre kanser raporları incelendiğinde kanser yükündeki bu artışlar açıkça görülmektedir. Dünya Sağlık Örgütü (WHO) Uluslararası Kanser Araştırmaları Ajansı’nın (IARC) yayınladığı GLOBOCAN 2008 raporuna göre, dünya genelinde 12,7 milyon yeni kanser vakasının meydana geldiği ve 7,6 milyon kişinin kanser sebebiyle öldüğü belirtilmektedir. Kanser yükü incelendiğinde ise insidans yönünden dünyada en yaygın kanserlerden ilk üçünün sırasıyla akciğer (1,60 milyon kişi), meme (1,38 milyon kişi) ve kolorektal (1,23 milyon kişi) kanseri olduğu görülmektedir (Boyle ve Levin, 2008). 2012 yılında ise dünya genelinde meydana gelen yeni kanser vakası sayısı toplam 14,1 milyon olduğu bildirilmektedir. IARC’nın yayınladığı GLOBOCAN 2012 veritabanı verilerine ve 2015 yılı Türkiye Birleşik Veritabanı verilerine göre erkekler arasında kolorektal kanser sıralaması, dünya genelinde, Türkiye’de ve Avrupa Birliği ülkeleri arasında üçüncü sırada olduğu, kadınlar arasında kolorektal kanser sıralaması ise dünya genelinde ve Avrupa Birliği ülkeleri arasında ikinci sırada, Türkiye’de ise üçüncü sırada olduğu rapor edilmektedir (Kara ve ark., 2018). Son çıkan 2018 yılı GLOBOCAN raporuna göre ise, 18,1 milyon yeni kanser vakasının, %11,6’sını akciğer kanseri, %11,6’sını göğüs kanseri ve üçüncü sırada da %10,2’sini kolorektal kanser oluşturmaktadır. 9,6 milyon ölüm vakasının ilk sırasında %18,4 ile akciğer kanseri, ikinci sırasında ise %9,2 ile kolorektal kanseri yer almaktadır (Bray ve ark., 2018). GLOBOCAN veritabanı verilerine göre önemli altı kanser türünün yıllara göre görülen yeni kanser vaka sayısı Şekil 1.1.’de, yine yıllara göre kanserden kaynaklı

ölüm sayısı ise Şekil 1.2.'de gösterilmiştir. Şekiller incelendiğinde de görüldüğü ki kanser vakaları yıllar geçtikçe katlanarak artmaktadır. Ayrıca, bu kanser vakaları içinde kolorektal kanserin en çok görülen üçüncü kanser türü olduğu görülmüştür. Kanserden kaynaklı ölüm sayısına bakıldığında ikinci sırada kolorektal kanser sebebiyle meydana gelen ölümlerin olduğu görülmektedir (GLOBOCAN, 2018). Dolayısıyla bu durum kolorektal kanserinin erken evrede ve kesin şekilde teşhisini önemli kılmaktadır.




Şekil 1.1. GLOBOCAN veritabanı verilerine göre yıl bazında yeni görülen vaka sayısı



Şekil 1.2. GLOBOCAN veritabanı verilerine göre yıl bazında kanserden kaynaklı ölüm sayısı

Koleraktal kanserler, sindirim sisteminin kalın bağırsak kısmında oluşan kanserlerdir. Şekil 1.3.'te görüldüğü üzere kolon ve rektum'dan oluşan kalın bağırsağın son 15cm'lik kısmını rektum, 1,5m'lik büyük bir kısmını ise kolon oluşturmaktadır. Kolon kanserleri genellikle en içteki katmanda küçük bir gelişim yani polip veya adenoma olarak başlamaktadır (Yarbuğ Karakayalı, 2019).




Şekil 1.3. Kolon ve rektumdan oluşan kalın bağırsak ve bölümleri (Yarbuğ Karakayalı, 2019)

Bütün kanserler vücudumuzun yapı taşı olan hücrelerin genetik yapılarının bozulmasıyla gelişmektedirler. İnsan vücudunun sağlıklı olması, metabolizmasının iyi bir şekilde çalışması ancak bu hücrelerin programlı bir şekilde çoğalması, bölünmesi ve yıprandıklarında veya hasar gördüğünde ölmesi ile olmaktadır. Fakat bazen bu işleyiş neoplastik hastalıklarda olduğu gibi bozularak yani genetik yapısı değişerek, hücrenin farklılaşp kontrolsüz bir şekilde çoğalması ve bozulması ile bölünme devam etmektedir. Bölünmesi kontrolsüz bir şekilde devam eden çoğalan hücreler, bir kütleli veya tümörleri oluşturmaktadır (Kanser Dairesi Başkanlığı, 2019). Tümör oluşturmayan kanser türleri de bulunmaktadır. Kan kanseri bu kanser türlerine örnek olarak verilebilir.

Tümörler, iyi huylu (benign) ve kötü huylu (malignant) tümörler olarak iki sınıfta gruplandırılmaktadır. Şekil 1.4.'te Hematoksilin ve Eozin (H&E) boyama tekniği ile boyanmış insana ait renkli mikroskopik kolon doku görüntüleri gösterilmektedir. Şekil 1.4. (a)'da iyi huylu kolon tümör görüntüsü ve Şekil 1.4. (b)'de ise kötü huylu kolon

tümör görüntüsü görülmektedir. İyi huylu kolon tümör görüntüleri üzerinde bez (gland), hücre (cell) ve çekirdek (nucleus) yapıları işaretlenmiştir. İyi huylu tümör görüntüsünde çekirdekler küçük ve bez'i çevreleyen tarzda düzenli bir yapı olarak gözükmemektedir. Ayrıca bez yapıları da düzenli ve yuvarlaktır. Kötü huylu tümör görüntüsüne bakıldığında ise çekirdekler büyük ve boyut farklılıkları bulunmaktadır. Bez yapıları düzensiz ve yuvarlaklık kaybolmuş şekildedir.



Şekil 1.4. Mikroskopik kolon doku görüntüleri: (a) iyi huylu kolon tümör görüntüsü, (b) kötü huylu kolon tümör görüntüsü

Kolon tümörlerinin doğru bir şekilde kesin tanısının yapılabilmesi için patolojik inceleme önemli bir işlemdir. Bu işlem, biyopsi yöntemiyle doku üzerinden alınmış örneklerin mikroskop altında incelenmesi sonucunda hücrelerin ve çekirdeklerin konumu, yapısal ve işlevsel bozulmaları da göz önüne alınarak uzman bir patoloj tarafından görsel olarak incelenip karar verilmesi şeklinde gerçekleşmektedir. Patolojik olarak tanı konulurken, ilk başta makroskopik ve mikroskopik özellikler değerlendirilmektedir. Bu değerlendirmede hücre, doku ve organlardaki normalden farklılaşmalar araştırılarak tanıya gidilmektedir. Makroskopik ve mikroskopik görüntülerin değerlendirilmesi patolojilerin bilimsel birikimi ile yapılmaktadır (Isik ve ark., 2010). Bu inceleme temel olarak görsel yorumlamaya dayanır ve bu nedenden dolayı, gözlemci-içi (intra-observer) ve gözlemciler-arası (inter-observer) farklı yorumlamaya, bu da standart ve objektif olmayan durumlara yol açabilmektedir. Özellikle kanser sınıflandırmasında değişkenlik ve farklı yorumlama daha fazla

olmaktadır (Altunbay ve ark., 2010). Bu nedenle objektif sonuçların elde edilmesi ve standart verilerin konu ile ilgili hekimler tarafından kesin olarak kabul edilebilmesi için çeşitli görüntü analiz sistemleri geliştirilmiştir. Bu görüntü analiz sistemlerindeki en önemli aşamaları görüntü bölütleme ve görüntü sınıflandırma oluşturmaktadır.

Görüntü bölütleme (image segmentation) bir görüntüyü anlamlı alt nesnelere ayırma işlemidir. Başka bir deyişle, görüntü bölütleme bir görüntüdeki benzer özelliklere sahip piksellerin veya görüntü (image) içindeki elemanların farklı kümelerde sınıflandırılması işlemidir (Sathya ve Manavalan, 2011). Görüntü bölütleme, bir görüntü/sahne (scene) içindeki ilgili bölgeleri tanımlamak veya veri etiketleme gibi birçok uygulamada kullanılan bir yöntemdir. Özellikle doku hacimlerinin ve miktarının belirlenmesi, mikroskobik görüntülerde bez-hücre-çekirdeklerin konum ve yerlerinin belirlenmesi, teşhis, anatomik yapı çalışmaları (Pham ve ark., 2000) gibi tıbbi ve mikroskobik görüntülerde önemli bir rol oynar (Pham ve ark., 2000; Sathya ve Manavalan, 2011; Deng ve Manjunath, 2001). Literatürde görüntü bölütleme işlemi için çok sayıda farklı algoritmalar bulunmaktadır. Bu algoritmalar genellikle bölge tabanlı bölütleme algoritmaları (Kancherla ve Mukkamala, 2013; Adams ve Bischof, 1994; Mat-Isa ve ark., 2005; Pohle ve Toennies, 2001; Pan ve Lu, 2007), sınır tabanlı bölütleme algoritmaları (Sharma ve Aggarwal, 2010; Kalviainen ve ark., 1995; Lav ve ark., 1996), eşikleme tabanlı bölütleme algoritmaları (Otsu, 1979; Canny, 1986), hesaplama veya kümeleme tabanlı bölütleme algoritmaları (Juang ve Wu, 2010; Prasath ve ark., 2014; Gunduz-Demir ve ark., 2010; Demir ve ark., 2005; Yogesan ve ark., 1996; Farjam ve ark., 2007; Gunduz-Demir, 2007; Graves ve Pedrycz, 2010) ve graf tabanlı bölütleme algoritmaları (Felzenszwalb ve Huttenlocher, 2004; Shi ve Malik, 2000; Boykov ve Funka-Lea, 2006; Gunduz-Demir ve ark., 2010) olarak beş temel sınıfa ayrılmaktadır (Bengtsson ve ark., 2004; Verma ve ark., 2013; Patil ve Deore, 2013; Singh ve Singh, 2010).

Son yıllarda popüler olan derin öğrenme algoritmalarından evrişimli sinir ağları (ESA) görüntü sınıflandırma için sıklıkla kullanılan algoritmalarından biridir. ESA ilk olarak 1989 yılında Yann LeCun tarafından önerilen (LeCun ve ark., 1989) sonraki yıllarda elyazıyı rakamlarını (MNIST) sınıflandırmak (LeCun ve ark., 1990) ve belge tanıma

için (LeCun ve ark., 1998) LeNet olarak isimlendirilen mimariyi kullanmıştır. Derin öğrenme 2005 yıllarından itibaren kullanılmaya başlansa da çok fazla eğitim datasına ve hesaplama kaynağına ihtiyaç duymasından dolayı 2012 yılına kadar çok fazla ilgi görmemiştir. Özellikle Grafik İşlem Birimlerinin (GPU) gelişmesi, hesaplama maliyetlerinin düşmesi ve çok büyük veri setlerinin elde edilmesiyle birlikte 2012 yılından itibaren büyük bir ivme kazanmış ve bununla birlikte farklı alanlarda kullanılmaya başlanmıştır. Derin öğrenmenin gerçek anlamda ivme kazanması, popüler olması, 2012 yılında yapılan ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC) Alex Krizhevsky ve arkadaşları tarafından sunulan 8 katmanlı derin evrişimli sinir ağları modellerinden olan AlexNet (Krizhevsky ve ark., 2012) ile birlikte gerçekleşmiştir. Daha sonraki yıllarda ise derin öğrenme modellerinden sırasıyla 2013 yılında ZFNet (Zeiler ve Fergus, 2013), 2014 yılında 16 katmanlı VGGNet (Simonyan ve Zisserman, 2014), yine 2014 yılında 22 katmanlı GoogLeNet (Szegedy ve ark., 2015), 2015 yılında 152 katmanlı ResNet (He ve ark., 2016) modelleri kabul görmüş ve popüler olmuştur. Böylelikle sınıflandırma, nesne tanıma, bölütleme, modelleme ve farklı birçok konuda ESA uygulamaları yaygınlaşmıştır. ESA ile genellikle fotoğrafik görüntülerde yüz ve nesne tanıma, medikal görüntülerde kanser ve hastalık sınıflandırması ve tespiti, mikroskobik görüntülerde sınıflandırma ve nesne tanıma üzerine çalışılmaktadır (Yurtsever ve Yurtsever, 2019).

Bu tez çalışmasında, uzman bir patolog tarafından, biyopsi yöntemiyle kolon dokusu üzerinden alınmış parçaların mikroskop görüntüleri analiz edilerek kolon kanserinin teşhis edilmesine ve sınıflandırılmasına yardımcı olacak, yapay zeka tekniklerini kullanan, derin öğrenme tabanlı bir yaklaşım geliştirilmesi amaçlanmıştır. Ayrıca kullanılan standart derin öğrenme modellerinin sınıflandırma performansının artışı sağlayacak yeni yaklaşımlar önerilmiştir. Bu amaçla, kümeleme tabanlı ağırlıklı k-ortalama algoritmasının başlatma parametrelerinin iyileştirilmiş bir versiyonu kullanılarak görüntülerin bölütlenmesi sağlanmış ve aynı renk uzayında orijinal görüntülerin dönüştürülmüş bir versiyonu olan bu görüntüler, AlexNet ve GoogLeNet ESA modellerinde eğitim (training) ve test veri seti olarak kullanılmıştır. Bu yöntem

ile orijinal ve ham görüntüler kullanan derin öğrenme algoritmalarına göre daha performanslı bir sınıflandırma başarımı elde edilmesi sağlanmıştır.

1.1. Literatür Özeti

Bu tez çalışmasında mikroskopik kolon tümör görüntülerinin geliştirilmiş yeni k-ortalama kümeleme algoritması ile bölütlenmesi gerçekleştirilmiş, sonraki aşamada ise bölütlenen bu görüntülerin kullanılmasının derin öğrenme tabanlı sınıflandırmada model performans başarımına etkileri araştırılmış ve derin öğrenme algoritmaları kullanılarak yapılacak sınıflandırmada yeni bir yaklaşım önerilmiştir. Bu nedenle de literatür araştırması birbirinden farklı iki alanda yapılmıştır. Bu alanlardan birincisi, kümeleme algoritmalarında, özellikle k-ortalama algoritmalarında, küme başlatma parametrelerinin ve yöntemlerinin performans etkilerini inceleyen çalışmalar, ikincisi ise kolon tümör görüntüleri üzerinde derin öğrenme tabanlı evrişimli sinir ağları kullanılarak yapılan sınıflandırma çalışmalarıdır.

1.1.1. Kümeleme algoritmaları için küme başlatma yöntemleri

Literatürde k-ortalama kümeleme algoritması kullanılarak farklı alanlarda birçok uygulama yapılmıştır. Yapılan uygulamaların çoğunda kullanılan k-ortalama kümeleme algoritmasında, küme merkezi başlatma işlemlerinde genellikle iki basit yaklaşım kullanılmıştır. İlk küme merkez değerleri, veri kümesindeki elemanlar içinden ilk örnekleri seçmek şeklinde veya rasgele olarak atanması şeklinde belirlenmiştir. Yapılan bu literatür araştırmasında özellikle küme başlatma yöntemlerinin algoritma performansına etkisini inceleyen çalışmalar incelenmiştir. Literatürdeki küme başlatma yöntemleri ile ilgili yapılan çalışmalar ve önerilen yöntemler genellikle rasgele örnekleme yöntemleri, mesafe optimizasyon yöntemleri ve yoğunluk tahmin yöntemlerinden birine dayanmaktadır. Celebi ve arkadaşları (2013) bu yöntemleri quadratic karmaşıklık, loglineer zaman karmaşıklığı, lineer zaman karmaşıklığı başlatma yöntemleri şeklinde üç kategoriye ayırmışlardır. Yapılan literatür araştırmasında, özellikle başlangıç parametrelerinin, ilk kümenin veya ilk küme merkezlerinin seçiminin ve bu seçim için kullanılan yöntemlerin, elde edilecek

son kümeyi etkileyen önemli parametrelerden biri olduğu tespit edilmiştir. Bu ilkendirme parametrelerinin seçimi, özellikle mesafe ölçümüne dayalı kümeleme algoritmalarında daha çok etkili olduğu görülmüştür. Kümeleme tabanlı algoritmalarda küme başlatma yöntemlerinin, ilk küme seçiminin ve ilk küme merkezi seçme yöntemlerinin etkileri hakkında yapılan literatür araştırması detayları aşağıda verilmiştir.

Al-Daoud ve Roberts (1996) çalışmalarında, k-ortalama algoritması için iki başlatma yöntemi geliştirmişlerdir. Önerdikleri yöntemlerdeki temel düşünce, küme merkezlerini veri dağılımına göre makro seviyede başlatmaktır. İlk önerdikleri yöntemde veri noktalarının yoğunluğuna göre küme merkezlerini doğrudan dağıtmaktadır. İkinci yöntemde ise küme merkezlerinin optimal dağılımı seyrek bölgelerde büyük mesafeyle, yoğun olan bölgelerde ise küçük mesafeyle dengelemeyi önermişlerdir. Bu yöntemleri farklı veri kümelerinde uygulamışlardır. Önerdikleri başlatma yöntemlerinin k-ortalama algoritması ile kullanıldığında iki yöntemin de daha iyi bir performans verdiğini tespit etmişlerdir. Bununla beraber önerdikleri iki yöntemden ikinci yöntemin daha iyi olduğunu bildirmişlerdir.

Bradley ve Fayyad (1998) çalışmalarında, yinmeli algoritmanın daha iyi yerel minimuma (local minimum) yaklaşmasına izin veren geliştirilmiş başlatma yöntemi önermişlerdir. Önerilen yöntemin çalışma süresinin, tüm veritabanının kümelenebilmesi için gereken süreden oldukça az olduğunu bildirmişlerdir. Bu yöntem, küme örnekleme yöntemine benzer şekilde, belirli bir veri kümesinin küçük alt-örnekleri ile çalışmaktadır. Bu yöntem ile tüm veri kümesi için gereken toplam belleğin küçük bir kısmı kullanılmış olmaktadır. Dolayısıyla bu çalışmada önerilen yaklaşım için özellikle büyük ölçekli veri kümelerinde yapılacak kümeleme için önemli bir avantaj sağladığı bildirilmiştir.

Pena ve arkadaşları (1999) çalışmalarında, veri kümeleme sorununun veri bölümlenmesi sorunu olduğunu düşünerek, kümeleme algoritmalarında başlatma yöntemlerinin etkisini ve başarımlarını deneysel olarak incelemişlerdir. K-ortalama kümeleme algoritması için Random, Forgy, MacQueen ve Kaufman

başlatma yöntemlerini, son kümenin kalitesi ve başlangıç koşullarına olan duyarlılık kriterine göre deneysel olarak karşılaştırmışlardır. Ayrıca yaptıkları çalışmada, her bir başlatma yöntemi kullanılırken k-ortalamlar algoritmasının yakınsama hızını yani yakınsaması için gereken iterasyon sayısını karşılaştırmışlardır. Yapılan çalışmada k-ortalamlar kümeleme algoritmasının başlangıç koşullarından etkilenen algoritma olmasından dolayı, yöntemlerin karşılaştırması bu algoritma üzerinde uygulanmıştır. Yapılan deneyler sonucunda, Random ve Kaufman başlatma yöntemlerinin k-ortalamlar algoritmasını ilk kümelemede daha etkili ve daha bağımsız bir hale getirdiğini tespit etmişlerdir. Ayrıca, yakınsaması için gereken iterasyon sayısı açısından ise Kaufman yönteminin daha iyi sonuç verdiğini belirtmişlerdir.

Albayrak ve Karslıgil (Albayrak, 2001; Albayrak ve Karslıgil, 2001) çalışmalarında, RGB ve CIE Lab renk uzayında mesafeye bağlı bir kümeleme yöntemi olan k-ortalamlar kümeleme algoritmasını histogram bilgisinden de yararlanacak şekilde uygulamaya yönelik olarak değiştirmiş ve ağırlıklı k-ortalamlar kümeleme isminde yeni bir algoritma önermişlerdir. Bu yöntemle elde edilen renk sınıfları ile resim tekrar oluşturulduğunda orijinal görüntüye daha benzer görüntüler elde edilmiştir. Ayrıca, geliştirilen algoritma ile k-ortalamlar kümeleme algoritması 120 adet görüntü üzerinde test edilerek karşılaştırılmıştır. Geliştirilen algoritmanın geleneksel k-ortalamlar algoritmasına göre daha başarılı renk toplama işlemi yaptığı belirtilmiştir.

Meila ve Hekerman (2001) çalışmalarında, ilk küme merkezlerini seçmek için kabul edilmiş bir kural olmadığından, model tabanlı kümeleme için aynı modelleri kullanan üç temel algoritmayı yüksek boyutlu ayrık değişkenli veri kümeleri üzerinde test ederek deneysel bir karşılaştırma yapmışlardır. Yapılan deneysel çalışmalar sonucunda, kümeleme algoritmalarından biri olan Expectation-Maximization algoritmasının diğer yöntemlere kıyasla çok daha başarılı bir performans gösterdiklerini tespit etmişler ve sonrasında random, marjinal ve aglomeratif kümeleme gibi başlatma yöntemlerinin algoritma performansı üzerindeki etkisini incelemişlerdir. Random başlatma yöntemleri ile diğer yöntemler arasında iki ilişkili niteliksel fark tespit etmişlerdir. Random başlatma ile öğrenen kümelerin sayısı olarak

daha büyük, boyut olarak da değişkenlik gösterdiğini tespit etmişlerdir. Sentetik veri setinde veriye bağlı başlatma yöntemlerinin, random yöntemine kıyasla çok daha iyi sonuçlar verdiği raporlanmıştır. Dolayısıyla kümeleme algoritmalarında başlangıç parametrelerinin veya başlangıç yöntemlerinin oluşan son kümeyi etkileyen önemli bir ilkendirme kriteri olduğu görülmüştür.

Khan ve Ahmad (2004) çalışmalarında, k-ortalama tabanlı kümeleme algoritmasında ilk küme merkezlerini hesaplamak için bir algoritma önermişlerdir. Bu işlemi, çok benzer olan veri noktalarının kümelerin çekirdeğini oluşturduğu ve küme üyeliklerinin aynı kaldığı deneysel gerçekliğine dayandırmışlardır. CCIA olarak isimlendirdikleri küme merkezi başlatma algoritması ile istenen küme sayısından daha fazla kümeler oluşması sebebiyle, istenen sayıda küme elde edilmesi için yoğunluk tabanlı çok ölçekli veri yoğunlaştırma yöntemi ile fazla kümeleri birleştirmişlerdir. Ayrıca önerdikleri algoritmanın, ilk küme merkezlerinin rasgele seçilmesi yöntemine kıyasla daha gelişmiş ve tutarlı küme yapıları gösterdiği bildirmişlerdir.

He ve arkadaşları (2004) çalışmalarında, küme başlatma yöntemlerini inceleyen kısa bir literatür araştırması yapmışlardır. Ayrıca sentetik veri ve gerçek dünya verisi kullanılarak başlatma yöntemlerinin performanslarını deneysel bir çalışma ile değerlendirmişlerdir. Bu değerlendirmede R-MEN, R-SEL, Simple Cluster Seeking (SCS), KKZ ve KR küme başlatma yöntemlerini iterasyon sayısı, Sep indeksi ve Cmp indeksine göre karşılaştırmışlardır. Sentetik veri kümesi üzerinde, SCS ve KKZ mesafe optimizasyon yönteminin benzer oldukları, Sep puanı olarak rasgele yöntemlerden olan R-MEN'in ise R-SEL ve KR yöntemlerinden daha iyi olduğu tespit etmişlerdir. KR yönteminin ise diğer tüm başlatma yöntemlerine göre daha kötü olduğunu, tek avantajının küme sayısının küçük olduğu durumlarda daha hızlı yakınsama gerçekleştirdiğini bildirmişlerdir. Gerçek dünya verileri üzerinde ise Sep puanı olarak SCS ve KKZ yöntemlerinin R-MEN, R-SEL ve KR yöntemlerinden daha iyi olduğu, Cmp ve Sep puanına göre ise iris veri setinde R-MEAN yönteminin diğer dört yöntemden daha kötü olduğunu tespit etmişlerdir. Elde ettikleri bu sonuçlara göre, mesafe optimizasyonuna dayanan SCS ve KKZ yöntemlerinin k-ortalama algoritması

için daha iyi küme ayırımını yapmaya yardımcı olan yöntemler olduğunu vurgulamışlardır.

Al-Daoud (2007) çalışmasında, k-ortalama kümeleme algoritmasının küme başlangıçları için bir algoritma önermiştir. Önerdiği algoritma, boyutu maksimum değişkenlikle bulmak, sıralamak, bir grup veri noktası olacak şekilde bölmek ve sonrasında her bir gruba karşılık gelen veri noktalarını kullanarak medyanını bulmak şeklinde oluşturulmuştur. Önerilen yöntem, farklı boyutta ve farklı küme sayısında olan iki veri kümesine uygulanmış ve önerilen yöntemin rasgele başlatma yöntemlerine kıyasla daha iyi sonuçlar verdiği tespit edilmiştir.

Arthur ve Vassilvitskii (2007) çalışmalarında k-ortalama algoritmasının başlangıç küme merkezlerini belirlemek için optimal kümeye uyumlu kmeans++ olarak isimlendirdikleri bir algoritma önermişlerdir. Bu algortmada ilk küme merkezi yine rasgele olarak seçilmektedir. Sonraki küme merkezlerini belirlemek için olasılıksal bir yaklaşım önermişlerdir. D^2 ağırlıklandırması ile başlangıç değerlerinin belirlenmesinin hem çalışma süresi hem de k-ortalama doğruluğu açısından önemli ölçüde iyileştirme sağladığı bildirilmiştir.

Mignotte (2008) çalışmasında, daha güvenilir ve doğru bölütleme sonucu elde etmek için farklı birkaç bölütleme haritasını birleştirme işlemine dayanan basit k-ortalama tabanlı bir bölütleme yaklaşımı önermiştir. Önerilen algoritma Berkeley bölütleme veritabanında 300 renkli görüntü üzerinde test edilmiştir. Karşılaştırma işlemi, olasılıksal rand indeksi (probabilistic rand index-PRI), bilgi değişimi (variation of information-VoI), küresel tutarlılık ölçüsü (global consistency measure-GCE) ve sınır yer değiştirme hatası (the boundary displacement error-BDE) performans kriterleri ile yapılmıştır. Karşılaştırma işlemi sonucunda önerilen algoritmanın Berkeley doğal görüntü veritabanı üzerinde, güncel ileri bölütleme tekniklerine kıyasla daha iyi bir performans gösterdiği belirtilmiştir.

Sathya ve Manavalan (2011) çalışmalarında, k-ortalama, geliştirilmiş k-ortalama, fuzzy c-ortalama ve geliştirilmiş fuzzy c-ortalama algoritmalarını önermişlerdir. Bu

kümeleme tekniklerini farklı görüntüler üzerinde test etmişlerdir. Önerdikleri algoritmaların performanslarını RI, GCE, VOI ve BDE bölütleme parametreleri kullanılarak ölçmüşlerdir. Yaptıkları testler sonucunda k-ortalamlar algoritmasının daha kısa zamanda bölütleme yaptığını fakat bölütleme sonuçlarının kötü olduğunu ortaya koymuşlardır. Geliştirilmiş olan k-ortalamlar ve geliştirilmiş bulanık c-ortalamlar algoritmalarının daha az sayıda iterasyon ile daha iyi bir bölütleme elde ettiğini belirtmişlerdir.

Celebi ve arkadaşları (2013) çalışmalarında, k-ortalamlar algoritması için başlatma yöntemlerinin verimliliğini ve etkilerini incelemişlerdir. Bunun için büyük, birbirinden farklı kategoride ve farklı küme sayısına sahip 32 adet veri kümesi üzerinde sekiz farklı doğrusal zaman karmaşıklığı başlatma yöntemlerini kullanarak karşılaştırmışlardır. Bu başlatma yöntemleri: Forgy yöntemi, MacQuenn'in ikinci yöntemi, maximin, Bradley ve Fayyad yöntemi, k-means++, greedy k-means++, Var-Part ve PCA-Part yöntemleridir. Yapılan karşılaştırmada beş kalite ve iki hız kriteri kullanılarak başlatma yöntemlerinin performansı ölçülmüş ve istatistiksel analiz yöntemleri kullanılarak elde edilen deneysel sonuçlar analiz edilmiştir. Celebi ve arkadaşları Forgy, MacQueen ve maximin yöntemlerinin çoğu zaman düşük performans gösterdiğini ve bu yöntemlerin daha iyi alternatiflerinin olduğunu bildirmişlerdir.

Fränti ve Sieranoja (2019) çalışmalarında, daha iyi bir başlatma tekniği kullanarak ya da algoritmayı tekrar çalıştırarak k-ortalamlar algoritmasının performansını nasıl geliştireceğini ve k-ortalama algoritmasının performansını kötüleştiren en önemli faktörlerin neler olduğunu incelemişlerdir. Fränti ve Sieranoja, başlatma teknikleri Rand-P, Rand-C, Maxmin, kmeans++, Bradley, Sorting, Projection, Luxburg, Split teknikleri içerisinde Maxmin tekniğinin daha başarılı olduğunu ve bu teknikte ortalama başarı oranının %22, Random Centroid yönteminin ise ortalama başarı oranının %5 olduğunu bildirmişlerdir.

Literatürdeki çalışmaları da incelediğimizde küme başlatma parametrelerinin ve yöntemlerinin oluşacak nihai kümenin kalite ve performansına etki eden önemli bir

kriter olduğu görülmüştür. Kullanılan veri tipine göre küme başlatma yöntemi ve parametrelerinin uyarlanması daha etkili sonuçlar vereceği tespit edilmiştir. Bu sebeple, tez çalışmasının kümeleme tabanlı bölütleme aşamasında, kümeleme işlemindeki ilk küme merkez değerlerinin belirlenmesi amacıyla yeni bir yaklaşım önerilmiştir. Önerilen bu yaklaşımda bölütleme işlemi, piksel değerlerine ve histogram bilgisine göre mesafe ölçümüne dayanan k-ortalamlar kümeleme algoritması ile yapıldığında, ilk küme merkezlerinin birbirinden eşit düzeyde ayrık olmasını sağlayacak bir küme başlatma yöntemi önerilmiştir. Önerilen yaklaşım, küme sayısına göre eşit şekilde artırılmış değerlerin ilk küme merkez değerlerine atanması ile gerçekleştirilmiştir. Bu yaklaşım ile 51'i iyi huylu, 49'u kötü huylu olmak üzere toplam 100 adet histopatolojik kolon tümör görüntüsü bölütlenmiştir. Aynı görüntüler literatürde genel kullanım olarak uygulanan ilk küme merkez değerlerinin rasgele olarak atanması yöntemiyle de bölütlenmiştir ve sonuçlar karşılaştırılmıştır. Aynı şartlar altında tüm işlemler üç kere tekrar edilmiştir. Bu karşılaştırma sonucunda, geliştirilmiş yeni k-ortalamlar kümeleme algoritmasının bölütleme başarımı ve performansının ağırlıklı k-ortalamlar kümeleme algoritmasına kıyasla daha iyi olduğu tespit edilmiş ve geliştirilmiş yeni k-ortalamlar kümeleme algoritmasının daha sitabil bir sonuç verdiği ortaya konulmuştur. Buna ilave olarak, bölütleme sonucunda elde edilen görüntülerin orijinal görüntülere olan benzerliği, histogram tabanlı benzerlik algoritması kullanılarak hesaplanmış ve önerilen küme başlatma yöntemi ile algoritma başarımının daha iyi olduğu görülmüştür.

1.1.2. Derin öğrenme yöntemleri ile kolon tümör görüntülerinin sınıflandırılması

Bu literatür araştırması, tez çalışmasındaki ikinci kısım olan kolon tümör görüntülerinde derin öğrenme tabanlı sınıflandırma çalışmaları üzerinedir. Akciğer, prostat ve göğüs kanserleri üzerinde yapılan araştırmalar ile kolorektal kanser üzerine yapılan araştırmalar kıyaslandığında, özellikle bölütleme ve sınıflandırma açısından literatüre az sayıda çalışma bulunmaktadır. Hücresel heterojenliğin yanı sıra bez (gland) içi değişkenliği gibi konular kolon tümör bölütlemesi ve sınıflandırmasını zorlu bir problem haline getirmiştir (Naqvi ve ark., 2019). Son yıllarda kullanımı ivme

kazanan derin öğrenme algoritmaları ile birlikte kanser görüntüleri üzerinde yapılan çalışmaların sayısı da artmaya başlamıştır. Özellikle evrişimli sinir ağları ile kolon tümör görüntülerinin sınıflandırılması ve bölütlenmesi üzerine yeni çalışmalar bulunmaktadır.

Xu ve arkadaşları (2016) çalışmalarında, histolojik görüntülerde bulunan epitelyal ve stromal doku tiplerinin bölgelerini, sayısallaştırılmış tümör dokusu mikrodizinlerinden otomatik olarak ayırmak veya sınıflandırmak için derin evrişimli sinir ağları (DCNN) temelli özellik öğrenmesi sunmuşlardır. Yaptıkları çalışmada, 106'sı NKI veri seti ve 51'i VGH veri seti olmak üzere 157 adet H&E tekniği ile boyanmış meme kanser görüntüleri ve 1376 adet kolorektal kanserin immünohistokimyasal (IHC) lekeli görüntülerden oluşan veri setleri kullanılmıştır. Önerdikleri DCNN tabanlı özellik öğrenme yaklaşımı ile NKI, VGH meme kanser veri seti ve IHC kolorektal kanser veri setinde sırasıyla, F1 sınıflandırma puanı olarak: %85, %89, %100, model doğruluğu olarak: %84, %88, %100, Matthews korelasyon katsayısı olarak: %86, %77, %100 değerlerini elde etmişlerdir.

Bychkov ve arkadaşları (2016) çalışmalarında, tümör dokusu mikroarray örneklerinin görüntülerine dayanan kolorektal kanserli hastalarda hastalık tespitinin evrişimli sinir ağları ile modellenmesini incelemişlerdir. 180 hastadan elde edilmiş kolorektal kanserli, sayısallaştırılmış ve H&E boyalı doku mikroarray örneklerinden oluşan görüntüler kullanılmıştır. 60 hastadan elde edilen görüntülerden oluşturulan test kümesi, sadece epitelyal doku görüntülerinden oluşan ESA modeli ile 0,66 AUC alanı ve 2,08'lik bir risk oranı elde edilmiş, epitelyal olmayan doku olarak ayrılmış görüntülerden oluşan ESA modeli ile ise 0,57 AUC değeri ve 1,67 bir risk oranı elde edilmiştir. Epitelyal olan görüntülerde epitelyal olmayan alanlar beyaz renk olarak atanmış, epitelyal olmayan görüntülerde ise epitel alanlar beyaz renk olarak atanmıştır. Sonuç olarak tümörün epitelyal olan kısımlarının kullanılması ile sınıflandırma doğruluğunun yüksek olduğunu bildirmişlerdir. Bychkov ve arkadaşlarının yapmış oldukları çalışma az sayıda görüntü üzerinde gerçekleştirilmiştir. Bilindiği üzere derin öğrenme daha büyük veri kümeleri için daha anlamlı olduğundan bu çalışmanın büyük veri kümesi üzerinde gerçekleştirilmesi daha anlamlı sonuçlar üretecektir.

Sirinukunwattana ve arkadaşları (2016) çalışmalarında, hücre çekirdeğinin tespiti için uzaysal kısıtlı Convolutional Neural Network (CNN) (SC-CNN) önermişlerdir. Çekirdeklerin sınıflandırılması için ise tespit edilen hücre çekirdeğinin sınıf etiketini daha doğru ve hassas bir şekilde tahmin etmek için softmax CNN ile birleştirilmiş yeni bir Komşu Topluluk Belirleyicisi (Neighboring Ensemble Predictor-NEP) önermişlerdir. Yaptıkları çalışmada, dört farklı sınıfa ait 20.000'den fazla kolorektal adenokarsinom görüntülerinden oluşan veri seti kullanılmıştır. Önerilen SC-CNN yaklaşımının diğer yaklaşımlarla kıyaslamasını F1 puanı üzerinden değerlendirmişlerdir. SC-CNN ve SR-CNN çekirdek tespiti, softmax CNN ile birlikte NEP ve SSPP sınıflandırma için bir kombinasyon olarak önerilmiştir. Sınıflandırma için Softmax CNN+SSPP, softmax CNN+NEP, superpixel, CRImage karşılaştırılmıştır. Ayrıca, SC-CNN & SSPP, SR-CNN & SSPP, SC-CNN & NEP ve SR-CNN & NEP karşılaştırılmıştır. Karşılaştırmalar F1 puanı üzerinden yapılmıştır ve softmax CNN+NEP'in F1 puanı ve AUC alan değerinin daha yüksek olduğu bildirilmiştir.

BenTaieb ve arkadaşları (2016) çalışmalarında, iki farklı kayıp fonksiyonu (loss functions) ile tek bir birleştirilmiş derin evrişimli sinir ağlarını optimize eden yeni çok-amaçlı (multi-objective) öğrenme yöntemi önermişlerdir. Veri seti olarak H&E boyanmış 37 iyi huylu ve 48 kötü huylu kolon tümör görüntüsü içeren Warwick-QU veri seti kullanmışlardır. AlexNet, Multi-Loss-Class, UNet, Multi-Loss-Seg ve Multi-Loss-Joint modellerini karşılaştırmışlardır. Muti-Loss-Joint sınıflandırma ve bölütleme modelinin diğer sınıflandırma modellerine göre sınıflandırma doğruluğu olarak %6, bölütleme olarak %6 ile %20 arasında bir artış sağladığı bildirilmiştir.

Kainz ve arkadaşları (2017) çalışmalarında, GlaS MICCAI2015 kolon bez bölütleme yarışmasına katılmak amacıyla, kötü huylu ve iyi huylu kolorektal tümör dokusunda bezlerin (glands) bölütlenmesi ve sınıflandırılması için derin sinir ağı temelli bir yaklaşım önermişlerdir. H&E boyalı görüntülerin piksel tabanlı sınıflandırılması için iki farklı derin ESA kullanmışlardır. İlk sınıflandırıcı bezleri arka plandan ayırmak için ikinci sınıflandırıcıyı ise bez ayırıcı yapıları tanımlamak için kullanmışlardır. Nihai bölütleme için ise ağırlıklı toplam varyasyona dayalı şekil-zemin bölütlemesi ile

ESA tahminleri düzenlenmiştir. Sistemin iyi huylu ve kötü huylu tümör sınıflandırma performansları ise sırasıyla %98 ve %95 olarak hesaplanmıştır.

Wang ve arkadaşları (2017) çalışmalarında, fine-grained sınıflandırma için yeni bir ESA modeli olan Bilineer CNN (BCNN) ile histopatolojik görüntülerin sınıflandırılmasını gerçekleştirmişlerdir. Histopatolojik görüntülerde, H&E boyama bileşenlerine ayrılmış ve sonrasında performansı temsil eden özellikleri geliştirmek için ayrılmış bileşenlere BCNN uygulamışlardır. BCNN algoritmasını sekiz sınıflı kolorektal kanser görüntüleri üzerinde uygulamışlardır. CNN, CNN-H, CNN-E ve BCNN algoritmalarını bu görüntüler üzerinde karşılaştırmışlardır. Karşılaştırma parametresi olarak AUC değerini kullanmışlardır. Sonuç olarak sekiz sınıfın ortalaması alınarak CNN için 0,981 ortalama AUC değeri, CNN-H için 0,960 ortalama AUC değeri, CNN-E için 0,973 ortalama AUC değeri ve BCNN için 0,985 ortalama AUC değeri elde etmişlerdir.

Awan ve arkadaşları (2018) çalışmalarında, önerilen sınıflandırma yaklaşımının ve multispektral görüntülemenin histopatoloji analiz için uygunluğunu ve yeterli olup olmadığını araştırmışlardır. Tıbbi spektral görüntüleme (prostat ve kolorektal) için ESA özelliklerinin analizi yapılmıştır. Spektral görüntüleme tekniğinin, RGB görüntülerinden daha fazla ayırt edici bilgi sağladığı ve çeşitli problemler için önerildiği bildirilmiştir. Kolorektal görüntülerdeki anomaliyi belirlemek için, spektral bilginin etkinliğini belirlemek amacıyla özel bir grup ve grubun farklı alt setlerini kullanarak analiz yapmışlardır. Ayrıca zayıf ve güçlü çapraz doğrulamanın sınıflandırma performansına etkisini grup temelli sınıflandırma üzerinde incelemişlerdir. Güçlü çapraz doğrulamada, pozitif sınıf kabul edilen CA ile %90,1 doğruluk, CA ile birlikte kanser gelişme riski yüksek bir anomali olan TA_LG ile %89,9 doğruluk elde etmişlerdir. Zayıf çapraz doğrulamada CA ile %96,1 doğruluk, CA + TA_LG ile %95,8 doğruluk elde edilmiştir. Buna ilave olarak, verilere kızıl ötesi gösterimin dahil edilmesi durumunda, sınıflandırma doğruluğunu %6 oranında artırarak kızıl ötesi ve görsel spektrum arasında bir sinerji olduğunu göstermişlerdir.

Basha ve arkadaşları (2018) çalışmalarında, RCCNet olarak adlandırdıkları kolon kanser çekirdeklerinin sınıflandırılması için evrişimli sinir ağı temelli bir mimari önermişlerdir. Önerdikleri mimari, kolon kanseri histolojik veri seti olan CRCHistoPhenotypes veri seti üzerinde kullanılmıştır. Önerilen model sonuçları beş ESA modeli ile karşılaştırılmıştır. Karşılaştırma parametreleri olarak doğruluk, ağırlıklı ortalama F1 puanı ve eğitim süresi kullanılmıştır. Önerilen RCCNet modeli ile %80,61 doğruluk ve 0,7887 ağırlıklı ortalama F1 puanı elde edilmiştir. RCCNet modelinin eğitim süresi ve aşırı öğrenme yönünden daha performanslı olduğunu bildirmişlerdir. RCCNet modeli diğer modellerle eğitim ve test doğruluğu açısından kıyaslanmıştır. Bu kıyaslama sonucunda, GoogLeNet, AlexNet ve VRN modelleri ile daha yüksek eğitim doğruluk değeri (train validation), RCCNet modeli ile ise en yüksek test doğruluk değeri (test validation) elde edilmiştir.

Morkūnas ve arkadaşları (2018) çalışmalarında, dijital patolojik görüntülerde makine öğrenme algoritmalarını eğitmek için süperpikselleri kullanarak tümör dokularının epitel-stroma sınıflandırmasını gerçeklemek için birkaç olasılık tanımlamışlardır. Önerdikleri yaklaşımda denetlemeli öğrenme için özellik uzayını, renk ve doku parametrelerini çıkararak ve boyutsallık azaltma yöntemlerini uygulayarak süper pikseller atanmış doku sınıfından oluşturmuşlardır. Önerilen yöntem, kolorektal kanser görüntülerinden oluşan özel bir veri seti üzerinde uygulanmıştır. Genelleme koşulları altında, gri ölçekli süper pikseller test edilen herhangi bir yöntemle etkin bir şekilde sınıflandırılmadığını ve AUC değerinin 0,9'dan küçük olduğunu tespit etmişlerdir. Tek örnek veri setlerinde renk ve doku özellikleri ile elde edilen maksimum AUC değerleri sırasıyla 0,8668 ve 0,9443 olarak hesaplanmıştır. "Genel" veri setinde en iyi performans MLP ve doku özellikleriyle AUC değeri 0,8885 olarak hesaplanmıştır. Elde ettikleri AUC değeri diğer deneysel yaklaşımların en iyi sonuçları ile karşılaştırıldığında düşük bir AUC değeri olduğu bildirilmiştir. Süper piksel doğrusallaştırma yaklaşımıyla ise kullanılan çoğu makine öğrenme yönteminde 0,95'ten yüksek AUC değeri bulunmuştur.

Tiwari (2018) çalışmasında, ESA kullanılarak yedi farklı doku tipi içeren insan dokusuna ait kolorektal kanser görüntülerinin sınıflandırılması için bir yöntem

önermiştir. Önerilen yöntem, Gauss gürültüsünün olması ve olmaması durumuna göre dört farklı renk modeli (RGB, HSV, YUV, LAB) kullanılarak değerlendirilmiştir. HSV renk modeliyle Gauss gürültüsünün olmaması durumunda %95,8 ve Gauss gürültüsünün olması durumunda ise %78,5 en yüksek sınıflandırma doğruluk değerleri elde edilmiştir.

Song ve arkadaşları (2018) çalışmalarında, evrişimli sinir ağlarında parametre ve hesaplama işlemlerini azaltmak için doğruluk kaybı olmadan evrişimli katmanlar için kanal seviyesinde azaltma stratejisi önermişlerdir. Kolorektal kanser veri setinde, kanal sayısını ve evrişim katmanı parametrelerini herhangi bir hassasiyet kaybı olmadan 5x ve 21x faktörü ile azaltmışlardır. ESA modeli olarak AlexNet modeli kullanılmıştır. AlexNet modelinde parametreleri azaltarak kullanıldığında da aynı doğruluk oranını elde etmişlerdir. AlexNet modeli ile %91, parametreleri azaltılmış AlexNet modeli ile de %91 doğruluk elde edilmiştir.

Naqvi ve arkadaşları (2019) çalışmalarında, H&E boyalı kolorektal kanser görüntülerinin sınıflandırılması ve bölütlenmesini otomatikleştiren bir algoritma önermişlerdir. Önerilen yaklaşım, yoğunluğa dayalı bilgileri, tümör malignitesini değerlendirmek için ESA ile birlikte morfolojik işlemleri içermektedir. Sınıflandırma amacıyla, AlexNet modelini eğitmek için öğrenme aktarması (transfer learning) yöntemi kullanılmıştır. Veri seti olarak MCCAİ GlaS yarışmasından alınan herbiri 5 ve 20 sayıda bez (gland) içeren, 80 iyi huylu tümör görüntüsü ve 85 kötü huylu tümör görüntüsünden oluşan 165 kolorektal tümör görüntüsü kullanılmıştır. Dolayısıyla görüntülerden 10.000 sayıda bez görüntüsü oluşturulmuş, bez görüntü boyutları 227x227x3 şeklinde yeniden boyutlandırılmış ve bu görüntüler üzerinde ESA modeli eğitilmiştir. Naqvi ve arkadaşları tümör dokusu sınıflandırma başarımını %90,4 olarak bulmuşlardır. Ayrıca duyarlılık değerini %89 ve özgüllük değerini ise %91 olarak hesaplamışlardır.

Yoon ve arkadaşları (2019) çalışmalarında, sınıflandırma ve yerelleştirme görevlerinde 2014 ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını kazanan Visual Geometry Group (VGG) modeli beş farklı versiyonunu geliştirmişlerdir. 28'i

normal ve 29'u tümör olan kolorektal histoloji görüntülerinin kırılması ile 6806 normal ve 3474 tümör görüntüsü olacak şekilde görüntü veri seti oluşturulmuştur. Yaptıkları model eğitimleri sonunda, geliştirilmiş beş VGG modeli içinden en iyi geliştirilmiş VGG modelini tespit etmişlerdir. Geliştirilmiş beş VGG modelinin doğruluk oranlarını yaklaşık olarak sırasıyla %82, %87, %87, %91 ve %94 olarak tespit etmişlerdir. Sonraki aşamada geliştirilmiş en iyi VGG modeli tüm veri seti üzerinde kullanılarak performans değerleri yeniden incelenmiş ve %93,48 model doğruluğu, 0,4385 kayıp (loss) değeri, %95,10 duyarlılık oranı ve %92,76 özgüllük oranı bulunmuştur. Ayrıca Yoon ve arkadaşları, 719 tümör görüntüsünden 667'sinin, 309 normal görüntüden ise 294'ünün doğru olarak sınıflandırıldığını tespit etmişlerdir.

Kather ve arkadaşları (2019) çalışmalarında, 86 kolorektal doku görüntüsünden 100.000 H&E boyanmış görüntü oluşturulmuş ve ESA modeli bu görüntüler ile eğitilmiştir. Ayrıca ESA modeli, 25 kolorektal doku görüntüsünden elde edilmiş birbirinden bağımsız 7.180 görüntüden oluşan görüntü kümesi ile test edilmiş ve bu test sonucunda %94'ten büyük bir doğruluk elde etmişlerdir. Ayrıca 2003-2007 yılları arasında Almanya'da çok sayıda kurumda işe alınan kişilerden DACHS taraması ile elde edilmiş, 409 kolorektal hasta üzerinde doğrulaması yapılmıştır.

Graham ve arkadaşları (2019) çalışmalarında, orijinal görüntüyü ağ içinde birden fazla noktaya yeniden dahil ederek, maksimum havuzlamanın neden olduğu bilgi kaybını önleyen ESA önermişlerdir. Önerilen ESA, GlaS yarışmasındaki veri setinde ve bağımsız olan ikinci bir kolorektal adenokarsinom veri setinde test edilmiştir. Ayrıca önerdikleri yöntemin genelleştirilebilirliğini göstermek için iki ek veri setinden tam slayt görüntüleri üzerinde bez(gland) bölütleme işlemi gerçekleştirilmiştir. GlaS yarışmasındaki veriler üzerinde MILD-Net ve diğer modellerin karşılaştırmasını yapmışlardır. F1 skoru olarak en yüksek skor 0,914 ile MILD-Net modelinden elde edilmiştir. Yine aynı şekilde CRAG veri seti üzerinde yapılan model performans karşılaştırmasında, en yüksek model performansını 0,825 ile MILD-Net modeli elde etmiştir.

Raza ve arkadaşları (2019) çalışmalarında, mikroskopik görüntülerde nesnelere bölütlenmesi için derin öğrenme mimarisine dayanan ESA modeli önermişlerdir. Önerilen ağ modeli, giriş parametrelerinin ayarlanması ile floresan mikroskobu ile elde edilmiş histoloji görüntülerinde hücre, çekirdek ve bezi bölütlemek için kullanılmıştır. Kullanılan veri seti, farklı kaynaklardan alınmış görüntülerden oluşmaktadır. Verilerin büyük bir kısmı açık yarışmalarda kullanılan H&E boyanmış mikroskopik RGB görüntülerden oluşmaktadır. Veri setlerinden birini dört farklı tümör tipi görüntülerindeki çekirdeklerin bölütlenmesi için, diğerini kolon kanser görüntülerinde bez bölütleme için kullanmışlardır. Önerilen ağ ile FCN8, FCN8W, DCAN, U-Net, Mikro-Net ağları Dice, F1, OD, PAcc, OH performans kriterleri açısından karşılaştırılmıştır. Bu karşılaştırma sonucunda önerilen ağın diğer derin öğrenme algoritmalarından daha yüksek performans gösterildiği bildirilmiştir.

Literatürde derin öğrenme algoritmaları ile görüntüler üzerinde yapılan sınıflandırmalarda, görüntüler genellikle orijinal halleriyle kullanılmaktadır. Mikroskopik veya histopatolojik görüntülerin kullanıldığı derin öğrenme algoritmalarında ise genellikle RGB görüntüler kullanılmaktadır. Literatürü incelediğimizde görüntülerin farklı renk uzaylarına dönüştürülmüş hallerinin derin öğrenme modellerinde kullanıldığı çalışmalar ile bu görüntülerin kullanılmasının geleneksel yöntemlere göre model performansına etkileri hakkında çalışmaların az sayıda olduğu görülmüştür. Bu konudaki çalışmalar aşağıda verilmiştir.

Cheng ve Guo (2017) çalışmalarında, geleneksel manuel çalışmanın verimliliğini ve doğruluğunu artırmak için, ince kesit görüntüsünden granülite analizi için ESA tabanlı bir yöntem önermişlerdir. ESA modelini Ordos havzasından aldıkları 4800 kaya görüntü üzerinde RGB, HSV ve YCbCr renk uzaylarında test etmişlerdir. Yapılan test sonucunda RGB renk uzayında %98,5 yüksek doğruluk oranına ulaşıldığı bildirilmiştir.

Sachin ve arkadaşları (2017) çalışmalarında, belirli sahne kategorilerini sınıflandırmak için önceden eğitilmiş bir ağın kullanımını önermişlerdir. Önceden eğitilmiş ağ, sahneleri 8 farklı sahne kategorisinde sınıflandırmak için basit sınıflandırıcılarla

birleştirmişlerdir. Ayrıca önerilen ESA bazlı sahne sınıflandırma sisteminin performansı RGB, YCbCr, CIEL*a*b* ve HSV gibi farklı renk uzaylarındaki görüntü ile test edilmiş ve renk uzaylarının etkisinin sınıflandırma doğruluğuna göre analizini yapmışlardır. Veri seti olarak sekiz sınıftan oluşan Oliva Torralba (OT) sahne veri seti kullanılmıştır. A Random Forest (RF) sınıflandırıcı ve Extremely Randomized Tree sınıflandırıcılarının farklı renk uzaylarında test edilmesi sonucunda, RGB uzayından farklı renk uzayının kullanılması durumunda sistemin doğruluk performansını etkilediği fakat bu olumlu etkinin RGB renk uzayına göre %1 civarında olduğu bildirilmiştir.

Diaz-Cely ve arkadaşları (2019) çalışmalarında, Inception-V3, ResNet ve MobileNet evrişimli modellerinde öğrenme aktarımı (transfer learning) tekniği kullanıldığında, modelin girdi görüntülerinin renk gösteriminin etkisini test etmişlerdir. Görüntü olarak, kedi ve köpek fotoğraflarından oluşan ve iki sınıf arasında eşit şekilde dağıtılmış farklı boyutlarda 25.000 görüntü içeren veri seti kullanılmıştır. Bu veri seti Kaggle yarışmasında kullanılan popüler bir veri kümesidir. Diaz-Cely ve arkadaşları yaptıkları testler sonucunda, CIE-L*a*b* renk uzayındaki renk gösteriminin, eğitim sırasında orijinal olarak kullanılan RGB renk gösterimine kıyasla daha iyi sonuçlar verdiğini bildirmişlerdir. MobileNet modelinde tüm renk uzaylarında yaklaşık %77 gibi aynı doğruluk oranı bulunmuştur. Renk uzayının MobileNet modeli için performans değeri olarak etkisinin olmadığı bildirilmiştir. ResNet mimarisinde ise RGB renk uzayında %97, Lab uzayında ise %91 doğruluk oranı elde edilmiştir. Inception-V3 modelinde ise RGB renk uzayında %68, Lab uzayında ise %75 doğruluk oranı bulunmuştur. MobileNet ve ResNet modellerinde farklı renk uzayının doğruluk üzerine olumlu bir etkisi görülmemiş, Inception-V3 modelinde ise Lab uzayı temsil eden görüntü kullanıldığında %7 lik bir iyileşme olduğunu bildirmişlerdir.

Khojasteh ve arkadaşları (2019) çalışmalarında, eksüdaların (exudates) otomatik tespiti için farklı fundus görüntü renk uzaylarının performansını karşılaştırmıştır. RGB renk uzayındaki orijinal renklerin ortogonal transformasyonu ile üretilen farklı renk uzaylarının performansını değerlendirmek için bir ESA kullanılmıştır. RGB, HSI ve LUV renk uzayında üç kanallı görüntülere temel bileşen analizi (PCA) ile özkanal

oluşturulmuştur ve çalışmalarında DIARETDB1 ve e-Ophtha veri seti kullanılmıştır. Üç kanallı fundus görüntülerinin yeni bir renk uzayını önermişlerdir. Sonuç olarak %98,2 doğruluk, 0,99 hassasiyet ve 0,98 özgüllük değerlerini elde etmişlerdir. Eksüdaların tespiti için yapılan performans analizinde RGB renk uzayında %90,07 doğruluk, HSI renk uzayında %97,62 doğruluk, LUV renk uzayında %89,21 doğruluk, PCA-RGB renk uzayında %96,16 doğruluk, PCA-HSI renk uzayında %95,48 doğruluk ve PCA-LUV renk uzayında ise %87,75 doğruluk elde edilmiştir. Verilerde 20-kat çapraz doğrulama tekniği kullanılarak, önerilen renk alanının geleneksel renk alanlarıyla karşılaştırıldığında daha yüksek tekrarlanabilirlik elde edildiğini doğrulamışlardır.

Yukarıda verilen literatürdeki çalışmalarda da görüldüğü üzere görüntülerin farklı renk uzaylarında kullanılmasının derin öğrenme model performansına olumlu etkilerinin olduğu fakat kullanılan model'e göre etkisinin farklılaştığı görülmüştür. Bizim önerdiğimiz yöntemde ise renk uzayını değiştirmeden yine aynı RGB renk uzayında görüntünün nesnelere farklı renkler atayarak bölütlenmesi ve renk karmaşıklığının azaltılması sonucunda elde edilen görüntülerin kullanılması ile model performansını arttırmak hedeflenmiştir. Yapılan testler sonucunda da farklı ESA modellerinde performans iyileşmeleri olduğu görülmüştür. Ayrıca model performansını düşüren, sistemin aşırı öğrenmesine sebep olan sorunlu veri setinde bile önerdiğimiz yöntemin kullanılması durumunda sistem performansında yüksek seviyede iyileşme sağladığı ve sistemi normalleştirdiği görülmüştür.

1.2. Tezin Katkısı

Tez çalışmasında önerilen yöntemler ve bu çalışmanın katkıları özetle şunlardır:

1. Mikroskopik kolon görüntüleri üzerinden iyi huylu ve kötü huylu tümörlerin bölütlenmesi, tespiti ve sınıflandırılması için kullanılan yöntemlerin detayları incelenmiş ve sistematik olarak sunumu gerçekleştirilmiştir.
2. Mikroskopik kolon tümör görüntülerinde bölütleme için geliştirilmiş yeni k-ortalamalar kümeleme algoritması önerilmiş, önerilen yaklaşım ile küme

sayısına göre eşit şekilde arttırılmış değerlerin ilk küme merkezlerine atanması gerçekleşmiştir. Önerilen algoritma ile ağırlıklı k-ortalamlar kümeleme algoritmasının karşılaştırılması yapılmış ve performans sonuçları ortaya konulmuştur.

3. Önerilen geliştirilmiş yeni k-ortalamlar kümeleme algoritmasında ilklendirme parametrelerinin ayarlanmasının bölütleme performansını olumlu etkilediği, k-ortalamlar algoritmasındaki iterasyon sayısının azaldığı, dolayısıyla bölütleme süresinin de azaldığı tespit edilmiştir. Kanser görüntüleri için her işlem tekrarında aynı sonucu veren kararlı bir sistem ortaya konulmuştur.
4. Mikroskopik kolon görüntüleri üzerinden sınıflandırma için son yıllarda popüler ileri tekniklerden biri olan derin öğrenme kullanılmış ve detaylı bir şekilde model performans karşılaştırmaları gerçekleştirilmiştir.
5. Sınıflandırma için kullanılan görüntülerin renk uzayını değiştirmeden yine aynı RGB renk uzayında, görüntü nesnelere farklı renkler atayarak bölütlenmesi gerçekleştirilmiş, renk karmaşıklığının azaltılması sonucunda elde edilen bölütlenmiş görüntülerin derin öğrenme modellerinde kullanılmasının performans başarımına etkisi detaylı bir şekilde incelenmiş ve deney sonuçları ortaya konulmuştur.
6. Önerilen yaklaşım ile ESA modellerinde performans iyileşmeleri olduğu görülmüştür. Ayrıca model performansını düşüren, sistemin aşırı ezberlemesine (over-fitting) sebep olan sorunlu “bir_ozel” ve “par_ozel” isimli veri setlerinde önerdiğimiz yöntemin kullanılması durumunda, AlexNet model performansında sırasıyla %23'lük ve %22'lik bir artış, GoogLeNet model performansında ise sırasıyla %27'lik ve %22'lik bir artışın sağladığı tespit edilmiştir.

1.3. Tez Organizasyonu

Bu tez çalışması beş bölümden oluşmaktadır. Birinci bölümünde kanser, kolon kanseri, görüntü bölütleme ve derin öğrenme konularında genel bir bakış açısı oluşturacak bilgiler verilmiştir. Ayrıca benzer çalışmalar incelenerek literatür özeti

çıkarılmış ve bu çalışmanın amacı, kapsamı da belirtilerek konu hakkında kısa bir gözden geçirme yapılmıştır. Diğer bölümlerin organizasyonu ise aşağıda sunulmuştur.

Bölüm 2: Bu bölümde görüntü bölütleme temelleri, mevcut görüntü bölütleme tekniklerinin genel işleyişi özetlenmiştir. Ağırlıklı k-ortalamlar kümeleme algoritması ve önerdiğimiz geliştirilmiş yeni k-ortalamlar kümeleme algoritması yaklaşımı açıklanmıştır.

Bölüm 3: Bu bölümde derin öğrenme temelleri ve genel işleyişi özetlenmiştir. Derin öğrenme tabanlı algoritmalarından evrişimli sinir ağları ve katmanları açıklanmış, AlexNet ve GoogLeNet modelleri detaylandırılmıştır.

Bölüm 4: Bu bölümde tez çalışmasında gerçekleştirilmiş olan iki uygulama detaylandırılmıştır. Bölüm 4.1.'de kullanılan mikroskobik kolon tümörü hücre görüntüleri hakkında detaylı bilgi verilmiş, yapılan ön işlemler detaylandırılmış, geliştirilen uygulama üzerinden istatistiksel analiz sonuçları ve performans analizi tablo ve şekiller ile açıklanmıştır. Görüntüler üzerinden, bölütleme için önerilen geliştirilen yeni k-ortalamlar kümeleme algoritması ile ağırlıklı k-ortalamlar kümeleme algoritmasının karşılaştırmalı sonuçları verilmiştir. Bölüm 4.2.'de ise derin öğrenme için kullanılacak görüntülerin veri artırımı işlemleri detaylandırılmıştır. Orijinal ve bölütlenmiş görüntüler ayrı ayrı kullanılarak eğitilmiş olan AlexNet ve GoogLeNet modellerinin test veri seti ile test edilmesi sonucunda elde edilen model performans sonuçları karşılaştırmalı analizler ile açıklanmıştır.

Bölüm 5: Bu bölümde tez çalışmasında elde edilen sonuçlar değerlendirilmiş ve öneriler sunulmuştur.

BÖLÜM 2. GÖRÜNTÜ BÖLÜTLEME

Görüntünün bölütlenmesi, özellikle medikal uygulamalarda görüntülerdeki anormalliklerin tespiti, bilgisayar görmesi (computer vision) ve yapay sinir ağlarında kullanılan çok kullanışlı yöntemlerden biridir (Khan ve Ravi, 2013). Görüntü bölütleme terim olarak; bir görüntünün, o görüntünün parçalarını içeren bir dizi alt bölüme ayrılması şeklinde ifade edilir. Tanım olarak ise, bir görüntüyü oluşturan bölge ve nesnelere farklı özellikler içeren anlamlı alt bölümlere veya kategorilere ayırma işlemi (Khan, 2014) şeklinde tanımlanır. Bu ayırma işlemi, piksel yoğunluk değerleri, spektral değerler ve doku gibi özellikler kullanılarak gerçekleştirilmektedir.

Görüntü bölütleme kavramı matematiksel olarak ifade edilecek olunursa; R bütün uzamsal bölgeyi gösteren bir görüntü olsun. Görüntü bölütleme, R 'yi $R_1, R_2, R_3, \dots, R_n$ şeklinde n sayıda alt bölgeye ayırmak işlemidir (Gonzalez ve Woods, 2008; Gonzalez ve Woods, 2014).

Bu işlemler 5 maddede tanımlanmaktadır.

1. $\bigcup_{i=1}^n R_i = R$.
2. $i = 1, 2, 3, \dots, n$ için R_i bağlı kümedir.
3. $R_i \cap R_j = \emptyset$, tüm i ve j değerleri için $i \neq j$ dir.
4. $i = 1, 2, 3, \dots, n$ için $Q(R_i) = DOĞRU$.
5. Birbirine komşu olan herhangi R_i ve R_j bölgeleri için $Q(R_i \cup R_j) = YANLIŞ$.

Burada, \emptyset , \cap , \cup sembolleri sırasıyla boş küme, kesişim ve birleşimi ifade etmektedirler. Herhangi bir R_i ve R_j bölgelerinin komşu olduğunu belirtmek için bu iki bölgenin birleşimlerinin bağlı bir küme oluşturması gerekmektedir. Bu maddelere göre (x, y) koordinatında olan bir p pikselinin yatay ve dikey olarak 4 komşusu $N_4(p)$,

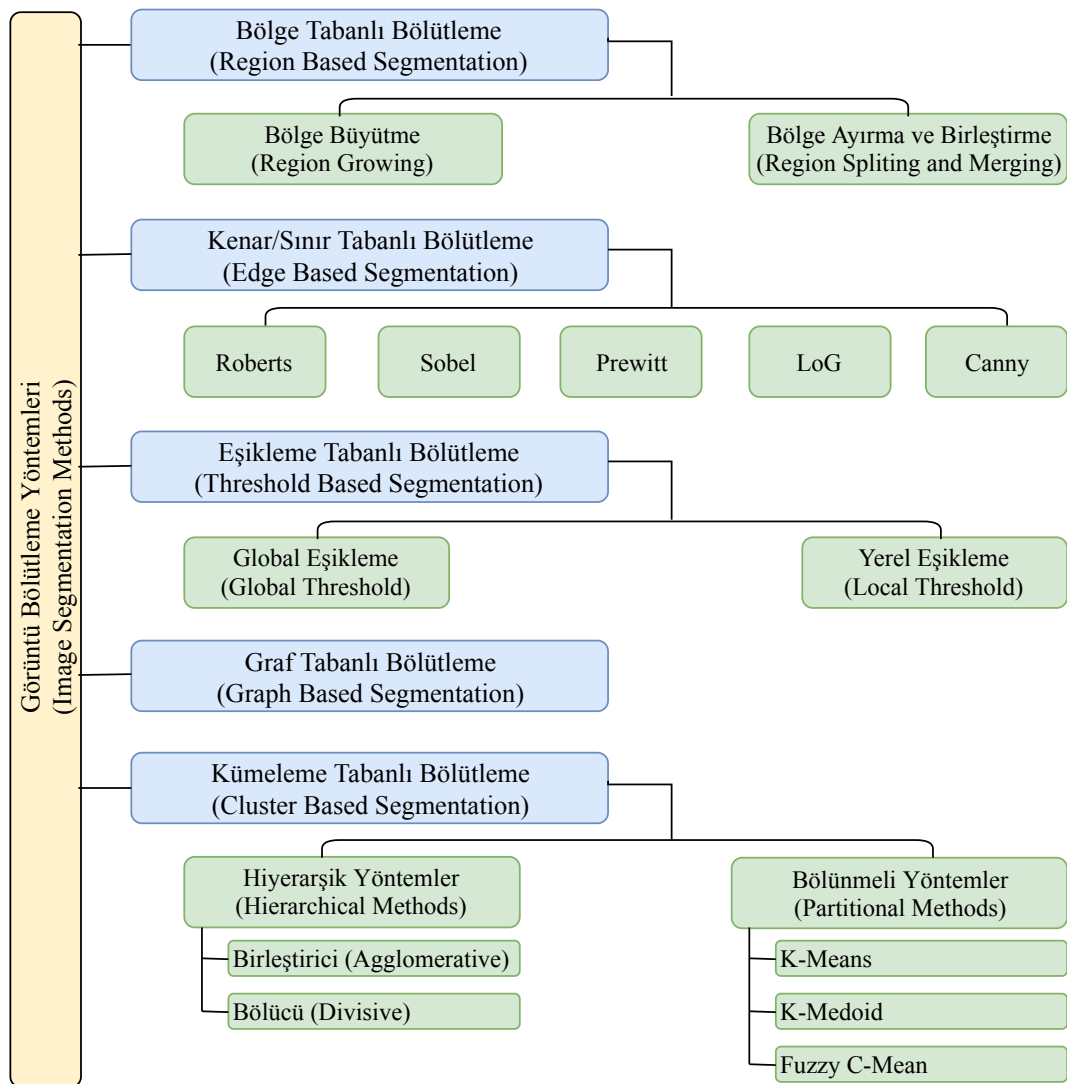
diyagonal olarak komşuları da dahil olmak üzere 8 komşusu $N_8(p)$ şeklinde R_i bölgesinin içindeki noktaların birbirine bağlı olmasını gerektirmektedir. R_i ve R_j gibi farklı bölgelerin birbirinden ayrı bir şekilde olmalarını yani kesişimlerinin olmamasını gerektirmektedir (Gonzalez ve Woods, 2008; Gonzalez ve Woods, 2014). Görüntü bölütlemeye bu belirtilen maddelerdeki koşulların sağlanması durumunda bölüntüleme işlemi doğru ve geçerli olacaktır.

Görüntü bölütlemenin temelde iki amacı vardır. Birinci amacı, bölütleme işlemi ile sadece analiz edilmesi gereken görüntü parçalarını güvenilir bir şekilde çıkarmaktır. İkinci amacı ise görüntünün temsil şeklini değiştirmektir. Böylelikle görüntü pikselleri daha ileri analizler için, hem daha etkili hemde daha anlamlı yüksek seviyeli görüntü parçaları şeklinde düzenlenmiş olacaktır (Shapiro ve Stockman, 2001).

Görüntü bölütleme, görüntü analizinin ilk ve en kritik aşamalarından biridir. Bu nedenle eğer bölütleme iyi ve başarılı bir şekilde yapılırsa, görüntü analizindeki tüm diğer aşamalar daha basit hale getirilmiş olacaktır (Glasbey ve Horgan, 1995). Görüntü bölütlemeye olası ilk yaklaşım düşük seviyeli bir bölütlemedir (low level segmentation). Bu bölütlemeye birbirine yakın olan, aynı rengi veya aynı deseni veya aynı parlaklık gradyanını paylaşan pikseller birbirine bağlı bir bölge oluşturur. Birbirine bağlı bu bölgeler tek bir nesnede gruplandırılır (Glasbey ve Horgan, 1995). Pikselleri nesnelere gruplamak için yapılan bu işlem görüntünün basit bölgeler ve temel öğeler ile tanımlanmasını sağlamaktadır (White, 1986). Ancak, renk, desen ve parlaklık gradyanı gibi özellikler iki piksel arasında önemli ölçüde değişiklik göstermesi durumunda ise bu pikseller tek bir nesnede gruplandırılmamaktadır.

Görüntü bölütleme, araştırmacılar tarafından büyük ilgi gören ve bilgisayar görmesi alanında çok çalışılan bir konu olmuştur. Bu nedenle görüntü bölütleme alanında birçok farklı algoritma ve teknik geliştirilmiştir. Temelde görüntü bölütleme algoritmaları süreksizlik (discontinuity) ve benzerlik (similarity) gibi iki temel özelliğe dayanmaktadır (Çatal Reis ve Bayram, 2016). Bu özelliklerden süreksizlik temelli bölütlemelerde görüntünün yoğunluk değişiklikleri baz alınarak, benzerlik temelli olan bölütlemelerde ise benzer olan pikselleri baz alınarak bölütleme yapılmaktadır.

Literatür incelendiğinde çok sayıda olan bu algoritma ve teknikler genel olarak Şekil 2.1.'de gösterildiği üzere; bölge tabanlı bölütleme (region based segmentation), sınır tabanlı bölütleme (edge based segmentation), eşikleme tabanlı bölütleme (threshold based segmentation) ve kümeleme tabanlı bölütleme (cluster based segmentation) olmak üzere 4 genel yaklaşım altında gruplandırılmaktadır. Bu dört yaklaşımdan ikisini veya daha fazlasını birleştiren çeşitli karma görüntü bölütleme teknikleri de bulunmaktadır (Hettiarachchia ve Petersa, 2017). Bu bölümde ise yukarıda belirtilen dört temel yaklaşım incelenmiştir.



Şekil 2.1. Görüntü bölütleme yöntemleri

2.1. Bölge Tabanlı Bölütleme

Bölge tabanlı bölütleme algoritmaları, benzer piksel değerlerine sahip ve komşu olan pikselleri bir araya getirerek, değer bakımından farklı olan piksel gruplarını da bölerek yinelemeli olarak çalışan algoritmalarıdır (Glasbey ve Horgan, 1995). Basitçe, bir görüntüdeki bölgeler, benzer özelliklere sahip bir grup bağlantılı pikseldir şeklinde tanımlayabiliriz (Kaur ve Goyal, 2013). Her piksel benzerlik kontrolü için gri seviye, renk, doku, şekil gibi özellikleri yönünden komşu pikselle karşılaştırılır. Sonuç benzer olması durumunda, bölgeyi büyütmek için piksele belirli bir piksel eklenir (Kapade, 2015).

Bölge tabanlı bölütleme algoritmaları kenar algılama yöntemleri ile karşılaştırıldığında, nispeten yönetilebilir ve gürültüye karşı daha dayanıklıdır (Kaur ve Goyal, 2013). Bir bölge tabanlı bölütleme yöntemi kullanmanın avantaj ve dezavantajları bulunmaktadır.

Avantajları (Hussain, 1991);

1. Bir görüntüdeki piksellerden daha az sayıda bölge oluşturmasıdır.
2. Bölgeler birbirine bağlıdır ve benzerleri yoktur.

Dezavantajları (Hussain, 1991);

1. Görüntü özelliklerinin tekdüzeliği konusunda varsayımlar yapmaktadır.
2. Bir bölge hatalı olarak tek bir yüzey olarak düşünülebilmektedir.
3. Yüzey özellikleri veya yansımalar gürültülü bölgeler oluşturacaktır.

Bölge tabanlı bölütleme yöntemi, bölge büyüme (region growing) ve bölge ayırma ve birleştirme (region splitting and merging) gibi iki kategoride sınıflandırılmaktadır.

2.1.1. Bölge büyütme

Bölge büyütme, isminden de anlaşılacağı üzere piksel veya alt bölgeleri daha büyük bölgelere büyütme veya gruplama işlemi olarak tanımlanmaktadır (Gonzalez ve Woods, 2014). Bölge büyütme yöntemi diğer benzer yöntemlere göre daha güvenilir sonuçlar vermektedir. Önceden tanımlanmış bazı kriterler kullanılarak temelde görüntüden bir bölge çıkarmaktadır (Khan ve Ravi, 2013). Bölge büyütmedeki temel yaklaşım, en küçük pikselden, tohumdan başlayarak benzer özelliklere sahip olan komşu piksellerin bu kümeye eklenmesi ile bölgelerin büyütülmesidir. Burada tohum tek bir piksel olabileceği gibi daha fazla üyeye sahip bir piksel grubunda olabilir. Komşu pikseller bu kümeye eklenirken, yeğinlik (intensity), renk, uzamsal özellikler ve yapısal özellikler, özelliklere dayalı tanımlayıcılar, gri seviye görüntülerde gri seviye değerleri, renkli görüntülerde ise RGB (Kırmızı-Yeşil-Mavi) değerleri ve bu özelliklerin benzerlik değerleri dikkate alınmaktadır. Burada hangi özelliklerin dikkate alınacağı probleme bağlı olarak değişiklik göstermektedir. Benzerlik kriteri seçiminde ise sadece probleme bağlı olmayıp, mevcut olan görüntü verisine de bağlı olmaktadır. Bölge büyütme işlemlerinde sadece Sınır Tanımlayıcılar (Boundary Descriptors), Fourier Tanımlayıcılar (Fourier Descriptors), Bölgesel Tanımlayıcılar (Regional Descriptors), Topolojik Tanımlayıcılar (Topological Descriptors), Eş-Oluşum Matrislerini (Co-Occurance Matrix)'de karakterize eden tanımlayıcılar, İstatistiksel Tanımlayıcılar, İlişkisel Tanımlayıcılar (Relational Descriptors) gibi tanımlayıcılar dikkate alınarak yapılan işlemlerde hatalı sonuçlar elde edilebilir (Gonzalez ve Woods, 2008; Gonzalez ve Woods, 2014). Bu nedenle, bölge büyütme işlemlerinde daha doğru sonuçlar elde etmek için, sadece tanımlayıcılar değil, piksel bağlılık (pixel connectivity) (Cheng ve ark., 2009) özellikleri de kullanılmalıdır (Gonzalez ve Woods, 2014).

Bölge büyütme yöntemini, tohumlanmış bölge büyütme (SRG-Seeded Region Growing) ve tohumlanmamış bölge büyütme (uSRG-Unseeded Region Growing) diye iki sınıfta gruplayabiliriz. SRG ve uSRG arasındaki temel fark SRG'nin yarı otomatik, uSRG'nin ise tam otomatik bir yöntem olmasıdır. SRG yönetimi için çeşitli algoritmalar bulunmaktadır. Bu algoritmalar bir bölgeye piksel eklemek veya pikseli

tohum ile karşılaştırma adımlarında farklılık göstermektedir (Khan ve Ravi, 2013). SRG ilk olarak Rolf Adams ve Leanne Bischof (Adams ve Bischof, 1994) tarafından önerilmiş bir yöntemdir. Bu yöntem, görüntünün bölütleneceği bölgelerin oluşumunu kontrol edecek tek tek pikseller veya bölgeler olmak üzere birçok tohumun girişini gerektirmektedir. SRG yaklaşımında başlangıçta tohumlar kullanıcılar tarafından belirlenir. Kullanıcı görüntüdeki farklı bölgeleri manuel olarak tanımlar. Bu tanımlama etiketleri de tohum olarak isimlendirilir. Tohum, ilgilenilen bölgeye ait olan ve ilgilenilen bölgenin bir parçası olması gereken ideal karakteristiğe sahip test pikselidir. Bu yöntem ile yapılan bölütlemenin genel başarısı tohum girdisine bağlı olduğundan dolayı tohum seçimi kritik bir öneme sahiptir. Belirlenen tohum dizisi için, SRG'nin her aşamasında tohum kümelerinden birine bir piksel eklenir. Bu piksel eklenirken hangi tohum kümesine ekleneceği benzerlik ölçütüne dayanarak yapılmaktadır. Aynı bölgeye ayrılmış pikseller aynı değer ile etiketlenir, diğerleri ise farklı değerler ile etiketlenir. Bölgelere eklenecek pikseller, bölgedeki piksellerden en az birine 8-bağlı (8-connected) olmalıdır. İki farklı bölge aynı etikete sahipse bu bölgeler birleştirilmelidir (Khan ve Ravi, 2013).

uSRG, bölge içindeki piksel benzerlikleri esasına dayanan esnek ve otomatik bir bölütleme yaklaşımıdır. Bu yöntem; SRG'ye benzeyen, kullanıcı taraflı bölütleme öncesinde tohum seçimini gerektirmeyen, yani otomatik bölge tabanlı bir bölütleme yöntemi olarak da tanımlanabilir. Bu yöntemde tek bir görüntü pikseli içeren bir A_1 bölgesi ile bölütleme işlemi başlatılır ve bölütleme işlemi sonunda A_1, A_2, \dots, A_n şeklinde alt bölgelere ayrılmış olarak ilk bölütleme aşaması tamamlanır (Lin ve ark., 2000; Khan ve Ravi, 2013).

$$T = \{ x \notin \bigcup_{i=1}^n A_i \wedge \exists k : N(x) \cap A_k \neq \emptyset \} \quad (2.1)$$

T (Denklem 2.1) tüm ayrılmamış piksellerin kümesi olsun. Bu denklemde $N(x)$, x noktasının hemen komşu olan pikselleri ifade etmektedir. Bölge istatistiklerinin ortalama değeri ile x noktasının görüntü değeri arasındaki fark ölçümü (difference measure) dikkate alınarak, o bölgeye atanacak veya atanmayacak olan piksel belirlenmektedir (Denklem 2.2).

$$\delta (x, A_i) = | g(x) - mean_{y \in A_i} [g(y)] | \quad (2.2)$$

$g(x)$, x noktasının görüntü değerini yani test pikselini ve i ise $N(x)$ 'in A_i ile kesiştiği bölgenin bir dizini ifade etmektedir. Bölge büyüme aşaması, bir nokta $z \in T$ ve bir bölge A_j ($j \in [1, n]$) seçmeyi içermektedir (Denlem 2.3).

$$\delta (x, A_j) = \min_{x \in T, k \in [1, n]} \{ \delta(x, A_k) \} \quad (2.3)$$

Fark ölçümünün değeri o bölgeye tanımlanmış olan t eşik değerinden düşük ise A_j diye belirlenen bölgeye atanır. Koşulun sağlanmadığı durumlarda ise test pikseli ile benzer bölgesel özelliklere sahip olan yeni bir A_i bölgesine atanır. Eğer test pikseli A_i ve A_j için koşullar sağlanamıyor ve atanamıyor ise bu durumda test pikselinin yeni bir üçüncü bölgeye ait olduğu anlamına gelmektedir. Her üç durumda da piksel bölgeye atandıktan sonra bölgenin istatistiksel değeri güncellenmelidir ve tüm pikseller bir bölgeye atanana kadar işlemler tekrarlanmalıdır. (Lin ve ark., 2000; Khan ve Ravi, 2013).

2.1.2. Bölge ayırma ve birleştirme


Bölge ayırma, bölge büyütme yöntemine göre daha kolay bir işlemdir. Bölge ayırma ve birleştirme yöntemleri Horowitz ve Pavlidis (Horowitz ve Pavlidis, 1974) tarafından birleştirilerek oluşturulmuş bir yöntemdir (Hussain, 1991). Bu yöntem dörtlü ağaçlar (quadtrees) temelinde çalışır ve asıl amaç görüntünün homojenliğini ayırt etmektir.

R bütün bir görüntüyü ve Q ise önceden tanımlanmış bazı kriterleri baz alan koşulu ifade edecek olsun. Buna göre bu yöntem, R 'yi bölütlemek için görüntüyü ardışıl daha küçük dördün bölgelere ayıracaktır. Bu ayırma işleminde herhangi bir R_i bölgesinin $Q(R_i) = DOĞRU$ koşulunu sağlayacak şekilde işlemi gerçekleştirecektir. Eğer Q koşulu sağlanmıyorsa, görüntü dörtlü bölgelere ayrılacaktır. Ayrılan bu dörtlü içinde Q koşulunun sağlanmaması durumunda, bu dörtlü Q koşulu DOĞRU olana kadar tekrar dördün bölgelere ayrılmaya devam edecektir (Gonzalez ve Woods, 2008;

Gonzalez ve Woods, 2014). Bölge bölünmesinin en büyük dezavantajı, ortaya çıkan görüntünün görüntüyü temsil etmek için kullanılan veri yapısını taklit etme eğiliminde olması, çok fazla dörtlü alt bölgeler ortaya çıkması ve birbirleri ile özdeş olan komşu bölgelerin olmasıdır. Bu sorunu çözmek için birleştirme işlemi uygulanır. Bölge birleştirme yaklaşımında, olabildiğince büyük ve homojen bölgeler oluşturmak için benzer bölgeler birleştirilir. Bunu gerçekleştirmek için de bölge birleştirme yaklaşımı, çoğunlukla bölge büyütme veya bölge ayırma ile beraber kullanılır (Cheng ve ark., 2001). Ayrıca, özdeş özellikli ve birbirine komşu olan R_k ve R_m gibi bölgeler $Q(R_k \cup R_m)$ koşulunu DOĞRU olarak sağlıyorsa birleştirme gerçekleştirilecektir (Gonzalez ve Woods, 2008; Gonzalez ve Woods, 2014).

Özetle, R bölgesi üzerinde çalışan bir Q koşulu göz önüne alındığında, bölgeleri bölmek veya birleştirmek için aşağıdaki üç adım uygulanabilir (Hussain, 1991).

1. $Q(R_i) = \text{YANLIŞ}$ olması durumunda Şekil 2.2.'de gösterildiği gibi R_i bölgesi dörtlü ağaç (quadtree) yöntemi kullanılarak dörtlü alt bölgelere ayrılır (Hussain, 1991).



Şekil 2.2. Bölge ayırma ve birleştirme


2. $Q(R_{i1} \cup R_{i2} \cup R_{i3} \cup R_{i4}) = \text{DOĞRU}$, dörtlü ağaç alt bölgelerini i bölgesi içinde birleştirir (Hussain, 1991).
3. $Q(R_k \cup R_m) = \text{DOĞRU}$, birbirine komşu olan iki bölge birinine benzer ise, bu bölgeler birleştirilir (Hussain, 1991).

2.2. Kenar/Sınır Temelli Bölütleme

Geleneksel kenar algılama şemaları temel olarak gri tonlama veya rengin değerinin gradyanını hesaplamaya bağlıdır (He ve Ni, 2019). Kenar tabanlı bir bölütleme yaklaşımı, karmaşık bir eşikleme şeması kullanmadan, bölümlenmiş nesnenin boyutunda yanlı bir etkiyi önlemek için kullanılabilen yöntemlerdendir (Jahne, 2005). Bu yöntemde, nesnelere tanımlamak için görüntüdeki algılanan kenarların nesne sınırlarını temsil ettiği kabul edilir. Yoğunluk değerindeki ani değişiklikler ile bölgeleri tespit etmeye dayalı bölütleme yöntemine Kenar veya Sınır temelli yöntemler denilmektedir. Sınır tespiti, görüntü analizinde temel öneme sahip bir konudur. Kenar tespiti yöntemleri genellikle gri seviyeli görüntülerde süreksizlik bulmak için kullanılan tekniklerdir. Süreksizliklerin tespiti için görüntü bölümlendirme yöntemleri sınır temelli yöntemlerdir (Muthukrishnan ve Radha, 2011).


Görüntü bölütleme için çok sayıda kenar algılama tekniği vardır. Bu kenar algılama yöntemleri, birinci mertebeden ve ikinci mertebeden türev operatörleri olarak iki kategoriye ayrılmaktadır. Genel olarak, birinci mertebeden türev operatörleri daha kalın sınırlar üretirler. İkinci mertebeden türev operatörleri ise daha gelişmiş yöntemlerdir ve ince detaylar üzerinde daha etkili olduğu için ince kenarlara ve gürültüye daha hassasdır (Gonzalez ve Woods, 2014). Bu yöntemlerden yönsüz kenar maskerini kullanan Roberts (Roberts, 1965), Sobel (Sobel ve Feldman, 1968; Sobel, 1970) ve Prewitt (Prewitt, 1970) operatörleri birinci mertebeden türev operatörleri kategorisine, Gauss'un Laplası (LoG) (Marr ve Hildreth, 1980) ve Canny (Canny, 1986) operatörleri de ikinci mertebeden türev operatörleri kategorisine ayrılmaktadır.

Şekil 2.3. ve Şekil 2.4.'te kolona ait mikroskobik görüntülerden, sırasıyla iyi huylu ve kötü huylu kolon tümörlerinin, kenar tabanlı bölütleme yöntemleri ile bölütlenmiş örnek görüntüleri verilmiştir.




(a)


(b)




(c)



(d)




(e)




(f)

Şekil 2.3. (a) Orijinal iyi huylu tümör görüntüsü (b) Canny operatörü uygulanmış görüntü (c) LoG operatörü uygulanmış görüntü (d) Sobel operatörü uygulanmış görüntü (e) Roberts operatörü uygulanmış görüntü (f) Prewitt operatörü uygulanmış görüntü




(a)

(b)



(c)

(d)



(e)

(f)

Şekil 2.4. (a) Orijinal kötü huylu tümör görüntüsü (b) Canny operatörü uygulanmış görüntü (c) LoG operatörü uygulanmış görüntü (d) Sobel operatörü uygulanmış görüntü (e) Roberts operatörü uygulanmış görüntü (f) Prewitt operatörü uygulanmış görüntü

Kenar temelli bölütleme yaklaşımında, kenar veya ayrıtların saptanması için yeğinlikteki (intensity) değişimler birinci ve ikinci derece türev ile belirlenmektedir. Bu yöntemde kullanılan maskeler, bir f görüntüdeki herbir piksel için $\partial f/\partial x$ ve $\partial f/\partial y$ kısmi türevlerinin hesaplaması sonucunda, g_x ve g_y gradyan bileşenlerinin (Denklem 2.4) elde edilmesi için kullanılmaktadır (Gonzalez ve Woods, 2014). Bu gradyan bileşenleri Denklem 2.5'te kullanılarak gradyanın genliği hesaplanır. Elde edilen sonuç bir T eşik değeri ile kıyaslanarak kenar noktası tespit edilir.

$$\begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (2.4)$$

$$M(x, y) = \sqrt{g_x^2 + g_y^2} \quad (2.5)$$

$$M(x, y) \approx |g_x| + |g_y| \quad (2.6)$$

$M(x,y)$ gradyan vektörü yönündeki değişim hızının (x,y) 'deki değeridir. Denklem 2.5'teki bu değer hesaplanması fazla işlem yükü oluşturduğundan (kare ve karekök alma) sıklıkla gradyan bileşenlerinin mutlak değerini kullanılan Denklem 2.6 tercih edilmektedir (Gonzalez ve Woods, 2014).

2.2.1. Roberts

İlk olarak Lawrence Roberts tarafından 1965 yılında tanıtılmıştır (Roberts, 1965). Bu operatör, görüntü üzerinde iki boyutlu gradyan ölçümünü basit ve hızlı bir şekilde gerçekleştirir. Böylelikle kenarlara karşılık gelen yüksek uzamsal frekans bölgeleri vurgulanmış olmaktadır. En iyi ikili (binary) görüntüler üzerinde çalışır. Operatörün giriş ve çıkış görüntüsü gri tonlamalı bir görüntüdür. Çıktı görüntüsünde bulunan her noktadaki piksel değeri, o noktadaki giriş görüntüsünün uzamsal gradyanının tahmini mutlak büyüklüğünü temsil etmektedir (Muthukrishnan ve Radha, 2011). Dolayısıyla bu operatör f görüntüsünün gradyanının maksimum olduğu yerlerde kenar döndürmektedir (Cui ve ark., 2013). Görüntüdeki kenarları bulmak için kullanılan en

basit ilk türev operatörlerinden biridir. Bu operatör satır ve sütunlarda kenarları ayrı ayrı bulur. Bulunan bu kenarlar nesnelere tüm şeklini ve kenarlarını ortay koymak için birleştirilir. Şekil 2.5.'teki 2 x 2 maskeler kullanılarak görüntü x ve y koordinatları boyunca taranarak kenarlar belirlenir. (Khan ve Ravi, 2013).

m_1	m_2
m_3	m_4

-1	0
0	1

0	-1
1	0

Şekil 2.5. Roberts operatör maskesi

Roberts operatörü Denklem 2.7 ve 2.8'de görüldüğü üzere diyagonal farklar uygulayan bir operatördür. Roberts operatörü için gradyan bileşenleri aşağıdaki denklemler ile elde edilmektedir.

$$g_x = \frac{\partial f}{\partial x} = m_4 - m_1 \quad (2.7)$$

$$g_y = \frac{\partial f}{\partial y} = m_3 - m_2 \quad (2.8)$$

2.2.2. Sobel

Sobel operatörü Sobel–Feldman operatör olarakta isimlendirilmektedir. Sobel ve Feildman tarafından 1968 tarihinde sunulmuştur (Sobel ve Feldman, 1968; Sobel, 1970). Bu operatörü, görüntü yoğunluğu fonksiyonunun gradyanının yakınsamasını hesaplayan bir ayrık türev operatörü olarakta tanımlayabiliriz. Sobel operatörü, Prewitt operatörü maskesinin merkez katsayısını 2 olarak değiştirilmiş halidir. Şekil 2.6.'da 3 x 3 maskeler kullanılarak x ve y koordinatları boyunca taranarak kenarlar belirlenir. (Khan ve Ravi, 2013).

m ₁	m ₂	m ₃	-1	-2	-1	-1	0	1
m ₄	m ₅	m ₆	0	0	0	-2	0	2
m ₇	m ₈	m ₉	1	2	1	-1	0	1

Şekil 2.6. Sobel operatör maskesi

$$g_x = \frac{\partial f}{\partial x} = (m_7 + 2m_8 + m_9) - (m_1 + 2m_2 + m_3) \quad (2.9)$$

$$g_y = \frac{\partial f}{\partial y} = (m_3 + 2m_6 + m_9) - (m_1 + 2m_4 + m_7) \quad (2.10)$$

Sobel operatöründeki 3 x 3 maskenin birinci ve üçüncü satırlarının merkez değerinde 2 değeri olduğundan Prewitt operatöründeki denklemlerde 2 katsayısı kullanılarak gradyan bileşenlerini Denklem 2.9 ve Denklem 2.10 ile elde edilmektedir.

2.2.3. Prewitt

Şekil 2.7.'de 3 x 3 maskeler kullanılarak f görüntüsü x ve y koordinatları boyunca taranarak kenarlar belirlenir. (Khan ve Ravi, 2013).

m ₁	m ₂	m ₃	-1	-1	-1	-1	0	1
m ₄	m ₅	m ₆	0	0	0	-1	0	1
m ₇	m ₈	m ₉	1	1	1	-1	0	1

Şekil 2.7. Prewitt operatör maskesi

Prewitt (Prewitt, 1970) operatörü için gradyan bileşenleri aşağıdaki denklemler ile elde edilmektedir (Denklem 2.11 ve Denklem 2.12).

$$g_x = \frac{\partial f}{\partial x} = (m_7 + m_8 + m_9) - (m_1 + m_2 + m_3) \quad (2.11)$$

$$g_y = \frac{\partial f}{\partial y} = (m_3 + m_6 + m_9) - (m_1 + m_4 + m_7) \quad (2.12)$$

2.2.4. Gauss'un laplası (LoG)

Gauss'un Laplası (LoG - The Laplacian of Gaussian) veya diğer bir adıyla Marr ve Hildreth algoritması (Marr ve Hildreth, 1980) 1980 yılında Marr ve Hildreth tarafından önerilmiştir. Bu yöntem görüntüyü bulanıklaştırmak ve böylelikle gürültüyü azaltmak için bir Gauss filtresi ve sıfır geçişleri bularak görüntüdeki kenarları ortaya çıkarmak için Laplas (Laplacian) kullanılmaktadır. Uygulanacak m x m Gauss filtresinin boyutunu m'nin 6σ'ya eşit veya daha büyük olduğu bir en küçük tamsayı olacak şekilde belirlenmektedir (Gonzalez ve Woods, 2014).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.13)$$


Bu denklemde (Denklem 2.13), x ve y sırasıyla yatay, dikey ekseninde orijinden olan mesafeyi göstermektedir. σ ise Gauss dağılımının standart sapmasıdır (Cui ve ark., 2013).

Marr ve Hildreth, LoG yöntemi için ani yeğinlik değişimi birinci türev işleminde bir tepe veya çukur oluşmasına, ikinci türevde ise sıfır geçişine sebep olacağını ve bu sıfır geçişlerin kenar noktaları tespit etmek için kullanıldığını, bu işlemi gerçekleştirecek operatörün de $\nabla^2 G$ olduğunu belirtmişlerdir (Denklem 2.14 ve Denklem 2.15). Bu denklemde ∇^2 Laplas operatörünü, G ise Gauss fonksiyonunu ifade etmektedir. (Cui ve ark., 2013; Gonzalez ve Woods, 2014). Aşağıdaki denklemlerde Gauss'un Laplası formüle edilmiştir ve Şekil 2.8'de LoG fonksiyonunun üç boyutlu çizimi verilmiştir.

$$\nabla^2 G(x, y) = \frac{\partial^2 G(x, y)}{\partial x^2} + \frac{\partial^2 G(x, y)}{\partial y^2} \quad (2.14)$$

$$\nabla^2 G(x, y) = \frac{x^2+y^2-2\sigma^2}{\sigma^4} G(x, y) \quad (2.15)$$

Şekil 2.8.'de gösterilen üç boyutlu LoG fonksiyonu görünüş itibari ile Meksika şapkasına benzediği için fonksiyon literatürde bazen Meksika Şapkası olarakta isimlendirilmektedir. (Gonzalez ve Woods, 2014).



Şekil 2.8. LoG fonksiyonunun 3 boyutlu çizimi

Gauss'un Laplası (LoG) yönteminde, Laplas işleci yön bağımsız olmasından dolayı avantajlı yapılardır ve Şekil 2.9.'da gösterilen 3 x 3 maskeler kullanılarak, x ve y koordinatları boyunca tarama işlemi ile görüntü üzerinde uygulanır. (Khan ve Ravi, 2013).

1	1	1	-1	2	-1	0	1	0
1	-8	1	2	-4	2	1	-4	1
1	1	1	-1	2	-1	0	1	0

Şekil 2.9. The laplacian of gaussian operatör maskesi

Burada görüntüyü uygun LoG maskesi ile konvolüsyon işlemine tabi tutmak ve çıktının sıfır geçişlerini tespit etmek suretiyle LoG yöntemi daha iyi bir belirleme yapar (Cui ve ark., 2013).


2.2.5. Canny

John F. Canny tarafından 1986 yılında geliştirilen Canny algoritması (Canny, 1986), görüntü gradyanının yerel maksimum olduğu yerleri bularak kenarları tespit eden ve diğer algoritmalara kıyasla daha karmaşık bir yöntemdir (Cui ve ark., 2013).

Canny'e göre iyi bir kenar tespit yaklaşımı aşağıda belirtilen üç temel özelliği olmalıdır (Nikhil ve Sankar, 1993; Gonzalez ve Woods, 2008; Gonzalez ve Woods, 2014).

1. Kenar olmayan noktaların yanlış olarak işaretlenme olasılığının düşük olması ve gerçek kenar noktalarının düşük hata olasılığıyla işaretlenmesi gerekir. Yani düşük hata oranı ile işaretlenmenin gerçekleşmesi gerekir.
2. Kenar notlarının iyi olarak belirlenebilir olması. Kenar olarak işaretlenmiş noktaların, gerçek olan kenarların merkezini mümkün olduğunca yakın olması gerekir.
3. Tek kenar noktası için tek bir kenar cevabının olması gerekir.

Bu yöntem yukarıda belirtilen kriterlerin matematiksel olarak ifade edilip en uygun çözümün bulunmasını temel almaktadır (Gonzalez ve Woods, 2014). Bu yöntemde ilk olarak gürültünün etkilerini azaltmak için görüntü üzerinde alçak geçiren Gauss filtresi uygulanmaktadır (Cui ve ark., 2013). Gauss filtresi, Gauss fonksiyonunu ile elde edilen değerlerden oluşan bir çekirdek (kernel) olarak tanımlanabilmektedir. Şekil 2.10.'da örnek bir 2D Gauss eğrisi grafiksel olarak gösterilmiştir. Gauss eğrisi çan şekline benzemektedir. Burada, tepe noktasının eğriliğini çekirdek boyutuna, yumuşatma oranı da σ yani standart sapmaya bağlıdır.



Şekil 2.10. Örnek bir Gauss eğrisinin görünümü

$f(x,y)$ giriş görüntüsü ve $G(x,y)$ Gauss fonksiyonu olarak verilsin, bu durumda Gauss filtresini oluşturmak için 2D Gauss fonksiyonu Denklem 2.13'teki gibi verilmiştir. G Gauss filtresi oluşturulduktan sonra f giriş görüntüsü ile konvolüsyon işlemine tabi tutulur ve türevi alınır böylelikle gradyan bileşenleri elde edilir (Denklem 2.16, Denklem 2.17 ve Denklem 2.18) (Cui ve ark., 2013).

$$G_x = \frac{-x}{\sigma^2} G(x, y), \quad G_y = \frac{-y}{\sigma^2} G(x, y) \quad (2.16)$$

$$g_x = \frac{\partial}{\partial x} (G * f) = f * G_x \quad (2.17)$$

$$g_y = \frac{\partial}{\partial y} (G * f) = f * G_y \quad (2.18)$$

Burada $*$ işareti konvolüsyon işlemi ifade etmektedir. Alınan türev ile yatay yönde g_x ve dikey yönde g_y değerleri elde edilmektedir. Elde edilen bu değerler Denklem 2.4 veya Denklem 2.5'te yerine konularak gradyan genliği hesaplanır. Aşağıdaki eşitlik ile de gradyan yönü hesaplanır (Denklem 2.19) (Gonzalez ve Woods, 2014).

$$\alpha(x, y) = \tan^{-1} \left[\frac{g_y}{g_x} \right] \quad (2.19)$$

Bu işlemler gerçekleştirildikten sonra gradyan büyüklüğünün yeral maksimumlarını bulmak için bir “maksimum olmayanları bastırma (non-maxima suppression)”

algoritması uygulanır. Gürültüden kurtulmak ve gerçek kenar noktalarını korumak için iki eşikli bir histeresis eşiği (hysteresis thresholding) uygulanır (Cui ve ark., 2013).

2.3. Eşikleme Temelli Bölütleme

Eşikleme tabanlı bölütleme yöntemi görüntü bölütleme için en çok kullanılan piksel tabanlı yöntemlerden birisidir. Başka bir deyişle, görüntüdeki arka plan pikselleri ile nesne pikselleri arasındaki piksel yoğunluğunun farkına dayanan en basit yöntemdir (Chen ve ark., 2017). Eşikleme temelli bölütleme yöntemi ile yapılan bölütlemelerde, ihtiyaç duyulan depolama alanının daha az olması, bölütleme işlem hızının yüksek olması ve görüntü manipülasyonunun kolay bir şekilde yapılması gibi avantajlardan dolayı eşikleme temelli bölütleme yöntemi diğer yöntemlere kıyasla daha çok tercih edilmektedir. (Arora ve ark., 2019).

Temelde eşikleme işlemi, görüntü piksellerini farklı sınıflara bölmek, nesnelere ve arka planı birbirinden ayırmak için uygun eşik veya eşikleri seçmek üzerine kuruludur. Literatürde uygun olan eşik seçmek veya bulmak için çeşitli yöntemler bulunmaktadır (Sezgin ve Sankur, 2004). Görüntü bölütleme için kullanılan en eski eşikleme tekniklerinden biri olan P-tile eşikleme (Doyle, 1962), nesnenin kapladığı alan bilgisine ve olasılığına dayanan bir yöntemdir (Hussain, 1991). Bu yöntemde, eşik değeri bölütleme yapılacak bölgenin boyutuna göre belirlenmektedir (Tenekeci ve ark., 2017). Ridler ve Calvard 1978 yılında, Trussell'da 1979 yılında tek bir eşik seçmek için basit inter-means algoritması önermişlerdir (Ridler ve Calvard, 1978; Trussell, 1979). 1979 yılında Nobuyuki Otsu tarafından, gri seviyeli görüntülerin binary görüntülere dönüştürülmesi için otomatik eşik değerini hesaplayan çok adımlı bir yöntem önerilmiştir (Otsu, 1979). 1980 yılında entropiye göre eşik seçiminin yapıldığı Pun yöntemi (Pun, 1980; Pun, 1981) önerilmiştir. Kapur ve arkadaşları ise 1985 yılında histogramların entropisi kullanılarak gri seviye görüntülerde eşikleme üzerine daha genişletilmiş bir versiyonunu (Kapur ve ark., 1985) önermişlerdir. Benzer bir entropi tabanlı yöntem Johanson ve Bille tarafından 1982 yılında önerilmiştir (Johanson ve Bille, 1982). Daha sonra Abutaleb tarafından eşik hesaplamasının iki boyutlu entropi (Abutaleb, 1989) ile yapıldığı bir yöntem önerilmiştir. Bu yöntemlere

ek olarak eşikleme için histogram tabanlı yöntemler, piksellerin ortalama değerleri kullanılarak yapılan eşikleme yöntemleri, kümeleme tabanlı eşikleme yöntemleri ve görsel(visual) teknikler de önerilmiştir. (Sezgin ve Sankur, 2004; Tobias ve Seara, 2002; Saini ve ark., 2012).

Eşikleme işlemi, görüntüdeki gri piksel değerine Denklem 2.20 ve Denklem 2.21’de gösterilen şartlara göre yeni bir değer ataması ile bölütlenmesi işlemidir. Bu şekilde, eşik değerinden daha düşük değerlere sahip pikseller bir sınıfa yerleştirilir ki bu sınıf arkaplan piksellerini ifade etmektedir ve eşik değerinden büyük olan pikseller diğer bir sınıfa yerleştirilir ki buda nesne piksellerini ifade etmektedir. Böylelikle, gri seviyeli görüntüler iki parçaya ayrılarak 0 ve 1 olarak binary görüntülere dönüştürülmüş olmaktadır.

$$T = T [x, y, p(x, y), I_g(x, y)] \quad (2.20)$$

Burada, $I_g(x,y)$ (x,y) noktasındaki gri seviye değerini, $p(x,y)$ (x,y) noktasının yerel özelliklerini göstermektedir (Gonzalez ve Wood, 2002).

$$I_b(x, y) = \begin{cases} 0, & I_g(x, y) < T \\ 1, & I_g(x, y) \geq T \end{cases} \quad (2.21)$$

Bu denklemde (Denklem 2.21) ise T eşik değerini, $I_b(x,y)$ binary bir görüntüyü ve $I_g(x,y)$ ise gri seviyeli görüntüyü ifade etmektedir. Burada eşikleme için genellikle görüntünün histogramından faydalanılmaktadır. Bu bölütleme yöntemi, koyu arka planda parlak nesnelere sahip görüntüler için daha etkili bir yöntemdir (Chen ve ark., 2017).

Literatüre bakıldığında eşikleme, görüntü bölütlemeye farklı biçimlerde kullanıldığı görülebilmektedir. Kullanım alanlarının farklılığı ve eşikleme tekniklerinin birçok geliştirilmiş versiyonlarının olması sebebiyle eşikleme tabanlı bölütleme farklı şekillerde kategorize edilebilmektedir (Sezgin ve Sankur, 2004; Gonzalez ve Wood,

2008). Ama genel olarak eşikleme temelli bölütleme, yerel ve global eşikleme olmak üzere 2 kategoriye ayrılmaktadır.

2.3.1. Global eşikleme

Global eşikleme yöntemi, ön plan ve arka plan nesnelерinin arasındaki yoğunluk dağılımının tam olarak belli olduğu durumlarda kullanılmaktadır. Bu tarz durumlarda tek eşik kullanılarak her iki nesneyi birbirinden ayırmak mümkün olmaktadır (Senthilkumaran ve Vaithegi, 2016). Denklem 2.20'deki fonksiyona bakarak, T eşik değeri sadece $f(x,y)$ 'ye bağlı ise yada bir görüntü için uygulanabilir tek bir sabit değeri ise eşik değeri global eşik olarak isimlendirilmektedir. Global eşikleme kullanılan birçok uygulama için tek eşik değeri belirlemek uygun olsada, eşik değerini otomatik olarak belirleyebilen iteratif algoritmalar ile daha iyi sonuçlar elde edilmektedir. Global eşikleme için iteratif bir eşik değeri seçilirken aşağıdaki 5 adım uygulanmaktadır (Gonzalez ve Wood, 2002; Gonzalez ve Wood, 2008).

1. Başlangıç için genel bir T eşik değeri belirlenir.
2. Belirlenen bu eşik değeri ile Denklem 2.21'deki şartlara uyan ikili bir görüntü oluşturulur. Böylelikle iki farklı piksel grubu oluşturulur.
3. Herbir piksel grubunun ortama yeğlilik değerleri (O_1 ve O_2) hesaplanır.
4. O_1 ve O_2 'nin ortalaması alınarak yeni eşik değeri belirlenir.
5. Adım 2 ile 4 arasındaki tüm işlemler tekrar edilir. Bu tekrarlardaki T'nin değerleri arasındaki fark önceden tanımlanmış olan ΔT parametresinden küçük ise işlem sonlandırılır ve yeni T değeri belirlenmiş olur.

Global eşikleme olarak iteratif eşikleme dışında optimal eşikleme, entropi tabanlı eşikleme, Otsu eşikleme gibi eşikleme yöntemleri de bulunmaktadır (Goh ve ark., 2018). Bu eşikleme yöntemlerinden en çok tercih edilen ve kullanılan yöntem ise Otsu eşiklemesidir. Otsu algoritmasındaki temel yaklaşım da global eşikleme için en uygun olan eşik değerinin bulunması üzerinedir.

2.3.2. Yerel eşikleme

Yerel eşikleme adaptif eşikleme olarakta isimlendirilmektedir. Denklem 2.20'deki fonksiyona bakarak, eğer T eşik değeri $f(x,y)$ ve $p(x,y)$ 'nin ikisine birden bağlı ise yani herhangi bir (x,y) noktasındaki eşik değeri bu noktanın komşu piksel özelliklerine bağımlı ise eşik değeri yerel eşik olarak adlandırılır ve Denklem 2.22'deki gibi formüle edilir. Yerel eşiklemede görüntü, alt görüntü bölgelerine ayrılır böylelikle görüntüde çok yönlü aydınlanma ve yansımalar dengelenmiş olmaktadır (Gonzalez ve Wood, 2002; Gonzalez ve Wood, 2008). Yerel eşikleme alt görüntülerin gri seviye değerleri, komşu piksellerin ortalama (mean) ve değişim (variance) gibi yerel görüntü özelliklerine bağlı olduğundan dolayı, görüntüyü alt görüntülere bölerken alt görüntülerin arkaplan ve ilgili nesnelere ilişkin yeterli büyüklükte olmasına dikkat edilmelidir (Bhargavi ve Jyothi, 2014). Alt bölgelere ayrılan herbir alt görüntü için yerel eşik değeri seçilir.


$$I_b(x, y) = \begin{cases} 0, & I_g(x, y) < T(x, y) \\ 1, & I_g(x, y) \geq T(x, y) \end{cases} \quad (2.22)$$

Bu denklemde (Denklem 2.22) $I_b(x,y)$ binary bir görüntüyü, $I_g(x,y)$ ise gri seviyeli alt görüntüyü ve $T(x,y)$ ise alt görüntülerin eşik değerini ifade etmektedir. Yerel eşikleme işleminde alt görüntüler için eşik seçiminde daha genel bir yaklaşım olarak yerel görüntü özelliklerine dayalı bir değişken eşikleme ile eşik belirleme yöntemi tercih edilmektedir (Gonzalez ve Wood, 2008; Gonzalez ve Wood, 2014). Eşik belirleme işlemlerinde p-tile eşikleme, optimal eşikleme, uyarlamalı eşikleme otomatik eşik belirleme yöntemleride tercih edilebilmektedir.

2.4. Graf Tabanlı Bölütleme

Graf tabanlı bölütleme (Graph based segmentation) yöntemlerinde düğümler; piksel, piksel köşeleri, bölgeler ve hatta kullanıcı tarafından çizilen işaretleyiciler şeklinde olabileceği bir grafik gösterimi sunmaktadır (Camilus ve Govindan, 2012). Graf kelimesi terimsel olarak incelendiğinde; geometrik veya kuramsal herhangi bir bilgi

vermeyen, düğüm şeklindeki noktalar ile bu noktaları birleştiren hatlardan oluşan çizgiler topluluğu şeklinde ifade edilmekte, çizge veya çizit olarak adlandırılmaktadır (Karaş, 2018). Graf teorisi başlangıcının, matematikçi Leonhard Euler tarafından 1736 tarihinde “Königsberg'in Yedi Köprüsü” problemine ilişkin önerdiği çözüme dayandığı kabul edilmektedir (Sachs ve ark., 1988). Şekil 2.11.'de x ve y noktaları graf düğümünü, E_{xy} ise bu düğümleri birleştiren bağlantıyı ifade etmektedir. Şekil 2.11.'de görüldüğü üzere graf, düğümler ve bu düğümleri birleştiren kenar veya hat kümesinin oluşturduğu bir ağ yapısı şeklinde görünmektedir.



Şekil 2.11. Örnek bir yönsüz graf görünümü

Başka bir deyişle graf (G), düğüm noktalarının kümesini (V) ve bu düğümleri birleştiren bağlantı kümesini (E) içeren bir $G=(V,E)$ çifti olarak tanımlanmaktadır. Burada E ve V 'nin küme gösterimi; $V=\{V_1,V_2,\dots,V_n\}$ ve $E=\{E_1,E_2,\dots,E_n\}$ şeklinde ifade edilmektedir. Her x ve y düğümü için E_{xy} ile W_{xy} ağırlığı ilişkilendirildiğinde oluşan grafa, ağırlıklı graf denilmektedir. Bu ağırlık düğümler arasındaki bağlantı özelliğini (yoğunluk, renk, hareket ve konum farkı veya diğer yerel özellikler) ifade eden bir sayıdır. Eğer bir görüntüde pikseller, düğümler olarak temsil edilirse ve kenarlar (E_{xy}) iki düğüm arasındaki hat ile ifade edilirse, bu durumda her bir kenara karşılık gelen ağırlıklar (W_{xy}) komşu pikseller arasındaki benzerliği veya farklılığı gösterecektir. (Sağlam, 2016; Felzenszwalb ve Huttenlocher, 2004; Fabijanska, 2011).

Graf tabanlı bölütleme işlemi, ağırlıklı grafını belirli kriterlere göre bölgelere kesen bir bölütlemedir (Felzenszwalb ve Huttenlocher, 2004). Böylelikle görüntü alt bölgelere ayrılmış olmaktadır. Bu işlemi gerçekleştirirken farklı yöntemler kullanılmaktadır. En çok kullanılan Graf Kesim (Graph Cut) yöntemidir. Bu yöntemde, pikseller yani

düğümler arasındaki hatlara, piksel benzerliğine göre hesaplama yapan bir maliyet fonksiyonu kullanılarak kesme işlemi uygulanır (Sağlam, 2016). Uygulanan bu kesme işlemi için genellikle Denetimsiz Graf Kesim (Unsupervised Graph Cut) algoritmaları olan Minimum Kesim (Minimum Cut) (Stoer ve Wagner, 1994), Normalleştirilmiş Kesim (Normalized Cut) (Shi ve Malik, 1997), Aritmetik Ortalama Kesim (Average Cut) (Sarkar ve Soundararajan, 2000), Ortalama Kesim (Mean Cut) (Wang ve Siskind, 2001) ve Oran Kesim (Ratio Cut) (Jermyn ve Ishikawa, 1999; Jermyn ve Ishikawa, 2001; Wang ve Siskind, 2003) algoritmaları kullanılmaktadır (Szeliski, 2011). Bu Denetimsiz Graf Kesim algoritmalarının fonksiyonları Tablo 2.1.'de verilmiştir.

Tablo 2.1. Denetimsiz Graf Kesim algoritmalarının fonksiyonları (Sağlam, 2016)

Algoritma	Fonksiyon
Minimum Kesim	$Cut_{Min}(A, B) = \sum_{i \in A, j \in B} w(i, j)$
Normalleştirilmiş Kesim	$Cut_N(A, B) = \frac{Cut(A, B)}{assoc(A, V)} + \frac{Cut(A, B)}{assoc(A, V)}$
	$assoc(A, V) = \sum_{i \in A, t \in V} w(i, t)$
Aritmetik Ortalama Kesim	$Cut_{Avg}(A, B) = \frac{Cut(A, B)}{ A } + \frac{Cut(A, B)}{ B }$
Ortalama Kesim	$Cut_{Mean}(A, B) = \frac{Cut(A, B)}{\sum_{i \in V_a, j \in (V/V_a)} 1}$
Oran Kesim	$Cut_{Ratio}(A, B) \triangleq \frac{C_1(A, B)}{C_2(A, B)}$

Tablo 2.1.'de verilen denklemlerde i ve j düğümleri, $w(i, j)$ bu düğümler arasındaki ağırlığı, V düğümler kümesini, A ve B iki bölüme ayrılmış ayrık kümeleri, $assoc(A, V)$ A 'daki düğümlerden tüm düğümlere olan toplam bağlantıyı, $assoc(B, V)$ 'de aynı mantıkla B 'deki düğümlerden tüm düğümlere olan toplam bağlantıyı, $C_1(A, B)$ $w_1(i, j)$ ilk kenar/hat ağırlığına göre iki bölge arasındaki sınır büyüklüğünü ve $C_2(A, B)$ ise $w_2(i, j)$ ikinci kenar/hat ağırlığına göre iki bölge arasındaki sınır büyüklüğünü ifade etmektedir.

2.5. Kümeleme Tabanlı Bölütleme

Kümeleme, eğitim verisi olarak sınıf etiketli veri kümesi gerektirmeden bilinmeyen bir veri setini kümeleyen denetimsiz bir öğrenme sürecidir (Hettiarachchia ve Petersa, 2017). Bölütleme açısından kümeleme, bir görüntünün hangi bileşenlerinin doğal bir şekilde aynı grubun üyesi olduğunu belirlemeye çalıştığımız, bölütlemenin doğal bir hali olarak tanımlanabilir (Forsyth ve Ponce, 2012). Basit anlamda ise, birbirine benzeyen veri bölümlerinin ayrı küme veya grup olarak ayrılmasıdır. Buradaki temel yaklaşım, küme veya grup içindeki benzerliklerin en üst düzeyde olması, kümeler arasındaki benzerliklerin ise en az düzeyde olması beklenmektedir. Benzerlik ve farklılık olarak ifade edilen küme veya küme içindeki elemanların birbirine uzaklıklarıdır (Özkan, 2008; Purutçuoğlu ve Ayyıldız, 2014). Kümeleme yöntemi, bölütleme ve gruplama şeklinde iki farklı amaçla kullanılabilir. Bölütleme için kullanılırken, sahip olunan veri kümesi (görüntü veya video dizisi olabilir) içindeki öğeler arasındaki ilişkiye veya benzerliğe göre kümelendirilir. Gruplama için kullanılırken ise, farklı veri öğeleri içeren veri kümesi içindeki, birbirine uygun şekilde bir araya gelebilecek öğeleri toplayarak gruplandırılır (Forsyth ve Ponce, 2012). Gruplama ve Bölütleme için yapılan kümelemelerde mantık ve yapılmak istenen amaç açısından her ne kadar farklı işlemler gibi görünsede, bir görüntü üzerinde uygulandığında gruplama işlemi de sonuç olarak bölütleme yapılmasını sağlamış olacaktır.

Bir kümeleme yöntemi kullanmak ve ondan bir görüntü bölütleyici oluşturmak oldukça basit ve tercih edilen bir yaklaşımdır. Görüntü bölütlemesi ve istatistiksel çalışmalarda en yaygın olarak kullanılan yöntemdir (Wang, 2010). Görüntü bölütleme ile ilgili literatür incelendiğinde, bu literatürün büyük bir kısmı, özünde kümelemeyle ilgili çalışmalardır (Forsyth ve Ponce, 2012). Özellikle tıbbi görüntüler üzerinde yapılan çalışmalarda kümeleme yöntemleri daha yaygın olarak kullanılmaktadır. Literatürde birçok kümeleme yöntemi ve bu yöntemlerin geliştirilmiş farklı versiyonları bulunmaktadır. Bu nedenle kümeleme algoritmaları; kullanılacak veri tipi, veri noktaları arasındaki benzerliği tanımlayan kümeleme kriteri, algoritmaların dayandığı teori ve temel kavramlar, kullanım alanları, işlevsellik ve temel özelliklerine

göre farklı şekillerde kategorize edilebilmektedir. Kullanılan yöntemlere göre kümeleme algoritmaları hiyerarşik yöntemler (hierarchical methods), bölünmeli yöntemler (partitional methods), yoğunluk tabanlı yöntemler (density based methods), ızgara tabanlı yöntemler (grid based methods), model tabanlı yöntemler (model based methods), bölge tabanlı kümeleme algoritmaları olarak beş gruba ayrılmaktadır (Halkidi ve ark., 2001, Hañçer, 2016). Özelliklerine göre ve literatürdeki kullanım sıklığına göre ise temelde hiyerarşik ve bölünmeli yöntemler olarak iki grupta incelenmektedir (Hañçer, 2016; Purutçuođlu ve Ayyıldız, 2014). Bu çalışmada hiyerarşik ve bölünmeli yöntemler incelenmiştir. Kullanım sıklığı, basit ve etkili olması ve hiyerarşik yöntemlere göre daha geniş kullanım alanına sahip olması nedeniyle bölünmeli yöntemler üzerinde durulmuştur.

2.5.1. Hiyerarşik yöntemler

Aşama sıralamalı kümeleme yöntemleri olarakta isimlendirilen hiyerarşik yöntemler, kümeler arasındaki hiyerarşik yapıyı ağaç şeklinde bir yapı oluşturarak göstermektedir (Wang, 2010; Purutçuođlu ve Ayyıldız, 2014). Kümeler arasındaki ilişkiyi ağaç şeklindeki yapı ile gösteren bu gösterime de dendrogram denilmektedir. Hiyerarşik yöntemlerde küme sayısının önceden belirlenmesi gerekmemektedir. Ancak hiyerarşik yöntemlerde oluşturulması gereken ağaç yapısı işleminde, bu işlemin durdurulması için bir eşik parametresi kullanılmaktadır. Hiyerarşik kümeleme yöntemleri de bölücü (Divisive) yöntemler ve gruplayıcı veya birleştirici (Agglomerative) yöntemler olarak ikiye ayrılmaktadır (Wang, 2010). Bu yöntemlerden gruplayıcı yöntemler, bölücü yöntemlere göre matematiksel olarak daha karmaşık ve kompleks yöntemlerdir. Bu nedenle de bölücü yöntemler daha hızlı çalışmaktadır. Gruplayıcı yöntemler, ayrı ayrı bir küme olarak ele alınan tüm veri elemanları, aşamalı olarak birbirine en yakın veya benzer olanları birleştirerek bir küme şeklinde gruplandırılmasını sağlar ve işlem bu şekilde devam eder. Bölücü yöntemler ise teorik olarak tüm küme elemanları başlangıçta tek bir kümeye toplanarak kümelerin bir ana küme olarak ele alınması ve aşamalı olarak alt kümelere ayrılmasını sağlar. Hiyerarşik yöntemlerdeki ayrı ayrı ele alınan kümeleri birleştirme veya ana kümeyi alt kümelere parçalama işlemleri benzerlik metriklerine göre gerçekleştirilmektedir. Bu benzerlik metrikleri; tek

bağlantı (single linkage), merkezi bağlantı (centroid linkage), ortalama bağlantı (average linkage) ve tam bağlantı (complete linkage) metrikleridir (Purutçuoğlu ve Ayyıldız, 2014; Hançer, 2016). Bu metriklerden en çok kullanılan yöntemler; en yakın komşu yöntemi olarakta isimlendirilen tek bağlantı yöntemi ve en uzak komşu yöntemi olarakta isimlendirilen tam bağlantı yöntemidir. Bu yöntemler isimlerinden de anlaşılacağı üzere tek bağlantı yönteminde, ayrı ayrı ele alınan iki kümenin elemanları arasında birbirine en yakın olan elemanların uzaklığı baz alınarak iki kümenin birbirine olan uzaklığı belirlenir. Tam bağlantı yönteminde ise ayrı ayrı ele alınan iki farklı kümenin elemanları arasında birbirine en uzak olan elemanların uzaklığı baz alınarak iki kümenin birbirine olan uzaklığı belirlenir (Özkan, 2008; Hançer, 2016).


2.5.2. Bölünmeli yöntemler

Bölünmeli yöntemler, hiyerarşik yöntemlerin tersine verinin kaç kümeye ayrılacağı bilgisinin önceden belirlenmesi gerekmektedir. Dolayısıyla bu yöntem, teorik olarak n sayıda elemandan oluşan bir veri kümesini (görüntü için piksel değerleri ifade eder) önceden belirlenen k sayıda kümeye ayırmaktadır. Bu kümelerdeki elemanlar arası benzerlik değerleri maksimum, fakat kümeler arasındaki benzerlik değerleri de minimum olması gerekmektedir. Bu benzerlik değerlerini hesaplamak için uzaklık ölçüleri kullanılmaktadır (Demiralay, 2005). Bölünmeli kümeleme yöntemleri k -ortalamalar (k -means) algoritması, k -medoid algoritması, fuzzy c -mean (FCM) algoritması ve k -ortalamalar algoritmasının geliştirilmiş versiyonlarıdır. Bu algoritmalar k -ortalamalar algoritması ve k -ortalamalar algoritmasının geliştirilmiş versiyonları, birçok bölütleme yöntemleri arasında ve kümeleme yöntemleri içinde en popüler olan ve en sık kullanılan tekniklerden biri olarak kabul edilmektedir (Ayeche ve Ziou, 2015).

2.5.2.1. Uzaklık ölçüleri

Görüntü bölütlemeye kullanılan kümeleme yöntemlerin birçoğunda bir görüntüdeki piksellerin arasındaki uzaklıklar hesaplanarak farklı kümelere atanır ve böylece görüntü kümelere ayrılarak bölütlenme işlemi gerçekleşir. Pikseller arasındaki

uzaklıkların veya benzerlik değerlerinin hesaplanması için genellikle Öklid (Euclidean) uzaklığı, Minkowski uzaklığı, Manhattan uzaklığı ve Mahalonobis uzaklığı kullanılmaktadır (Demiralay, 2005). Bu uzaklıklar içinde, küme elemanları ve kümeler arasındaki uzaklıkları hesaplamada en çok tercih edilen uzaklık ölçüsü, Öklid uzaklığıdır. (Lin ve ark., 2014; Ism Khan, 2018). Öklit uzaklığını aşağıdaki şekilde (Şekil 2.12.) gösterildiği gibi iki boyutlu bir uzayda değerlendirildiğinde Denklem 2.24'teki formül kullanılarak bu işlem gerçekleştirilir.



Şekil 2.12. İki boyutlu uzayda P ve Q arasındaki d uzaklığı

Şekil 2.12.'de P (x_1, y_1) ve Q (x_2, y_2) iki boyutlu uzayda iki noktanın koordinatları, d P ve Q noktaları arasındaki uzaklığı temsil etmektedir. Şekil 2.12.'ye bakıldığında bir Pisagor teoreminin gösterimi olduğu görülmektedir. Pisagor teoremine göre d noktası Denklem 2.23'teki gibi hesaplanmaktadır (Özkan, 2008; Howard ve Rorres, 2014).

$$d^2 = a^2 + b^2 \text{ ise } \|d\| = \sqrt{a^2 + b^2} \quad (2.23)$$

Bu denklemi iki boyutlu uzaydaki noktalar için düzenlenirse Denklem 2.24, üç boyutlu uzaydaki noktalar için ise Denklem 2.25 elde edilir.

$$d(P, Q) = \|P, Q\| = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (2.24)$$

$$d(P, Q) = \|P, Q\| = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + \dots + (z_n - z_n)^2} \quad (2.25)$$

Bu denklemler Öklid n uzayında ifade edilecek olursa, $P=(P_1,P_2,\dots,P_n)$ ve $Q=(Q_1,Q_2,\dots,Q_n)$ olduğunda $d(P,Q)$ ise P ve Q noktaları arasındaki uzaklığı ifade etmektedir ve Denklem 2.26'daki gibi genelleştirilmektedir.

$$d(P, Q) = \|P, Q\| = \sqrt{\sum_{t=1}^n (P_t - Q_t)^2} \quad (2.26)$$

Denklem 2.25'te $P=(P_1,P_2,\dots,P_n)$ ve $Q=(Q_1,Q_2,\dots,Q_n)$ olduğunda $d(P,Q)$ ise P ve Q noktaları arasındaki uzaklığı ifade etmektedir.

Renkli görüntülerdeki renkleri tanımlamak için RGB (Red-Kırmızı, Green-Yeşil, Blue-Mavi), CMY (Cyan-Camgöbeği, Magenta-Eflatun, Yellow-Sarı), HSB (Hue-Ton, Saturation-Doygunluk, Brightness-Parlaklık), ve HSI (Huge, Saturation, Intensity-Işık şiddeti) gibi farklı renk modelleri kullanılmaktadır. Bu renk modelleri renklerin standart, genel kabul görmüş bir şekilde tanımlanmasını kolaylaştırmaktadır. Temel olarak, renk modelleri her bir rengin tek bir noktayla temsil edildiği bir koordinat sistemidir ve üç boyutlu olarak gösterilmektedir (Cirillo ve ark., 2019). Bu renk modelleri ile temsil edilen görüntüler kümeleme tabanlı görüntü bölütleme yöntemleri ile bölütlenmek istendiğinde, pikseli ifade eden renk üç boyutlu uzayda temsil edilmiş bir nokta gibi düşünülmektedir. Buna göre, benzerlik değerini hesaplamak için Denklem 2.25 veya bu denklemin genelleştirilmiş hali olan Denklem 2.26'daki Öklid uzaklığı kullanılmaktadır.

İki farklı noktayı temsil eden $P=(P_1,P_2,\dots,P_n)$ ve $Q=(Q_1,Q_2,\dots,Q_n)$ noktaları için, L_p olarak adlandırılan Minkowski uzaklığı Denklem 2.27 ile tanımlanmaktadır. Minkowski uzaklığı p özel durumlarını da içeren genelleştirilmiş bir metriktir. $p=1$ olması durumunda Denklem 2.27 Manhattan uzaklığını, $p=2$ olması durumunda ise Denklem 2.29 Öklid uzaklığını göstermektedir. $p=\infty$ olması durumunda da Denklem 2.30 L_∞ olarak isimlendirilen Chebyshev uzaklığını ifade etmektedir. Bu denklemlerde p sıfırdan büyük sayılardan olmalıdır (Arora ve ark., 2019).

$$d(P, Q) = \left(\sum_{t=1}^n |P_t - Q_t|^p \right)^{\frac{1}{p}} \quad (2.27)$$


$$p = 1, \quad d(P, Q) = \sum_{t=1}^n |P_t - Q_t| \quad (2.28)$$

$$p = 2, \quad d(P, Q) = \sqrt{\sum_{t=1}^n |P_t - Q_t|^2} \quad (2.29)$$

$$p = \infty, \quad d_{\infty}(P, Q) = \max_{t=1}^n |P_t - Q_t| \quad (2.30)$$

Mahalanobis uzaklığı (Mahalanobis, 1936) Prasanta Chandra Mahalanobis tarafından 1936 yılında önerilmiştir. Gözlemlerin sınıflandırılması ve çok boyutlu istatistiksel analizde kullanılmaktadır. Dağılım ile verilen bir nokta arasındaki mesafenin ölçüsü şeklinde tanımlanır ve kovaryans matrisini hesaba katılarak işlem yapmaktadır. Buna göre P ve Q noktaları (vektörleri) arasındaki Mahalanobis uzaklığı S kovaryans matrisini kullanılarak Denklem 2.31'e göre hesaplanmaktadır (De Maesschalck ve ark., 2000).

$$d = \sqrt{(P - Q)^T S^{-1} (P - Q)} \quad (2.31)$$



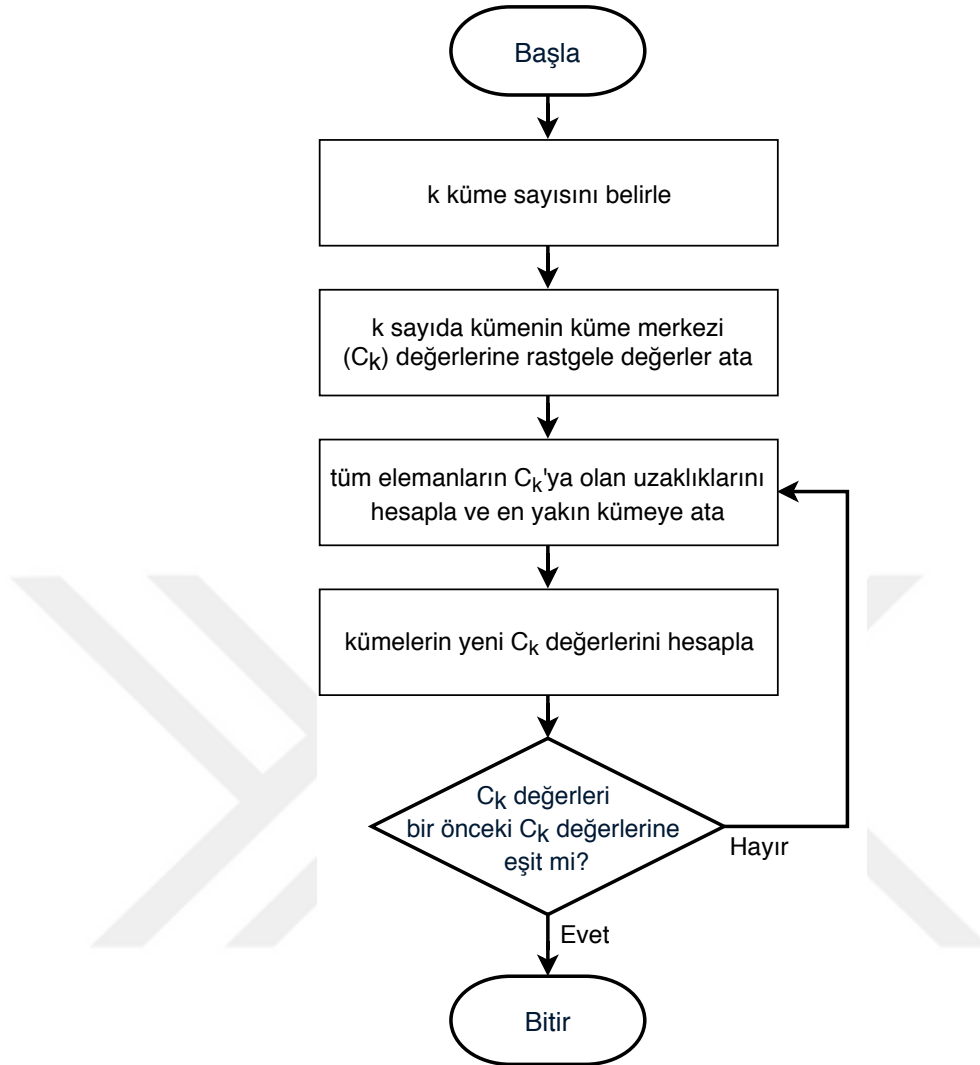
Şekil 2.13. Uzaklık ölçüleri iki boyutlu gösterimi: (a) Öklid, (b) Manhattan, (c) Chebyshev, (d) Mahalanobis

Denklem 2.23 ve Denklem 2.31 arasındaki denklemler ile tanımlanmış olan Öklid, Manhattan, Chebyshev ve Mahalanobis uzaklıklarını temsil eden iki boyutlu gösterimleri Şekil 2.13.'te verilmiştir.

2.5.2.2. K-ortalamlar kümeleme algoritması

K-ortalamlar (MacQueen, 1967) kümeleme algoritması 1967 yılında MacQueen tarafından önerilmiştir. K-ortalamlar algoritması uygulamasının çok basit olması, sadeliği, etkinliği ve farklı problemlerde istikrarlı performansının olması gibi nedenlerden dolayı çok tercih edilen bir algoritma olmaya devam etmektedir. Birçok durumda k-ortalamlar algoritmasından daha iyi sonuçlar veren kümeleme algoritmaları bulunsada lokal ince ayarlama kabiliyetinin çok etkili olması nedeniyle çok daha iyi algoritmaların bir parçası olarak kullanılmaktadır (Fränti ve Sieranoja, 2019). Diğer bir taraftan, k-ortalamlar algoritması farklı uygulamalarda da geniş çapta kullanılmaktadır. Özellikle tıbbi görüntülerin bölütlenmesinde çok tercih edilmektedir. Bunun yanında k-ortalamlar algoritmasının performansını daha da geliştirmek için farklı çalışmalar da yapılmaktadır (Zhaoa ve ark., 2018).

K-ortalamlar (K-means) gibi geleneksel kümeleme tekniklerinde, küme sayısı önceden belirlenmiş olması gereklidir. Ayrıca, ilk küme merkezi değerleri bilinmemektedir ve bu nedenle ilk küme merkezlerine rasgele değerler atanmaktadır. Bu nedenle k-ortalamlar algoritması kümeleme sayısının önceden bilinebildiği problemler için çok kullanışlı tekniklerden biridir. K-ortalamlar kümeleme algoritmasının adımları Şekil 2.14.'te gösterildiği şekilde işlemektedir.



Şekil 2.14. K-ortalamlar algoritmasının akış şeması

Şekil 2.14.'te gösterildiği üzere, k-ortalamlar algoritmasına göre kümeleme yapmak için gereken işlem basamaklarının detayları;

1.Basamak: Öncelikle veri elemanlarının (görüntü için piksellerin) kaç kümeye ayrılacağı belirlenir. Başka bir deyişle k küme sayısı belirlenir.

2.Basamak: Her küme için bir küme merkezi (C_k) (centroid) değeri belirlenir. Bu küme merkezleri değerleri rasgele bir sayı olabileceği gibi, veri elemanları içinde rasgele seçilmiş elemanların değerleri de olabilir.

3.Basamak: Tüm veri elemanları ile rasgele belirlenmiş olan küme merkez değerleri arasındaki uzaklık öklid uzaklık formülü kullanılarak hesaplanır. Elde edilen sonuçlara göre tüm veri elemanları kendisine en yakın olan küme merkezine atanır.

4.Basamak: Yeni küme elemanlarına sahip olan bu kümeler için küme merkez değerleri, küme içinde bulunan elemanlarının değerlerinin aritmetik ortalaması alınarak yeniden hesaplanır. Elde edilen yeni küme merkez değeri bir önceki küme merkez değeri ile karşılaştırılır.

5.Basamak: Eğer küme merkez değerleri bir önceki küme merkez değerleri ile aynı ise kümelerin değişmediği varsayılır ve işlem sonlandırılır. Eğer küme merkez değerleri değişmiş ise üçüncü basamaktan itibaren tüm basamak işlemleri tekrar edilir.

$X=\{X_1,X_2,\dots,X_n\}$ veri kümesini, k küme sayısını, $C=\{C_1,C_2,\dots,C_k\}$ küme merkezi değerlerini, m herbir küme içindeki küme elemanı sayısını, $C_{1..k}=\{Z_1,Z_2,\dots,Z_m\}$ küme merkezi içindeki elemanlarını ifade ediyor ise;

$$C_k = \frac{1}{m} \sum_{i=1}^m Z_i \quad (2.32)$$

$$d(C_k, X) = \|C_k, X\| = \sqrt{\sum_{i=1}^n (C_k - X_i)^2} \quad (2.33)$$

Buna göre, ilgili kümenin, küme merkez değerlerini hesaplamak için Denklem 2.32, tüm veri kümesi ile küme merkezleri arasındaki uzaklığı hesaplamak için Denklem 2.33 kullanılmaktadır.

2.5.2.3. Ağırlıklı k-ortalamlar kümeleme algoritması

K-ortalamlar algoritması çok farklı alanlarda uygulanmaktadır. Uygulanan bu alanların farklılıklarına göre de algoritmada farklı geliştirmeler yapılmaktadır.

Ağırlıklı k-ortalamlar algoritması (Albayrak ve Karşılıgil, 2001; Albayrak, 2001), görüntü üzerinde renk toplama ve bölütleme için kullanılabilen görüntü histogram bilgisini de algoritmaya dahil eden bir yöntemdir. Algoritma k-ortalamlar algoritmasının geliştirilmiş bir versiyonu olduğundan dolayı birçok algoritma basamağı, k-ortalamlar algoritması ile aynıdır.

Ağırlıklı k-ortalamlar algoritmasında a ve b renklerinin birbirine uzaklığını Denklem 2.34'teki gibi Öklid mesafesi ile hesaplanır. İki renk arasındaki mesafe hesaplanırken renkli görüntülerde, renk değerleri RGB olduğundan dolayı Denklem 2.34'te toplam ifadesi için i değeri 1, 2 ve 3 değerini almaktadır ve hesaplama buna göre yapılmaktadır.

$$d(a, b) = \sqrt{\sum_{i=1}^3 (a_i - b_i)^2} \quad (2.34)$$

Küme merkezi değerleri ise k-ortalamlar algoritmasından farklı olarak küme elemanlarının histogram bilgisi de kullanılarak Denklem 2.35'teki formül ile hesaplanmaktadır.

$$C_k = \frac{1}{\sum_{i=1}^m h_i} \sum_{i=1}^m h_i Z_i \quad (2.35)$$

Burada, $X = \{X_1, X_2, \dots, X_n\}$ veri kümesini, k küme sayısını, $C = \{C_1, C_2, \dots, C_k\}$ küme merkezi değerlerini, m herbir küme merkezindeki küme elemanı sayısını ve buna göre $C_{1..k} = \{Z_1, Z_2, \dots, Z_m\}$ küme merkezi içindeki elemanlarını, h_i ise Z_i renginin histogram değerini ifade etmektedir. Buna göre ağırlıklı k-ortalamlar algoritmasının işlem basamaklarının detayları;

1.Basamak ve 2.Basamak işlemleri bölüm 2.5.2.2.'de k-ortalamlar için belirtilen işlem basamakları ile aynı şekilde işletilmektedir.

3.Basamak: Tüm veri elemanları ile rasgele belirlenmiş olan küme merkez değerleri arasındaki uzaklık Denklem 2.34'teki formüle göre hesaplanır. Elde edilen sonuçlara göre tüm veri elemanları kendisine en yakın (formül sonucunda çıkan en küçük değer) olan küme merkezine atanır.

4.Basamak: Yeni küme elemanlarına sahip olan bu kümeler için küme merkez değerleri, küme içinde bulunan elemanlarının değerleri ve bu elemanların histogram bilgisi de formüle dahil edilerek Denklem 2.35'teki formül ile yeniden hesaplanır. Elde edilen yeni küme merkez değeri bir önceki küme merkez değeri ile karşılaştırılır.

5.Basamak: Eğer küme merkez değerleri bir önceki küme merkez değerleri ile aynı ise kümelerin değişmediği varsayılır ve işlem sonlandırılır. Eğer küme merkez değerleri değişmiş ise üçüncü basamaktan itibaren tüm basamak işlemleri tekrar edilir.

2.5.2.4. Geliştirilmiş yeni k-ortalamlar kümeleme algoritması

Bu çalışmada geliştirilmiş yeni k-ortalamlar kümeleme algoritmasında (Yurtsever ve ark., 2018), k-ortalamlar algoritmalarındaki gibi öncelikle küme sayısı belirlenmiştir ve buna göre $C=\{C_i, i=1,2,\dots,k\}$ şeklinde k sayıda küme oluşturulmuştur. Geleneksel k-ortalamlar kümeleme algoritması ve ağırlıklı k-ortalamlar kümeleme algoritmasında bu küme merkezlerine ilk değer, rasgele olarak atanmaktadır. Bu rasgele atanmasından dolayı benzersiz bir küme elde edilmesi her zaman mümkün değildir. Bu nedenle, ilk küme merkezlerinin belirlenmesi için kullanılan yöntem, elde edilecek son kümenin nasıl olacağı belirleyen önemli bir etkidir. Bu durumda sistemin performansı açısından önemlidir. Bu nedenle, geliştirilen bu yaklaşımda küme merkezlerine ilk değer atanması işlemi, aşağıda belirtilen denklemler (Denklem 2.36, Denklem 2.37) ile hesaplanarak gerçekleştirilmiştir. Bu denklemler belirlenirken kullanılan mikroskobik kolon tümör görüntülerinde hücre, çekirdek ve bez yapılarının farklı renklerde olduğu göz önüne alınarak birbirinden olabilecek maksimum uzaklıkta olacak şekilde ilk küme merkezlerinin belirlenmesine dikkat edilmiştir.

$$K_c = \frac{D_h}{k+1} \quad (2.36)$$

$$i = \{1, \dots, k\} \text{ için, } C_i = K_c i \quad (2.37)$$

Burada k küme sayısını, K_c küme merkezi oluşturma katsayısını, C_i küme merkezi değerini, D_h histogram boyutunu göstermektedir ve D_h değer olarak 256 verilmiştir. K_c küme merkezi oluşturma katsayısı küsüratlı çıkması durumunda tamsayı olan kısım K_c değeri olarak kabul edilecektir.

Denklem 2.36 ve Denklem 2.37’de belirtilen formüller ilk küme merkez değerleri rasgele olarak atanan k -ortalamlar ve geliştirilmiş tüm k -ortalamlar algoritmaları için uygulanabilmektedir. Bu yöntemde, ilk küme merkez değerlerinin atanmasından sonraki aşamalar, ağırlıklı k -ortalamlar kümeleme algoritmasının 2. maddesinden sonraki aşamalarının birebir uygulanması ile gerçekleştirilmektedir. Buna göre geliştirilmiş yeni k -ortalamlar algoritmasının işlem basamaklarının detayları aşağıdaki gibidir.

1.Basamak: Öncelikle veri elemanlarının (görüntü için piksellerin) kaç kümeye ayrılacağı başka bir deyişle k küme sayısı belirlenir.

2.Basamak: Her küme için bir ilk küme merkezi (C_k) (centroid) değeri belirlenir. Bu ilk küme merkezleri değerleri Denklem 2.36 ve Denklem 2.37 kullanılarak ilk küme merkezlerinin birbirinden optimum ayrıklıkta değer alması sağlanır.

3.Basamak: Tüm veri elemanları ile küme merkez değerleri arasındaki uzaklık Denklem 2.34’teki formüle göre hesaplanır. Elde edilen sonuçlara göre tüm veri elemanları kendisine en yakın (formül sonucunda çıkan en küçük değer) olan küme merkezine atanır.

4.Basamak ve 5.Basamak işlemleri bölüm 2.5.2.3.’te ağırlıklı k -ortalamlar için belirtilen işlem basamakları ile aynı şekilde işletilmektedir.

2.6. Histogram Tabanlı Benzerlik Fonksiyonu

Benzerlik fonksiyonları verilerin, histogram ikililerinin arasındaki benzerlik ölçüsünü hesaplayan fonksiyonlardır (Zweng ve ark., 2011). Renkli görüntü histogramlarının benzerlik değerlerini belirlemek için farklı mesafe ölçüm yöntemleri bulunmaktadır. Genel olarak, olasılık dağılımlarını karşılaştırmaya dayalı olan teknikler renkli histogramlar için uygun teknikler değildir. Bunun sebebi görsel algının benzerliği belirlemek üzerine olmasıdır. Olasılık dağılımlarının yakın olması bu benzerliği sağlamamaktadır. Renk mesafesi formülleri, renk içeriğinin algılanmasına dayanan görüntüler arasındaki benzerlik ölçüsüne göre işlem yapmaktadır (Jeong, 2001). Bu renk mesafesi yöntemleri histogram öklid mesafesi (histogram euclidean distance), histogram kesişimi mesafesi (histogram intersection distance) (Smith ve Chang, 1996) ve çapraz histogram mesafesi (histogram cross distance) yöntemleridir. Denklem 2.38'deki histogram tanımlamasına göre, histogram öklid mesafesi için Denklem 2.39, histogram kesişimi mesafesi için Denklem 2.40, histogram çapraz mesafesi için ise Denklem 2.41 kullanılarak benzerlik ölçümü hesaplanmaktadır. Bu fonksiyonlar içinde histogram çapraz mesafesi yöntemi, histogramdaki kutular arasında çapraz benzerliği hesapladığından Minkowski metriklerine kıyasla daha fazla hesaplama yükü getirmektedir (Kumar ve ark., 2009).

$$(r, g, b) = N \cdot \text{Prob}(R = r, G = g, B = b) \quad (2.38)$$

$$d(h, g) = \sqrt{\sum_R \sum_G \sum_B (h(r, g, b) - g(r, g, b))^2} \quad (2.39)$$

$$d(h, g) = \frac{\sum_R \sum_G \sum_B \min(h(r, g, b), g(r, g, b))}{\min(|h|, |g|)} \quad (2.40)$$

$$d(h, g) = (h - g)^T A (h - g) \quad (2.41)$$

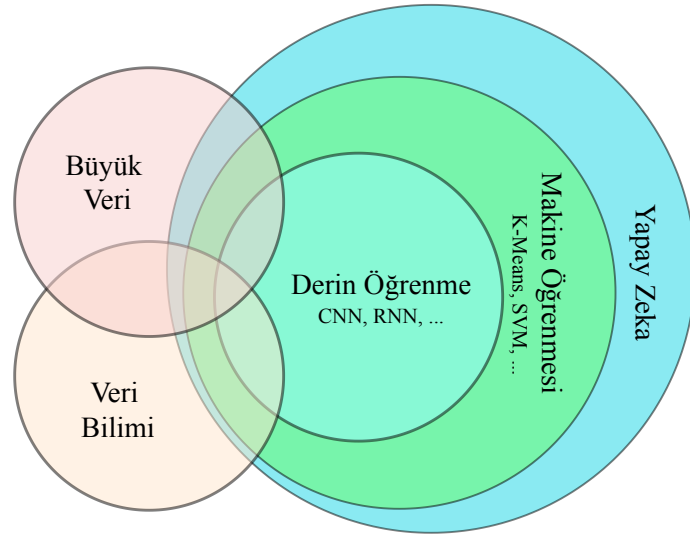
Burada h ve g farklı iki histogramı, R, G ve B üç farklı renk kanalını, $|h|$ ve $|g|$ örnek sayısına eşit her histogramın büyüklüğünü, N görüntü içindeki piksel sayısını, A ise benzerlik matrisini ifade etmektedir (Jeong, 2001).



BÖLÜM 3. DERİN ÖĞRENME

Derin öğrenme, her ne kadar son yıllarda popüler olmuş yeni bir konu olarak düşünülse de temelleri 1940 ile 1960'lı yıllar arasına kadar dayanmaktadır. Derin öğrenme ismi verilmeden önce, araştırmacılar çalışmalarında 1940-1960 yılları arasında sibernetik (cybernetics), 1980-1990 yılları arasında bağlantıcılık (connectionism) gibi farklı isimler kullanmıştır. Bu nedenle günümüzde derin öğrenme yeni bir konu gibi popüler olmuştur. Yapay sinir ağları (YSA) da geçmiş tarihte derin öğrenme yerine verilmiş isimlerden biri olarak tanımlanmaktadır. YSA gibi birçok erken öğrenme algoritması biyolojik öğrenme modelleri olarak geliştirilmiştir. Bu tip modeller biyolojik yöntemler olmasından dolayı, bu modellerin temel amacı öğrenmenin nasıl gerçekleştiğini belirleyip buna göre öğrenmeyi modellemektir (Goodfellow ve ark., 2018).

Zaman içinde farklı isimlerle tanımlanmış olan derin öğrenme, YSA ve benzeri makine öğrenme algoritmalarını kapsayan özel bir makine öğrenmesi türü olarak tanımlanmaktadır. Derin öğrenme konusunun tam olarak anlaşılması için öncelikle yapay zeka, makine öğrenmesi kavramlarının tam olarak neyi ifade ettiğini, bu alanların birbiriyle ve derin öğrenme ile olan ilişkilerini ve tarihsel süreçleri ortaya koymak gerekmektedir. Yapay zeka, makine öğrenmesi, derin öğrenme, büyük veri ve veri bilimi arasındaki ilişki ve kapsamı Şekil 3.1.'de venn şemasıyla gösterilmiştir. Şekilde görüldüğü üzere yapay zeka bu terminolojinin en üst kapsayıcısıdır. Zaman içinde yapay zeka farklı alt çalışma alanlarına ayrılmıştır. Bu alt alanlardan biri olan makine öğrenmesi de şekilde yapay zekanın bir alt kolu olarak gösterilmiştir. Son yıllarda popüler olan derin öğrenme ise makine öğrenmesi tekniklerinden biridir ve bu nedenle şekil üzerinde makine öğrenmesi kapsamı içinde gösterilmiştir.



Şekil 3.1. Yapay zeka, makine öğrenmesi, derin öğrenme ve veri arasındaki ilişkiyi gösteren venn şeması

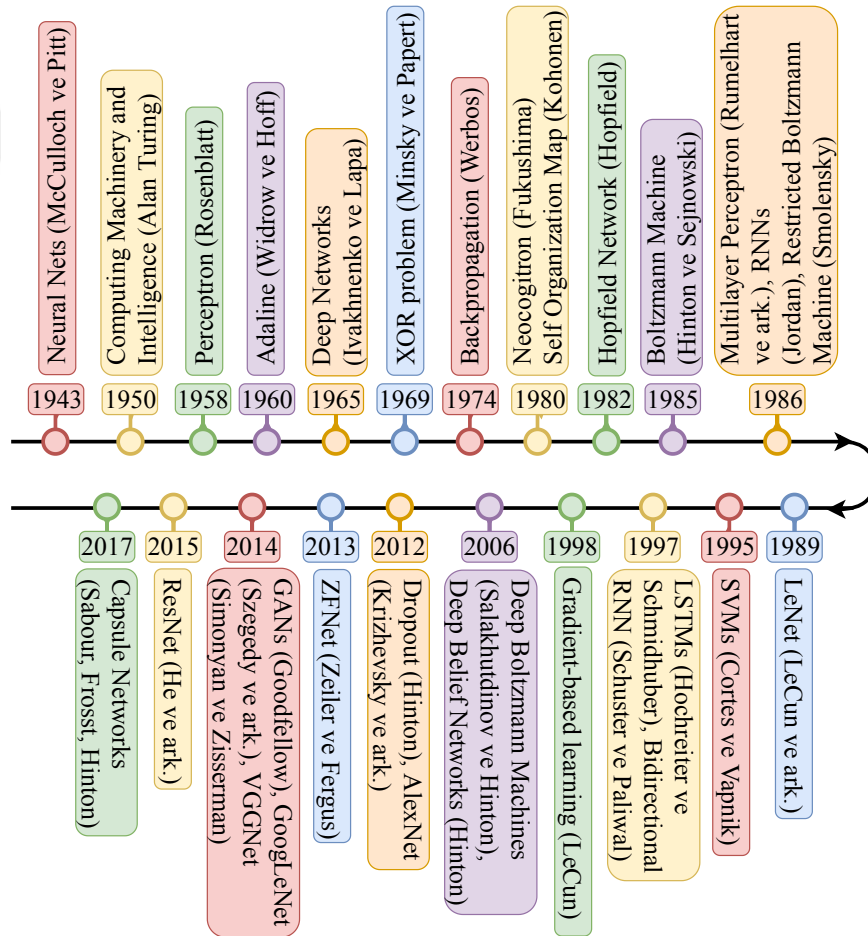
İnsanlar için çözmesi zor olan matematiksel problemler, yapay zekanın ortaya çıktığı ilk dönemlerden itibaren bilgisayarlarla kolaylıkla çözülebiliyordu. Fakat insanların günlük hayatta kolaylıkla gerçekleştirdiği ve rutin olan görüntülerin, seslerin, nesnelerin tanınması ve sınıflandırılması gibi olayların, bilgisayarlar için matematiksel olarak tanımlanması ve çözülmesi zor olan problemler olduğu ortaya çıkmıştır (Goodfellow ve ark., 2018). Böylelikle daha sonraki dönemlerde yapay zeka, insanların düşünme ve öğrenme şekli, biyolojik yapısı, canlıların davranış şekilleri gibi canlıya ait olan özellikleri modelleyen ve hatta daha iyi bir şekilde başarımlar elde etmeye çalışan algoritmalar geliştirilmeye evrilmiştir.

1943'lü yıllarda Alan Turing tarafından "Makineler Düşünebilir mi?" sorusuyla ortaya atılan fikir, 1950 yılında yazdığı bir makalede de (Turing, 1950) irdelenmiştir. Ayrıca Alan Turing 1950'li yıllarda önermiş olduğu Turing Testi ile zeki makine veya yapay zekanın nasıl olması gerektiğini de ortaya koymuştur. Bu testte insanın veya sorgulayıcının bir etkileşim ile karşılaştığı durumlarda, bu etkileşimin arkasında insan veya makine olduğunu ayırt edip edememesine bakılmaktadır. Eğer etkileşim arkasındakinin makine olduğu anlaşılıyorsa o zaman o makine için zeki makine denilmektedir. Buradan yola çıkarak yapay zeka, makinelerin gerçek bir insan gibi tepki vermesi şeklinde tanımlanması yapılmaktadır. Yapay zeka terim olarak ise 1955 yılında John McCarthy tarafından İngiltere'de Dartmouth College'da yapılan bir konferansta önerilmiş ve tanımlanmıştır. Geniş bir kapsama alanına sahip olan ve bu

terminolojinin en üst kapsayıcısı olan yapay zeka, yıllar içinde daha spesifik sorunlara çözüm bulmak amacıyla alt çalışma alanlarına ayrılmış ve robotik (robotics), doğal dil işleme (natural language processing), olay işleme (event processing), tahmini bilgi yönetimi (predictive knowledge management), deterministik kurallar & süreçler & kararlar (deterministic rules & processes & decisions) ve makine öğrenmesi (machine learning) gibi yeni alt alanlar oluşturmuştur (MarTech, 2019). Bu alt alanlardan makine öğrenmesi terimindeki öğrenme kavramı, insanın doğasında var olan öğrenme ile aynı özellikleri taşımaktadır. İnsanlar öğrenme ile benzer görevleri yerine getirirken performanslarını iyileştirme eğiliminde olduğu bilinmektedir. Aynı mantıkla performanslarını arttırmak için makinelere de bu öğrenme ilkesinin eklenmesi ile makine öğrenmesi gerçekleşmektedir (Konar, 2000). Buna göre öğrenme problemi, bir görevi yerine getirirken, eğitim deneyimi yoluyla performans ölçütünü geliştirme sorunu olarak tanımlanmaktadır (Jordan ve Mitchell, 2015). Tanım olarak ise makine öğrenmesi, bilgisayarların algılayıcı verilerinden veya girdi/egitim verilerinden matematiksel ve istatistiksel yöntemler ile öğrenen, insan zekasının yapabileceklerini gerçekleştirebilen, elde edilen verilerden çıkarımlar yapan algoritmaların genel adı olarak ifade edilmektedir. Başka bir ifadeyle makine öğrenmesi, bilgisayarların karşılaştıkları olaylar veya problemler ile ilgili elde ettikleri verilerden bilgiler üreterek, bu bilgilerden ve tecrübelerden öğrenerek, benzer durumlar karşısında doğru kararlar verebilmesi ve çözümler üretebilmesi şeklinde tanımlanmaktadır (Öztemel, 2006). Makine öğrenmesindeki temel yaklaşım ise mevcut veri kümesi üzerinde makine öğrenmesi algoritması kullanılarak en başarılı ve en yüksek performans metrik değerlerini elde edebilen modelin kurulmasıdır. Bu nedenle farklı uygulama alanlarındaki farklı problemlerde en yüksek performans metrik sonucunu elde etmek için karar ağaçları, k-ortalamlar algoritması, basit bayes sınıflandırıcı, destek vektör makineleri (SVM), YSA gibi çok sayıda makine öğrenmesi algoritması geliştirilmiştir. Bu algoritmalar sınıflandırma, regresyon, kümeleme, boyut azaltımı, tahmin gibi yeteneklerine göre kategorize edilmektedir (Atalay ve Çelik, 2017). Makine öğrenmesi algoritmaları öğrenme yöntemlerine göre ise denetimli öğrenme (supervised learning), pekiştirmeli öğrenme (reinforced learning) ve denetimsiz öğrenme (unsupervised learning) olarak üçe ayrılmaktadır (Vasuki ve Govindaraju, 2017). Denetimli öğrenmede, girdilerin ve bu girdilere ait çıktılarının makineye

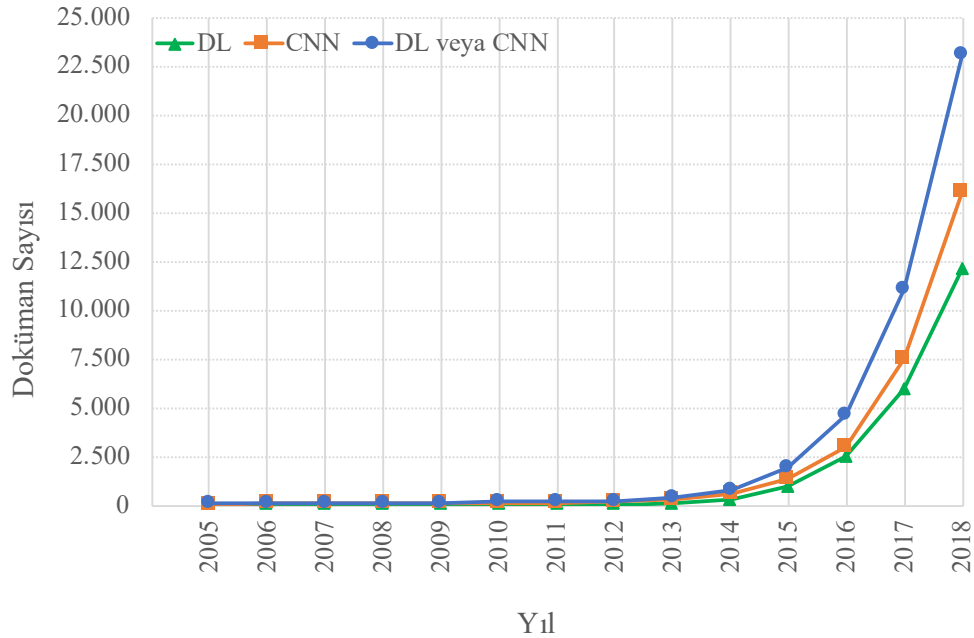
verilmesi sonucunda bu bilgilerden bir çıkarım yapılması ve veriler arasındaki ilişkinin öğrenilmesi amaçlanmaktadır. Denetimsiz öğrenmede, sadece girdiler makineye verilerek girdi verilerinden sonuçlar çıkarılması ve genel yapının modellenmesi amaçlanmaktadır. Pekiştirmeli öğrenmede ise eğitim verisi olmadan, etkileşimli bir şekilde, neden-sonuç ilişkisiyle, ödül-ceza yöntemiyle makinenin öğrenmesi ve karar vermesi amaçlanmaktadır (Konar, 2000).

Yapay zeka, makine öğrenmesi ve derin öğrenme tarihsel süreç içinde ilk olarak önerilmesi her ne kadar çok eski tarihlere dayandığı belirtilse de bu kavramların popüler oldukları dönem açısından genel kronolojik sıralamasına bakıldığında, 1950'li yıllar da yapay zeka, 1980'li yılların sonundan itibaren makine öğrenmesi, 2006'lı yıllardan itibaren de derin öğrenme popüler olmaya başlamıştır. Derin öğrenmenin tarihsel gelişimi gösteren kronolojik sıralaması ise Şekil 3.2.'de gösterilmiştir.



Şekil 3.2. Derin öğrenme kronoloji grafiği

Derin öğrenme, ses tanıma, yüz tanıma, görsel nesne tanıma, nesne algılama, biyoenformatik, doğal dil işleme, kanser, görüntü bölütleme, sınıflandırma alanlarındaki değişken işlevler gerektiren karmaşık sorunları ve çeşitli problemleri, derin sinir ağı algoritmalarını kullanarak çözmektedir (Lopez ve ark., 2017). Bu algoritmalarından en bilinen ve en çok kullanılan algoritmalarından biri olan ESA'nın temelleri ise 1989 yılında atılmaya başlanmıştır (LeCun ve ark., 1989). ESA, çok fazla eğitim verisine ve güçlü hesaplamalar için gerekli olan güçlü donanımlara ihtiyaç duymasından dolayı, 2012 yılına kadar bilgisayarlı görü (computer vision) alanında pek fazla ilgi görmemiştir. Farklı alanlarda çok büyük veri setlerinin elde edilebilmesi, büyük veri kavramının önem kazanması, algoritma verimliliğinin artması, GPU'ların gelişmesi, hesaplama maliyetlerinin azalması ile birlikte 2012 yılından itibaren ESA konusu büyük bir ilgi görmüş ve çok popüler olmuştur (Yurtsever ve Yurtsever, 2019). Böylelikle de birçok alanda kullanılmaya başlanmıştır. Socopus veritabanında Deep Learning (DL) ve Convolutional Neural Network (CNN) konusunda yapılan literatür çalışmalarının yıllara göre sayılarını gösteren Şekil 3.3.'teki grafik incelendiğinde de bu alandaki çalışmaların 2012 yılından itibaren büyük bir ivme kazandığı açıkça görülmektedir.



Şekil 3.3. Yıllara göre derin öğrenme ve evrişimli sinir ağlarının eğilim grafiği (Scopus Veritabanı)

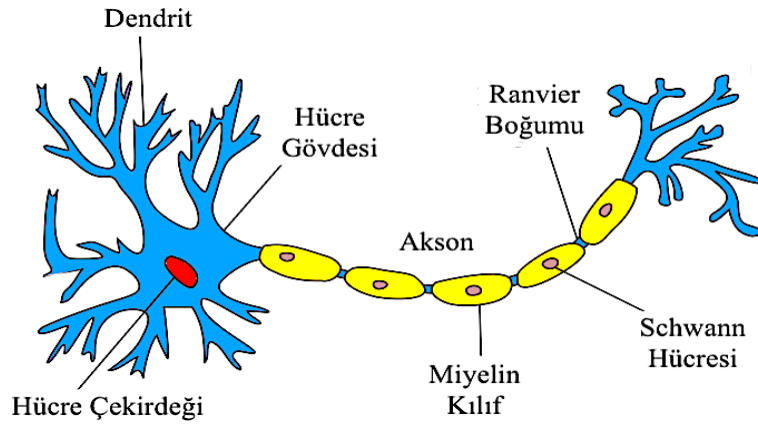
Özellikle Hinton's (Krizhevsky ve ark., 2012) takımı, bir çeşit YSA olan ESA kullanarak ImageNet görüntü sınıflandırmasında şampiyonluğu elde etmesinden sonra ESA bilgisayarlı görü alanında büyük ilgi görmeye başlamış ve diğer alanlarda da uygulanmaya başlanmıştır (Tang ve ark., 2012; Vallet, 2015, LeCun ve ark., 2015).

3.1. Yapay Sinir Ağları

YSA biyolojik sinir sistemini taklit ederek öğrenme, sınıflandırma, optimizasyon ve genelleme gibi insan beyninin fonksiyonel özelliklerine benzer işlemleri gerçekleştiren programlardır. YSA yapısal olarak insan sinir hücresine benzer şekilde yapay sinir hücreleri (nöronlar) ile çalışmaktadır. Bu sinir hücrelerinin milyarlarca bir araya gelerek sinir ağını oluşturmaktadır (Öztemel, 2006). Bu nedenle YSA'nın ve yapay sinir hücrelerinin tam olarak anlaşılması için öncelikle biyolojik sinir hücresi ve yapısı incelenmiştir.


3.1.1. Biyolojik sinir hücresi ve yapısı

İnsan sinir sistemi merkezi ve çevresel sinir sisteminden oluşmaktadır. (Öztemel, 2006). Vücudun duyu organlarından yani sensörlerinden alınan görme, işitme, tat, hissetme ve koku gibi bilgiler sinir sistemiyle beyine taşınmaktadır ve beyin oluşturduğu kararlar organlara iletilerek tepkiler oluşturulmaktadır. Bu yapı içindeki nöronlar kabaca bilgi girişi ve çıkışı olan bir anahtar ya da sinir sisteminin bilgi işleyen ve bilgi ileten bileşeni olarak tanımlanmaktadır (Haykin, 2009). Biyolojik sistemin yapı taşını oluşturan sinir hücresinin yapısı Şekil 3.4.'te gösterilmiştir. Şekil 3.4.'te gösterilen sinir hücresi, hücre çekirdeği, hücre gövdesi (soma), dendrit, aksondan oluşmaktadır. Akson dalının ucundaki düğme görünümlü yapılar ise diğer bir sinir hücresiyle sinaps oluşturmaktadır. Sinapslar veya sinir uçları da sinir hücreleri arasındaki elektriksel sinyallerin geçişini sağlayan boşlukları oluşturmaktadır. Sinir hücreleri arasında oluşan bu sinaptik iletişim ile sinyaller hücre gövdesine iletilmektedir. Bu elektriksel sinyal geçişi sonraki aşamada aksonlar yardımıyla dendritlere iletilmektedir (Gülbağ, 2006).



Şekil 3.4. Sinir hücresinin biyolojik gösterimi (Kriesel, 2007)

Bu sinir sisteminin çalışma şekli Şekil 3.5.'te üç aşamalı bir blok diyagramı ile gösterilmiştir. Bu blok diyagramına bakıldığında sistemin merkezinde sürekli bilgi alan, algılayan ve uygun kararlar alan sinir ağı ile temsil edilen beyin bulunmaktadır. Reseptörler, insan vücudundan veya dış ortamdaki gelen uyarıları, sinir ağına bilgi olarak ileten elektriksel darbelerle dönüştürmektedir. Etkiler ise sinir ağı tarafından üretilen elektriksel darbeleri, sistem çıkışları gibi tepkilere dönüştürmektedir. Bu blok diyagramında soldan sağa (kırmızı ok) doğru olan gösterim sinyallerin sistemden ileri iletimini, sağdan sola (mavi ok) doğru olan gösterim ise sistemdeki geri bildirimleri ifade etmektedir (Haykin, 2009).

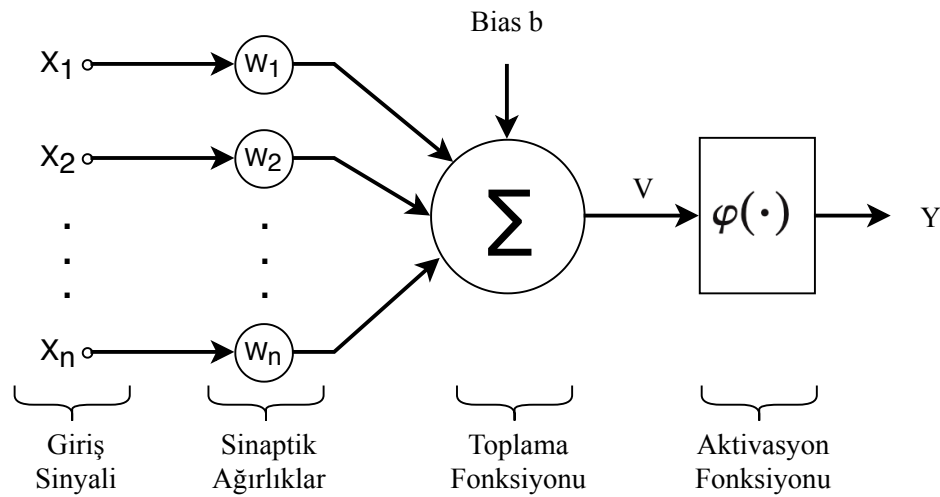


Şekil 3.5. Sinir sisteminin blok diyagramı olarak gösterimi (Haykin, 2009)

3.1.2. Yapay sinir hücresi ve yapısı

Yapay sinir hücreleri, biyolojik sinir hücrelerinin yapısını ve özelliklerini taklit ederek geliştirilmiş modellerdir. YSA içindeki bir nöron, sinir ağının çalışması için temel olan bilgi işlem birimidir. YSA'nın temelini oluşturan bu nöronun matematiksel gösterimi Şekil 3.6.'da verilmiştir. Buna göre biyolojik sinir sistemindeki nöron, dendrit, hücre gövdesi, aksonlar ve sinapların YSA matematiksel modelindeki karşılıkları sırasıyla işlem elemanı, toplama fonksiyonu, aktivasyon fonksiyonu, çıkış elemanı ve ağırlıklar şeklinde gösterilmiştir. Sinapslar veya nöron bağlantıları her biri kendine ait bir ağırlık

veya kuvvet ile karakterize edilmiştir. Toplama fonksiyonu, nöronun ilgili sinaptik kuvvetleri ile ağırlıklandırılmış giriş sinyallerini toplayan bir fonksiyondur. Aktivasyon fonksiyonu ise bir nöron çıkışının genliğini sınırlamak için oluşturulmuş bir fonksiyondur (Gülbağ, 2006; Öztemel, 2006; Haykin 2009).



Şekil 3.6. Sinir hücresinin matematiksel modeli

Şekil 3.6.'da gösterilen yapay sinir hücresi matematiksel olarak Denklem 3.1 ve Denklem 3.2 ile tanımlanmaktadır. Daha genel bir ifadeyle ise YSA'nın en küçük parçası olan perseptron (perceptron) $Y=X*W+b$ fonksiyonu ile ifade edilmektedir.

$$V = \sum_{j=1}^m w_j x_j + b \quad (3.1)$$

$$Y = \varphi(V) \quad (3.2)$$

Bu denklemlerde X bağımsız değişken ve girdiyi, W ağırlık parametresini, b bias değerini, V toplama fonksiyonu çıkışını ve Y ise X değerine bağlı olan bağımlı bir değişkeni ifade etmektedir.

Şekil 3.6.'da görüldüğü üzere bir yapay sinir hücresinin girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktısı olmak üzere 5 temel proses elemanı

bulunmaktadır. Girdiler, biyolojik sinir hücresinde duyu organlarından gelen sinyaller, bir yapay sinir hücresinde ise dış dünyadan gelen bilgilerdir. Ağırlıklar, bir yapay sinir hücresinde girdiler ile gelen bilginin önemini belirtmektedir. Toplama fonksiyonu, ağırlıklandırılmış girdileri toplayan bir fonksiyondur. Toplama fonksiyonu için Tablo 3.1.'de verilen farklı formüller kullanılabilir. Fakat genellikle toplama fonksiyonu olarak toplam formülü kullanılmaktadır (Öztemel, 2006).

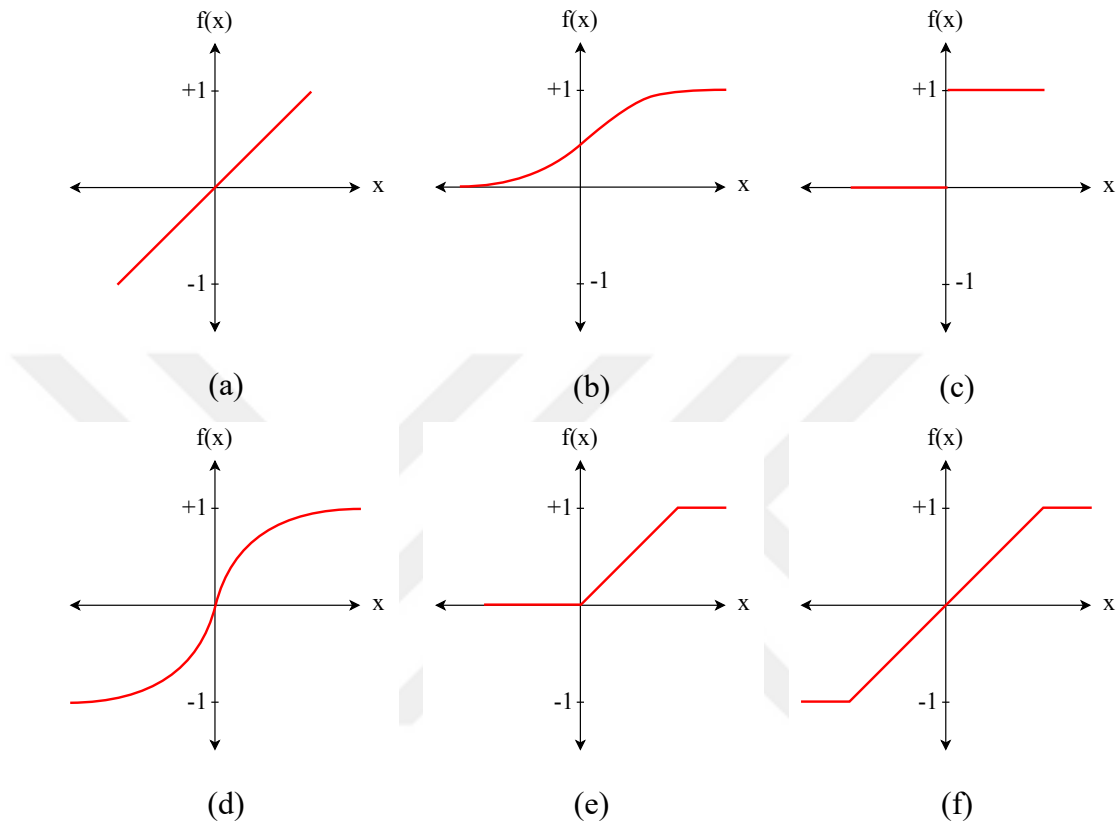
Tablo 3.1. Toplama fonksiyonları (Öztemel, 2006)

Toplam Fonksiyonu:	Yığılma Fonksiyonu:
$Net = \sum_{j=1}^m X_j W_j$	$Net = Net_{eski} + \sum_{j=1}^m X_j W_j$
Çoğunluk Fonksiyonu:	Çarpım Fonksiyonu:
$Net = \sum_{j=1}^m sgn(X_j W_j)$	$Net = \prod_{j=1}^m X_j W_j$
Minimum Fonksiyonu:	Maksimum Fonksiyonu:
$Net = Min(X_j W_j)$	$Net = Max(X_j W_j)$

Tablo 3.1.'deki toplama fonksiyonlarında j proses elemanını, m proses eleman sayısını, X girdi elemanını, W ağırlıkları ifade etmektedir.

Yapay sinir hücresinin diğer bir temel elemanı aktivasyon fonksiyonu veya başka bir ifadeyle etkinlik işlevidir. Toplama fonksiyonu sonucunda elde edilen NET değeri, aktivasyon fonksiyonu ile işlenerek sistem çıktısı hesaplanmaktadır. Bu hesaplamada aktivasyon fonksiyonunun eşik seviyesine göre işlem yapılmaktadır. YSA'daki bir sinir modeli, aktivasyon fonksiyonunun eşik seviyesinin altında bir çıkış üretememektedir. Aksine eşik seviyesinin üstünde bir çıkış üretmektedir (Elmas, 2016). Buna göre bir yapay sinir hücresinde aktivasyon fonksiyonu olarak basamak (step) fonksiyonu, doğrusal (linear) fonksiyon, sigmoid fonksiyonu, sinüs fonksiyonu, rampa fonksiyonu, eşik değer fonksiyonu ve hiperbolik tanjant fonksiyonu gibi fonksiyonlardan biri kullanılabilir. Şekil 3.7.'de örnek aktivasyon fonksiyonu grafikleri verilmiştir. Doğru aktivasyon fonksiyonunun seçilmesi YSA modelinin performansını doğrudan etkileyen önemli bir kriterdir. Bu nedenle, aktivasyon

fonksiyonlarından hangisinin YSA modelinde kullanılacağı, öğrenme modeline göre belirlenmektedir. Fakat literatürdeki çalışmalarda, özellikle çok katmanlı algılayıcı modelinde genel kullanım sigmoid fonksiyonudur.




Şekil 3.7. Örnek aktivasyon fonksiyonu grafikleri: (a) doğrusal fonksiyon, (b) sigmoid fonksiyonu, (c) basamak fonksiyonu, (d) hiperbolik tanjant fonksiyonu, (e) eşik değer fonksiyonu, (f) rampa fonksiyonu

Yapay sinir hücresinin son proses elemanı olan hücre çıktısı, aktivasyon fonksiyonu sonucunda üretilen çıktı değeridir. Her proses elemanının sadece bir çıktı değeri bulunmaktadır. Bu değer dış dünya veya diğer bir sinir hücresine gönderilebilmektedir (Öztemel, 2006; Elmas, 2016).

3.1.3. YSA'nın yapısı

Tek bir yapay nöronun gerçek dünya problemlerini çözmesi pek mümkün değildir. Fakat birden fazla yapay nöronun bir araya gelerek oluşturduğu YSA ise karmaşık gerçek dünya problemlerini çözebilmektedir. Çok sayıda yapay sinir hücresinden oluşmuş bir YSA, girdi katmanı, ara katman (gizli katman) ve çıktı katmanı olmak

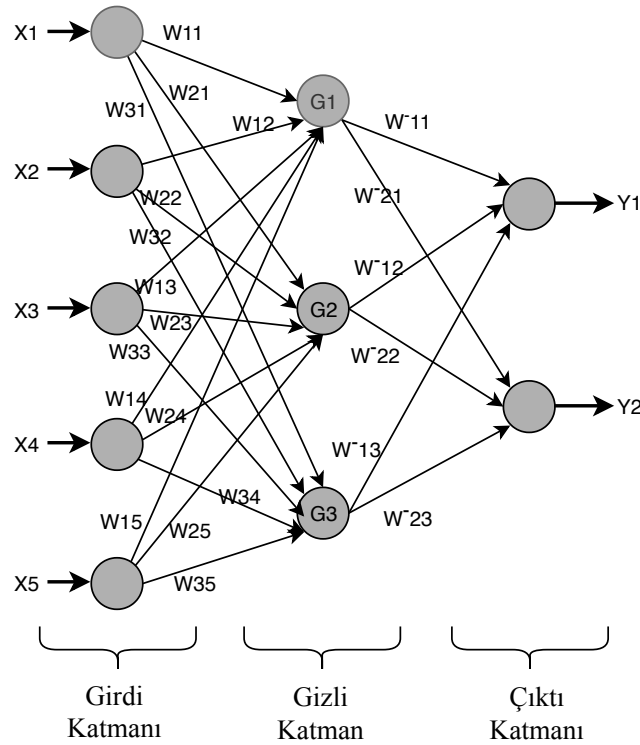
üzere üç temel katmandan oluşmaktadır (Andrej ve ark., 2011). Sadece girdi katmanı ve çıktı katmanından oluşan ve girdi katmanında hesaplama yapılmayan sinir ağları da bulunmaktadır. Şekil 3.8.'de tek katmanlı ileri beslemeli örnek bir ağ topolojisi görülmektedir. Bu şekilde giriş katmanında herhangi bir hesaplama yapılmayıp sadece çıkış katmanında hesaplama yapıldığından sinir ağı tek katmanlı olarak gösterilmiştir (Haykin, 2009).



Şekil 3.8. Tek katmanlı ileri beslemeli ağ topolojisi

Gerçek dünya problemlerini çözecek yapıdaki sinir ağlarında en az bir gizli katman bulunmaktadır. Gizli katman sayısı sistemin karmaşıklığına göre artırılabilir. Çok katmanlı ileri beslemeli bir ağ topolojisi Şekil 3.9.'da verilmiştir. Şekil 3.9.'da verilen bu ağ topolojisi bir giriş katmanı, bir gizli katman ve bir çıktı katmanı olmak üzere üç katmanlı bir yapıya sahiptir ve şekildeki oklar işlem elemanları arasındaki bağlantıyı ifade etmektedir. Çok katmanlı bir sinir ağındaki her katmanın kendine özel bir görevi vardır. Çok katmanlı sinir ağında girdi katmanı, dış dünyadan gelen giriş sinyallerini gizli katmandaki tüm nöronlara yeniden dağıtmaktır. Girdi katmanında girdi elemanı sayısı kadar nöron bulunmaktadır. Fakat genelde bu nöronlarda herhangi bir işlem gerçekleştirilmeden olduğu gibi diğer katmanlardaki nöronlara giriş bilgileri iletilmektedir. Gizli katmana ise girdi katmanından bilgiler gelmektedir ve gizli katmanda bu bilgiler proses edildikten sonra bir sonraki gizli katmana veya çıktı katmanına iletilmektedir. Bu katmanda bir gizli katman olacağı gibi birden fazla gizli katman da olabilmektedir. Ve bu katmanlardaki nöron sayısı da farklılık gösterebilmektedir. Gizli katmandaki katman sayısı ve her katmanda bulunacak nöron

sayısı problemin karmaşıklığına göre değişmektedir. Çıktı katmanı ise gizli katmandan gelen bilgileri proses ederek çıktı üretmektedir. Bu çıktılar girdilere karşılık olarak üretilmiş sonuçlardır (Negnevitsky, 2005; Haykin, 2009; Elmas 2016).



Şekil 3.9. Çok katmanlı ileri beslemeli ağ topolojisi

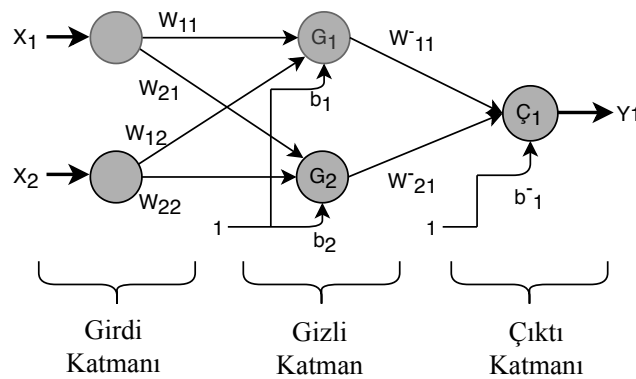
Bir sinir ağının nöronlarının topolojileri, yapılandırma şekilleri ile ağı eğitmek için kullanılan öğrenme algoritmaları arasında yakın bir ilişki bulunmaktadır (Haykin, 2009). Derin öğrenme'nin giriş bölümünde açıklandığı üzere makine öğrenmesi içinde öğrenme algoritmaları modeli etkileyen önemli bir kısımdır. Aynı şekilde makine öğrenmesi kapsamı içinde olan YSA' da öğrenme algoritmalarına göre üç kısma ayrılmaktadır. Bunlar; denetimli, denetimsiz ve pekiştirmeli öğrenmedir. Öğrenme kuralına göre de dört kısma ayrılmaktadır. Bunlar; Hopfield, Delta, Hebb ve Kohonen'dir (Gülbağ, 2006).

YSA'lar yapılarına, topolojilerine göre ileri beslemeli (feedforward) ağlar ve geri beslemeli (feedback) ağlar olmak üzere ikiye ayrılmaktadır. Şekil 3.9.'da verilen çok katmanlı algılayıcı ağ, ileri beslemeli bir ağ örneğidir. Şekilde de görüleceği üzere ileri beslemeli ağlarda, girdi katmanı, gizli katman ve çıktı katmanı şeklinde üç katmanlı

bir yapı bulunmaktadır ve ağın veri akışı girdi katmanından çıktı katmanına doğru ileri yönde olmaktadır. İleri beslemeli ağlar için tek katmanlı algılayıcı, çok katmanlı algılayıcı ve radyal temelli fonksiyon ağları örnek olarak verilmektedir. Geri beslemeli bir sinir ağında ise ileri beslemeli bir sinir ağında olduğu gibi üç katmanlı bir yapı olmaktadır. Bu tip ağlarda geri besleme döngüleri ile ileri beslemeli ağların aksine iki yönlü olarak bilgi akışı olmaktadır. Geri beslemeli ağlarda, bir nöronun çıktısı önceki veya sonraki katmanda bulunan bir nörona girdi olarak bağlanabildiği gibi kendi katmanındaki bir nörona da girdi olarak bağlanabilmektedir. Bu tip geri beslemeli ağlar için Hopfield, Kohonen SOM, ART Model, Rekabetçi Ağlar (Competitive Network) örnek olarak verilmektedir (Jain ve ark., 1996).

3.1.4. YSA'nın eğitilmesi

Bu bölümde bir YSA'nın eğitilmesi ve aşamaları çok katmanlı algılayıcılar üzerinden anlatılmıştır. Çok katmanlı algılayıcı ağların eğitilmesi mantık olarak diğer ağların eğitilmesinden farklı değildir.



Şekil 3.10. Örnek çok katmanlı ileri beslemeli YSA

Şekil 3.10.'da verilen girdi katmanında iki giriş, gizli katmanında iki nöron ve bir çıktı katmanı olan üç katmanlı ağ için gizli katman çıkışları Denklem 3.3 ve Denklem 3.4 ile hesaplanmaktadır.

$n=1,2,\dots,N$ ve $k=1,2,\dots,K$ olmak üzere gizli katman çıkışları;

$$G_k = f\left(\sum_{j=1}^m w_{kj}x_n + b_k\right) \quad (3.3)$$

$$G_1 = f(b_1 + (w_{11}x_1 + w_{12}x_2)) \text{ ve } G_2 = f(b_2 + (w_{21}x_1 + w_{22}x_2)) \quad (3.4)$$

Çıkış katmanı çıktısı, gizli katmandan gelen çıkış değerlerinin yine Denklem 3.3'te girdi olarak kullanılarak hesaplanmaktadır. Buna göre çıkış katmanı sinirinden üretilen çıktı Denklem 3.5'teki gibi hesaplanmaktadır.

$$\zeta_1 = f(b_1^- + (w_{11}^-G_1 + w_{12}^-G_2)) \quad (3.5)$$

Sonraki aşamada elde edilen çıkış değeri ile beklenen çıkış değeri karşılaştırılarak toplam maliyet (cost) fonksiyonunu hesaplanmaktadır. Maliyet fonksiyonu beklenen gerçek değer ile elde edilen değer arasındaki karesel farkların toplamı şeklinde Denklem 3.6'ya göre hesaplanmaktadır.

$$E = \frac{1}{2} \sum (Y - \zeta)^2 \quad (3.6)$$

Burada Y beklenen gerçek değeri, ζ ise elde edilen çıktı sonucunu ifade etmektedir.

Toplam hata büyük olduğu takdirde hatanın geriye yayılması gerekmektedir. Böylelikle ağda bulunan ağırlıkların güncellenmesi gerçekleştirilmiş olacaktır. Bu işlem ile beklenen gerçek çıktıya yaklaşılmaya çalışılmaktadır. Hatanın geri yayılımı (backpropagation) ile beklenen çıktı değerine yaklaşmak için ağdaki ağırlıkların güncellenmesi Denklem 3.7 ve Denklem 3.8 ile gerçekleştirilmektedir. Burada zincir kuralına göre işlem yapılmaktadır ve denklemler genelleştirilmiştir.

$$\frac{\partial E}{\partial w} = \frac{\partial E}{\partial N_{\zeta k}} * \frac{\partial N_{\zeta k}}{\partial N_{gir}} * \frac{\partial N_{gir}}{\partial w} \quad (3.7)$$


$$\Delta w(t + 1) = \Delta w(t) - \lambda * \frac{\partial E}{\partial w} \quad (3.8)$$

Burada E toplam hatayı, w ağırlığı, $N_{\text{çık}}$ katman sinirinde üretilen çıktıyı, N_{gir} katman sinirine gelen net girdiyi ve λ ise öğrenme katsayısını (learning rate) ifade etmektedir (Elmas, 2016; Gülbağ 2006; Öztemel, 2006). Ağırlıklara geri yayılım için uygulanan bu denklemler aynı şekilde bias içinde uygulanmaktadır.

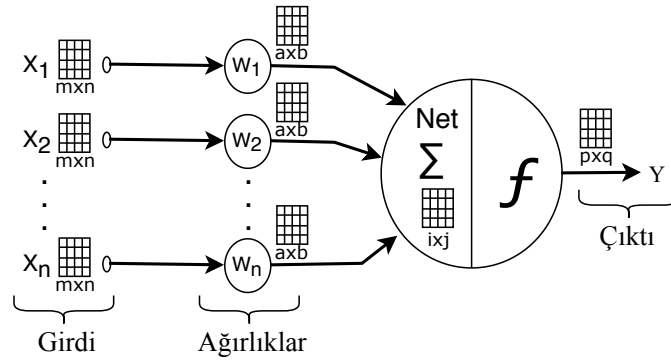
3.2. Evrişimli Sinir Ağları

Bir YSA türü olan ESA, genellikle görüntülerin analiz edilmesi için uygulanan, veri işlemek için kullanılan ve grid benzeri bir yapıya sahip olan derin ileri beslemeli özel bir sinir ağıdır. Başka bir ifadeyle katmanlarda matris çarpımı yerine evrişim ismi verilen matematiksel bir işlemi uygulayan sinir ağları olarak tanımlanmaktadır (Goodfellow ve ark., 2018). Günümüzde özellikle bilgisayarlı görü alanında yüksek başarımlar elde etmesinden dolayı sınıflandırma, nesne tanıma, doğal dil işleme gibi birçok alanda yaygın olarak kullanılmaktadır. Evrişimli sinir ağlarının ilk katmanlarında daha basit ve ilkel olan öznitelikler elde edilmektedir. Fakat katman sayısı arttıkça daha derin katmanlarda daha karmaşık öznitelikler elde edilmektedir. Bu karmaşık öznitelikler, görüntüyü daha iyi temsil eden özniteliklerdir (Kızrak ve Bolat, 2018).

İnsan görme sistemini model alan ESA, geleneksel sinir ağları ile karşılaştırıldığında, sayıl (scalar) veriler yerine matrisleri kullanmaktadırlar. Geleneksel bir düğüm Şekil 3.11.'de, bu düğüme karşılık gelen bir ESA düğümü ise Şekil 3.12.'de verilmiştir.




Şekil 3.11. Geleneksel bir sinir düğümü



Şekil 3.12. ESA sinir düğümü (Mercan, 2015)

Şekil 3.12.'de görüldüğü üzere ESA sinir ağı, geleneksel sinir ağından farklı olarak matris kullanmaktadır ve tüm işlemler matris üzerinden gerçekleşmektedir. Matris kullanmanın temel amacı ise yerel algı alanı (receptive field) şeklinde çalışmalarını ve yerel uzaysal komşulukları korumasıdır (Mercan, 2015). Geleneksel bir ESA, girdi ve çıktı katmanı dışında evrişim katmanı (convolution layer), havuzlama katmanı (pooling layer) ve tam bağlantı katmanı (fully connected layer) olmak üzere 3 katmandan oluşmaktadır. Temel bir ESA modeli Şekil 3.13.'te gösterilmiştir.



Şekil 3.13. Temel bir ESA modeli (Kızrak ve Bolat, 2018)

3.2.1. Evrişim katmanı

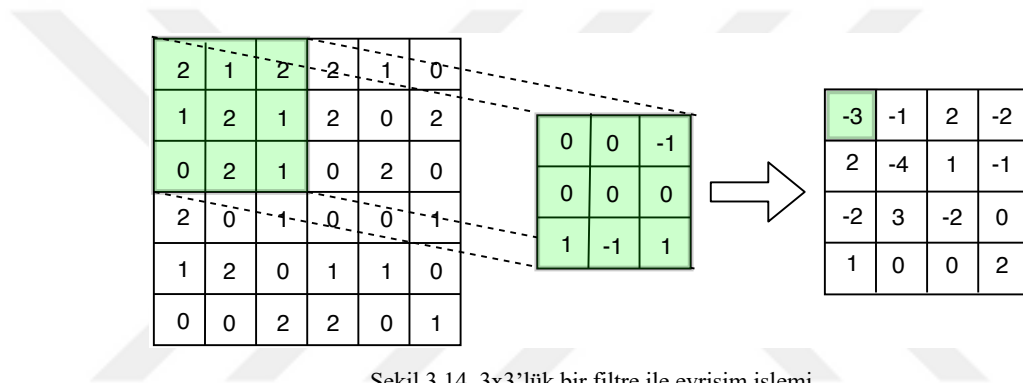
Bu katmanda evrişim işlemleri filtreler ile giriş görüntüsünü matris olarak boyutlarına göre tarayarak gerçekleştirilmektedir. Evrişim işleminde x eksenine ve y eksenine göre döndürülmüş filtre kullanılmaktadır. Filtrede herhangi bir döndürme işlemi yapılmadan kullanıldığı durumlara da çapraz korelasyon (cross correlation) işlemi denilmektedir (Kızrak ve Bolat, 2018; Ng ve ark., 2017). Denklem 3.9'da evrişim

işlemi formüle edilmiş, Denklem 3.10'da çapraz korelasyon işlemi formüle edilmiştir (Goodfellow ve ark., 2018). Şekil 3.14.'te ise bir evrişim işlemi gösterilmiştir.

$$S(i, j) = (I * F)(i, j) = \sum_m \sum_n I(m, n)F(i - m, j - n) \quad (3.9)$$

$$S(i, j) = (F * I)(i, j) = \sum_m \sum_n I(i + m, j + n)F(m, n) \quad (3.10)$$

Burada I giriş görüntüsünü F filtreyi ifade etmektedir.



Şekil 3.14. 3x3'lük bir filtre ile evrişim işlemi

Şekil 3.14.'te 3x3 lük bir filtre kullanılmıştır ve 6x6 olan bir görüntüyü tarayarak evrişim işlemi gerçekleştirilmiştir. Şekil üzerinde yeşil renkli olan matrisler üst üste olacak şekilde getirilmiş, karşılıklı gelen elemanlar çarpılmış, elde edilen sonuçlar toplanmıştır ve elde edilen değerler çıkış matrisinin elemanı olarak atanmıştır. Bu şekilde 6x6'lık görüntü taranmış ve 4x4'lük bir çıkış matrisi elde edilmiştir. Çıkış matrisinin ilk elemanının hesaplama adımları Denklem 3.11'de gösterilmiştir. Diğer elemanları da aynı yöntemle hesaplanmıştır.

$$Y = \begin{bmatrix} 2 & 1 & 2 \\ 1 & 2 & 1 \\ 0 & 2 & 1 \end{bmatrix} * \begin{bmatrix} 0 & 0 & -1 \\ 0 & 0 & 0 \\ 1 & -1 & 1 \end{bmatrix}$$

$$Y = \begin{bmatrix} (2x0) & (1x0) & (2x-1) \\ (1x0) & (2x0) & (1x0) \\ (0x1) & (2x-1) & (1x1) \end{bmatrix} = \begin{bmatrix} 0 & 0 & -2 \\ 0 & 0 & 0 \\ 0 & -2 & 1 \end{bmatrix} \quad (3.11)$$

$$Y = 0 + 0 + (-2) + 0 + 0 + 0 + 0 + (-2) + 1 = -3$$

Şekil 3.14.'te gösterilen evrişim işlemi iki boyutlu matris için gerçekleştirilmiştir. Kırmızı, yeşil ve mavi (RGB) olmak üzere üç kanaldan oluşan renkli görüntülerde evrişim işlemi üç kanal için ayrı ayrı yapılmaktadır. Ayrıca filtre sayısı ve giriş kanal sayısı aynı olmaktadır. Giriş görüntülerini taramak işleminde kullanılan filtreler geri yayılım ile güncellenen ağırlık matrisleri olmaktadır. Ayrıca aktivasyon fonksiyonu, çıkış matrisine uygulanmadan önce bir bias değeri de eklenmektedir (Kızrak ve Bolat, 2018). Evrişim işlemlerinde kullanılan filtrelerin boyutları genellikle tek sayıdan oluşmaktadır. Bu filtrenin bir merkezinin olması ve simetrik bir dolgulama (padding) işleminin yapılmasını sağlamaktadır (Ng ve ark., 2017).

Şekil 3.14.'te uygulanan evrişim işleminde giriş ve çıkış matrisleri arasında boyut olarak farklılık olduğu görülmektedir. Kaydırma adım sayısı (stride) 1 olan 6×6 ($n \times n$)'lık bir görüntü matrisine 3×3 ($f \times f$)'lük bir filtre uygulanması sonucunda 4×4 ($m \times m$)'lük bir çıkış matrisi elde edilmiştir. Çıkış görüntüsünün boyutu Denklem 3.12'ye göre hesaplanmıştır.

$$m = \frac{(n - f)}{s} + 1 \quad (3.12)$$

Bu denklemde m çıkış matrisinin boyutunu, n giriş matrisinin boyutunu, f filtre matrisinin boyutunu ve s kaydırma adım sayısını ifade etmektedir. Kaydırma adım sayısı, görüntü üzerinde yatay ve düşey ekseninde filtre kaydırılırken kaç adım kaydırılacağını belirlemektedir. Denklem 3.12'de görüldüğü üzere adım sayısı arttıkça çıkış görüntüsünün boyutu da azalacaktır. Denklem 3.12'de m çıkış matrisi tamsayı olmak zorundadır. Eğer m değeri tamsayı çıkmıyorsa kaydırma adım sayısının veya filtre boyutunun değiştirilmesi gerekmektedir.

$n \times n$ boyutunda bir görüntüye dolgulama (padding) işlemi yapılmadan $f \times f$ boyutunda bir filtre uygulandığında elde edilen görüntü daha küçük boyutta bir çıkış görüntüsü olacaktır. Çok katmanlı bir derin ağda, evrişim işlemi devam ettirildiğinde çok az bir iterasyon sonucunda çok küçük boyutta bir çıkış görüntü elde edilmiş olacaktır. Evrişim işlemi sonucunda, girdi görüntüsü boyutu ile elde edilen çıktı görüntüsü boyutunun aynı olması istenebilir. Bununla beraber evrişim işlemlerinde giriş

görüntüsünün üzerinde filtre kaydırılırken kenarlarındaki bilgilerin çok daha az filtre ile temas etmekte ve bu nedenle kenar bilgilerinin etkisi azalmaktadır. Merkezdeki pikseller/bilgiler ise filtre ile çok fazla temas ettiği için çıktı görüntüsünde etkisi yüksek olmaktadır. Bu olumsuzlukların üstesinden gelinmesi amacıyla giriş görüntüsüne dolgulama (padding) işlemi uygulanmaktadır (Ng ve ark., 2017). Dolgulama işleminde giriş görüntüsünün kenarlarına ilave olarak Şekil 3.15.'te gösterildiği gibi sıfır dolgulama (zero padding) yapılarak bir katman daha eklenmektedir. Böylelikle giriş görüntüsü boyutu eklenen katman sayısı kadar artmış olacaktır.

0	0	0	0	0	0	0	0
0	2	1	2	2	1	0	0
0	1	2	1	2	0	2	0
0	0	2	1	0	2	0	0
0	2	0	1	0	0	1	0
0	1	2	0	1	1	0	0
0	0	0	2	2	0	1	0
0	0	0	0	0	0	0	0

Şekil 3.15. Sıfır dolgulama işlemi

Giriş görüntüsüne eklenen dolgulama katmanının sayısı çıkış matrisinin boyutunu doğrudan etkilemektedir. Çıkış matrisinin boyutunun artırılması istendiğinden eklenecek katman sayısı da artırılmaktadır. Çıkış görüntüsü ile giriş görüntüsünün boyutlarının aynı olduğu bir evrişim işlemi gerçekleştirilmesi durumunda, bunun için Denklem 3.13 uygulanarak dolgulama katman sayısı belirlenmektedir.


$$p = \frac{(f - 1)}{2} \quad (3.13)$$

Burada, p dolgulama katman sayısını, f filtre boyutunu ifade etmektedir. Denklem 3.12'de verilen ve çıkış görüntüsü boyutunu hesaplayan formüle dolgulama parametresi de eklenince Denklem 3.14'teki formül elde edilmiştir.

$$m = \frac{(n - f + 2p)}{s} + 1 \quad (3.14)$$

3.2.2. Havuzlama katmanı

ESA için önemli yöntemlerden biri de havuzlama katmanıdır. Havuzlama katmanı, literatürde biriktirme, ortaklama ve seyrek örnekleme (subsampling) gibi farklı isimlerle de kullanılmaktadır. Genelde tek bir ağırlık parametresi ile ortalama alma veya maksimum işlemi yapılmaktadır ve böylelikle parametre sayısını önemli ölçüde azaltılmaktadır (Mercan, 2015). Bu işlem derinlik boyutunu etkilemeyen fakat görüntü boyutunu azaltan bir işlemdir. Genellikle ReLU katmanından sonra uygulanmaktadır. Bu işlem, modelin ezberleme (overfitting) yapmasını engellemek ve bir sonraki katman için hesap yükünü azaltmak gibi iki temel amaç için uygulanmaktadır. Havuzlama katmanı, evrişim katmanında olduğu gibi işlemleri filtreler üzerinden gerçekleştirmektedir. Genellikle ortalama havuzlama ve maksimum havuzlama gibi iki temel filtreden biri kullanılmaktadır. Maksimum havuzlamada, görüntü üzerinde filtreye karşılık gelen değerler içinden maksimum olanı almak şeklinde işlem yapılmaktadır. Ortama havuzlamada ise görüntü üzerinde filtreye karşılık gelen değerlerin ortalamasının alınması şeklinde işlem gerçekleştirilmektedir (İnik ve Ülker, 2017; Amidi ve Amidi, 2019).




Şekil 3.16. Maksimum havuzlama işlemi (İnik ve Ülker, 2017)

Şekil 3.16.'da havuzlama işleminin matris olarak gösterimi verilmiştir. 4x4'lük görüntü üzerinde tek adım kaydırmalı 2x2'lik filtreler kullanılarak maksimum havuzlama işlemi yapılmıştır ve böylelikle boyutları azaltılmış 3x3'lük bir görüntü elde edilmiştir. Evrişim işlemi ile benzer işlemler gerçekleştirildiğinden Denklem 3.12 ile havuzlama işlemi sonucunda elde edilen çıktı görüntüsünün boyutu hesaplanmaktadır.

3.2.3. Tam bağlantı katmanı

Teoride çok katmanlı algılayıcı ile aynı şekilde çalışmaktadır. Şekil 3.17.'de görüldüğü üzere tam bağlantı katmanı (fully connected layer) kendinden önceki katmandan gelen verilere tamamen bağlanan nöronları içermektedir (Kurt, 2018; Amidi ve Amidi, 2019). Genellikle tam bağlantı katmanından önce matris girişlerini tek boyutlu bir yapıya dönüştüren düzleştirme katmanı da (flatten layer) bulunmaktadır.



Şekil 3.17. Örnek tam bağlantı katmanı (Amidi ve Amidi, 2019)


3.3. Derin Öğrenme Modelleri

Derin öğrenme giriş bölümünde de belirtildiği üzere ESA, çok fazla eğitim verisine ve güçlü hesaplamalar için gerekli olan güçlü donanımlara ihtiyaç duymasından dolayı, 2012 yılına kadar bilgisayarlı görü (computer vision) alanında pek fazla ilgi görmemiştir. 2012 yılında Krizhevsky ve arkadaşları ImageNet görüntü sınıflandırması yarışmasında şampiyonluğu elde etmesinden sonra modern derin öğrenme modelleri popüler olmuş ve birçok alanda kullanılmaya başlanmıştır. LeNet ve AlexNet modeli ile başlayan bu modern derin öğrenme modellerini ZFNet,

GoogLeNet, VGGNet, ResNet ve SeNet gibi modeller takip etmiştir. Özellikle AlexNet ve GoogLeNet modelleri birçok alanda kullanılmış ve popüler olmuş modellerdir. Bu tez çalışmasında AlexNet ve GoogLeNet modelleri kullanılmıştır. Aşağıdaki kısımda LeNet, AlexNet ve GoogLeNet modelleri açıklanmıştır.

3.3.1. LeNet


1998 yılında Yann LeCun tarafından önerilen LeNet modeli gri seviye el yazısı ile yazılmış görüntülerin tanınması için uygulanmış bir modeldir. Evrişimli ağların ilk başarılı uygulamalarından biridir. Şekil 3.18.'de LeNet modeli verilmiştir.



Şekilde de görüldüğü üzere model giriş görüntüleri 32x32x1 boyutundadır. Sonrasında 6 tane 5x5'lik bir filtre 1 kaydırma ile kullanılmıştır. Günümüz derin öğrenme modellerinde genellikle maksimum havuzlama kullanılmaktadır fakat bu modelde ise ortalama havuzlama yöntemi kullanılmıştır. Ortalama havuzlama olarak 2x2 boyutunda ve 2 kaydırmalı bir filtre tercih edilmiştir. Aktivasyon fonksiyonu olarak sigmoid ve tanh doğrusal olmayan (non-linear) fonksiyonu kullanılmıştır. Dolgulama işlemi bu modelde kullanılmadığından dolayı 32x32x1 boyutları ile başlayan bu model, düzenli bir şekilde azalarak 5x5x16'lık bir boyutla evrişim işlemini tamamlamıştır. Ve 400 düğüm ile son katman olan ve 120 nöron bulunan tam bağlantı katmanına bağlanmıştır. Sonrasında yine 84 nöron olan bir başka tam bağlantı katmanı kullanılmıştır. Bu 84 özelliği kullanarak gauss bağlantısı ile 0'dan 9'a kadar olan sayıları tahmin eden nihayi çıktıyı üretmektedir. Bu modelin toplam 60.000 parametresi bulunmaktadır (LeCun ve ark., 1998; Ng ve ark., 2017; Kızrak ve Bolat, 2018).

3.3.2. AlexNet

AlexNet modeli (Krizhevsky ve ark., 2012), Alex Krizhevsky, Ilya Sutskever ve Geoff Hinton tarafından geliştirilmiş, 2012 yılında ImageNet yarışmasında görüntü sınıflandırma alanında birinci olmuş ve çoklu evrişim işlemlerinin kullanıldığı bir modeldir. Şekil 3.19.'da AlexNet modeli verilmiştir.



Şekil 3.19. AlexNet modeli (Ng ve ark., 2017)

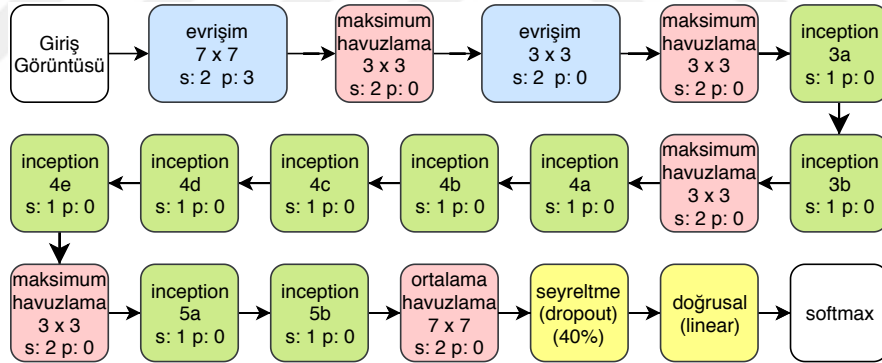
Şekil 3.19.'da görüldüğü üzere sekiz katmanlı bir yapı vardır. Bu katmanlardan beşi evrişim katmanı üçü tam bağlı katmandır. Tam bağlı katmanların sonuncu katmanın çıktısı 1000 sınıf üzerinde dağılım gösteren bir softmax fonksiyonuna bağlıdır. Aktivasyon fonksiyonu olarakta doğrutulmuş doğrusal birim (ReLU-rectified linear unit) fonksiyonu kullanılmıştır. Krizhevsky ve arkadaşlarının 2012 yılında yayınladıkları yayınlarında AlexNet mimarisinin giriş görüntüsünün boyutları 224x224x3 olarak verilmiştir. 96 adet 11x11x3 ve 4 kaydırmalı bir filtre ile evrişim işleminde 55x55x96 boyutlarında bir çıktı görüntüsü elde edilememektedir. Bu nedenle giriş görüntüsünün boyutlarının hatalı yazıldığı ve gerçek boyutunun 227x227x3 boyutlarında olması gerektiği ifade edilmektedir (Ng ve ark., 2017).

Bu model iki GPU üzerinde modellenmiştir. Şekil 3.19.'da gösterilen AlexNet modeli detaylı olarak incelenecek olursa ilk katmanda, 227x227x3 boyutundaki görüntüye 96 adet 11x11x3 ve 4 kaydırmalı bir filtre uygulanmış ve evrişim işlemi sonucunda 55x55x96 boyutlarında bir görüntü elde edilmiştir. Sonrasında 3x3'lük ve 2 kaydırmalı bir filtre ile maksimum havuzlama uygulanmış ve 27x27x96 boyutlarında bir görüntü elde edilmiştir. Takip eden diğer katmanlarda sırasıyla 256 adet 5x5'lik boyutlarında

dolgulama parametresi 2 olan bir filtre ve maksimum havuzlama, 384 adet 3x3'lük bir filtre, tekrar 384 adet 3x3'lük bir filtre ve beşinci katmanda 256 adet 3x3'lük bir filtre uygulanmıştır. Son katmanda 4096 nöron bulunan tam bağlantı katmanı kullanılmıştır. Son katman çıktısında ise 1000 sınıf üzerinde dağılım gösteren bir softmax fonksiyonu kullanılmıştır (Krizhevsky ve ark., 2012; Ng ve ark., 2017; Kurt, 2018).

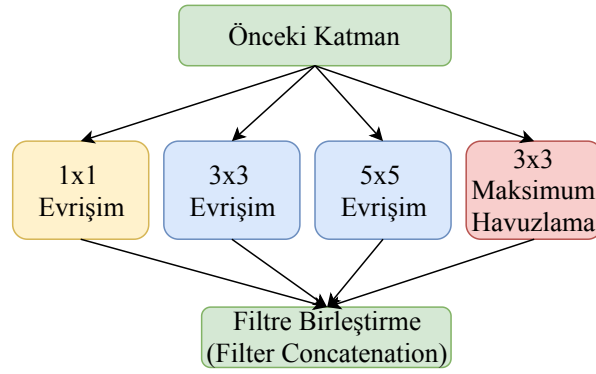
3.3.3. GoogLeNet

GoogLeNet mimarisi, Google çalışanlarından Szegedy ve arkadaşları tarafından 2014 yılında ImageNet yarışmasında sunulmuştur. 22 katmanlı olan GoogLeNet mimarisi, Krizhevsky ve arkadaşlarının 2012 yılında önerdikleri AlexNet mimarisinden 12 kat daha az parametreye ve %5,7 hata oranı ile daha yüksek doğruluğa sahiptir (Szegedy ve ark., 2015). GoogLeNet modelinde, LeNet'den esinlenilmiştir fakat inception modülü ekleyerek yeni bir ESA yapısı oluşturmuştur. Standart GoogLeNet mimarisi blok şeması Şekil 3.20.'de verilmiştir.



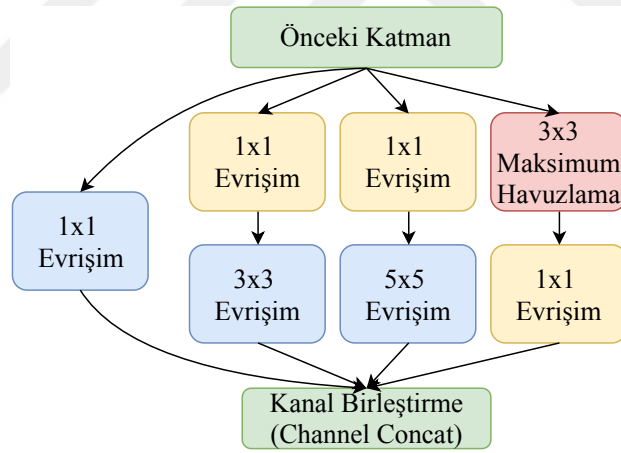
Şekil 3.20. Örnek GoogLeNet mimarisi blok şeması (Yurtsever ve Yurtsever, 2019)

GoogLeNet mimarisini oluşturan temel yapı taşı inception modülüdür. Inception ismi, "Inception" filminde geçen ve sonrasında internet sitelerinde caps olan "We need to go deeper (Daha derine inmeliyiz)" sözünden esinlenerek verilmiştir (Szegedy ve ark., 2015). Şekil 3.21.'de basit inception modülü verilmiştir. Bu basit inception modülünün kullanılması, çıkış görüntü boyutunun büyümesi, parametre sayısının artması ve buna bağlı olarak hesaplama işlem yükünün fazlalaşması gibi sorunları da beraberinde getirmektedir (Kızrak ve Bolat, 2018).



Şekil 3.21. Basit inception modülü

Bu nedenle 3x3 ve 5x5 boyutlu evrişim katmanları öncesinde ve 3x3 maksimum havuzlama sonrasında 1x1 evrişim katmanı eklenmiştir. Bununla birlikte 1x1 evrişim ReLU aktivasyon fonksiyonunu da içermektedir (Szegedy ve ark., 2015; Ng ve ark., 2017; Kızrak ve Bolat, 2018; Kurt 2018). Parametre sayısını azaltan bu inception modülü Şekil 3.22.'de gösterilmiştir. AlexNet modelinde 60 milyon olan parametre sayısı GoogLeNet inception modülüyle 5 milyona düşürülmüştür.



Şekil 3.22. Inception modülü

Inception modülünün v1 sürümünden sonra, 2015 yılında v2 (Ioffe ve Szegedy, 2015), 2016 yılında v3 (Szegedy ve ark., 2016) ve 2017 yılında v4 (Szegedy ve ark., 2017) sürümleri de geliştirilmiştir (Kurt, 2018).

3.4. Veri Artırımı

Derin öğrenme algoritmalarında kullanılan görüntüler için veri artırımı (data augmentation), veri setindeki örneklerin gerçek dünya verisini temsil edecek şekilde dikey çevirme (vertical flip), yatay çevirme (horizontal flip), farklı açılarda döndürme (rotate), kesme (crop), kaydırma (shift), yakınlaştırma (zoom) ve gürültü (noise) ekleme gibi farklı yöntemler kullanılarak elde edilen değiştirilmiş kopyalar ile veri setini büyüten bir yaklaşım olarak tanımlanmaktadır. Bu yaklaşım ile modelin, görüntü verilerinden çıkarılan özellikleri (feature extraction) daha iyi öğrenmesi sağlanmaktadır ve böylelikle model başarımı artmaktadır. Ayrıca, model görüntülerde olabilecek küçük değişikliklerden kaynaklı etkilere karşı daha dayanıklı hale getirmiş olacaktır. Veri artırımı işlemi derin ağlarda genellikle eğitim veri kümesine uygulanmaktadır. Fakat test kümesinde de veri artırımı yöntemleri kullanılmaktadır. Bu işlemlerde dikkat edilmesi gereken önemli konu, model içinde bilgi sızması (information leak) durumu oluşturacak bir veri kümesi dağılımının oluşturulmamasıdır. Eğitim kümesinde veri artırımı yapılmış örneklerin, test kümesinde olmaması. Aynı şekilde test kümesinde veri artırımı ile elde edilmiş görüntü örneklerinin de eğitim kümesinde olmamasıdır. Özellikle mikroskobik kanser görüntülerinde tek bir hastadan alınmış çok büyük boyulardaki mikroskobik görüntülerde hücre veya bez kısımlarını içerecek alt parçalara ayrılması ile veri büyütme işlemi yapılmaktadır. Bu işlem ile elde edilen görüntüler birbirlerinden farklı görüntüler olsa da bu görüntüler birbirine yakın özellikler barındıran görüntülerdir. Bu tez çalışmasında da bu tarz bir veri kümesinden hazırlanmış bir veri setinin model doğruluğunu nasıl etkilediği de ayrıca incelenmiştir.

BÖLÜM 4. UYGULAMA VE ARAŞTIRMA BULGULARI

4.1. Mikroskop Görüntüsü

Bu çalışmada (Yurtsever ve ark., 2018) mikroskoba (Nikon Eclipse E400) monte edilmiş dijital kamera (Nikon Coolpix E5000) ile çekilmiş insana ait renkli kolon doku görüntüleri üzerinde çalışılmıştır. Bu çalışmada kullanılan tüm görüntüler H&E (Ekicioglu ve ark., 2005; Lillie ve Fullmer, 1976) boyama tekniğiyle boyanmış mikroskop görüntüleridir. H&E boyama, histopatoloji alanında en çok kullanılan boyama tekniğidir. H&E boyama tekniği ile boyanmış histopatolojik görüntülerde hücre çekirdeği mavi ve siyah, sitoplazma (cytoplasm) pembe, kas lifleri (muscle fibres) koyu kırmızı, alyuvarlar (RBCs) turuncu-kırmızı arası bir renk ile boyanmış olmaktadır.

Mikroskop görüntülerinin geliştirilmiş k-ortalama algoritması ile bölütlenmesi konusunda yapılan çalışmada, görüntüler sayısallaştırılırken öncelikle mikrometre mikroskop lamının bir fotoğrafı da çekilmiştir. Uzunluk, aynı büyütme altında çekilmiş olan mikrometre mikroskop lamının fotoğrafı ile numunenin fotoğrafı karşılaştırılarak kalibre işlemi yapılmıştır. Elde edilen kolona ait mikroskopik görüntülerinin boyutları 2560x1920 pikseldir. Bu görüntülerin 51'i iyi huylu, 49'u kötü huylu kolon tümörlerine ait görüntülerdir. Bu mikroskopik görüntüler, Necmettin Erbakan Üniversitesi, Tıbbi Patoloji Anabilim Dalında tanı almış ve arşivinde saklanan, H&E ile boyalı preparatlardan, İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurulu izni ile rasgele seçilerek alınmış görüntülerdir.

Bölütlenmiş görüntüler kullanılarak derin öğrenme (deep learning) yöntemiyle iyi huylu ve kötü huylu tümör sınıflandırma çalışmasında ise bölütleme işlemi için kullanılan görüntülere ilave yapılarak 62 iyi huylu ve 61 kötü huylu kolon tümörüne

ait olmak üzere veri kümesi toplam 123 görüntüye çıkarılmıştır. Bu görüntülere ilave olarak, Warwick Üniversitesi, Bilgisayar Bilimleri bölümü web sayfası, <https://warwick.ac.uk/fac/sci/dcs/research/tia/glascontest/> adresinde araştırma amaçlı kullanım için izin verilmiş olan görüntüler kullanılmıştır. Bu görüntüler, 16 H&E boyalı histolojik kesitlerden elde edilen 165 görüntüden oluşmaktadır. Her kesit görüntüsü farklı hastalara ait ve dolayısıyla, veri kümesi hem boya dağılımında hem de doku yapısında özneler arası yüksek değişkenlik göstermektedir. Bu histolojik kesitlerin bütün slayt görüntülere (whole-slide images) sayısallaştırılması için 0,465 μm piksel çözünürlüğüne sahip Zeiss Mirax Midi Slide Scanner kullanılmıştır. Sayısallaştırılan bütün slayt görüntüler, 20x objektif büyütmesine eşdeğer 0,620 μm piksel çözünürlüğüne ölçeklendirilmiş görüntülerdir (Sirinukunwattana ve ark., 2015, Sirinukunwattana ve ark., 2017). Bu görüntülerin 74'ü iyi huylu ve 91'i kötü huylu kolon tümörlerine ait görüntülerdir. Elde edilen tüm bu görüntülere bölüm 4.3.1.'de detaylı olarak açıklandığı şekilde veri artırımı uygulanmış ve veri kümesi büyütülmüş ve toplam 11543 görüntü oluşturulmuştur.

4.2. Kolon Mikroskop Görüntülerinin Geliştirilmiş Yeni K-Ortalamlar Kümeleme Algoritması İle Bölütlenmesi

4.2.1. Önerilen yeni geliştirilmiş k-ortalamlar kümeleme algoritması

Renkli görüntülerin kümeleme tabanlı yaklaşımlarla bölütlenmesi işleminde, küme sayısının ve piksel kümelerinin ne olacağını belirlemek zor ve önemli bir aşamadır. Özellikle küme sayısı ve bu kümelerin ilk küme merkez değerlerinin doğru ve optimum bir şekilde belirlenmesi performans, bölütleme kalitesi ve bölütleme başarısı açısından büyük önem taşımaktadır. Ayrıca, kümeleme yöntemleri ile bölütleme işleminde elde edilen görüntülerin her işlem tekrarında aynı sonucu vermesi yani her kümeleme işlemi tekrarında aynı kümeleri ve bu kümeler içindeki aynı piksel değerlerini vermesi sistem kararlılığı ve stabilite açısından çok önemlidir. Özellikle tıbbi alanda, histopatolojik görüntülerde aynı görüntü için her işlem tekrarında aynı sonucu elde etmek sistem güvenilirliği açısından önemli bir kriterdir. Bunun için ilk küme merkezlerinin belli bir algoritmaya göre belirlenmesi gereklidir. Fakat bu işlemi

yaparken de sisteme fazla işlem yükü getirmemesi, basit ve kararlı bir yapı sunması göz önüne alınması gerekmektedir. Özellikle renkli histopatolojik görüntülerin kullanıldığı hesaba katıldığında ve bu görüntülerdeki piksellerin 0'dan 255'e kadar değer aldığı düşünüldüğünde, piksel kümelerinin ilk küme merkez değerlerinin birbirinden optimum şekilde uzak ve ayrık olması gereklidir.


İlk küme merkezlerinin atanması işlemi için literatürde genelde rasgele değer belirleme yöntemi kullanılmaktadır. Yapılan bu çalışmada (Yurtsever ve ark., 2018) ise H&E boyama tekniği ile boyanmış mikroskopik kolon kanser görüntüleri için ilk küme merkez değerlerinin rasgele atanması yerine optimum değer atanması şeklinde bir yöntem önerilmiştir. Önerilen bu yöntem, çok fazla hesap yükü getirmeyen, basit, performans artışı sağlayacak ve her işlem tekrarında aynı sonucu verecek şekilde kararlı bir yapı sunmaktadır. Bölüm 2.5.2.4.'te detaylandırılan bu yöntem, Denklem 2.35 ve Denklem 2.36'da verilmiştir. Ayrıca önerilen bu yöntem ile ilk küme merkezlerinin belirlenmesinin, sistem performansı açısından artı veya eksi nasıl etki sağladığı karşılaştırmalı olarak incelenmiştir. Buna ek olarak, küme sayısının 3, 4, 5 ve 6 şeklinde belirlenmesi sonucunda görüntülerin bölütlenmesi Şekil 4.3., Şekil 4.4., Şekil 4.5. ve Şekil 4.6.'da gösterilmiştir.

4.2.2. Uygulama

Yapılan bu çalışmada (Yurtsever ve ark., 2018), 51 iyi huylu ve 49 kötü huylu olarak tanı almış toplam 100 adet kolona ait dokuların mikroskopik görüntüsü kullanılmıştır. İlk olarak iyi huylu ve kötü huylu alanların görüntüsü üzerinde uzman bir patoloğ tarafından hücre çekirdekleri kırmızı renkle işaretlenerek altın standart oluşturulmuştur ve Şekil 4.1.'de gösterilmiştir.


Orijinal iyi huylu ve kötü huylu doku görüntülerine küme sayısı $k=\{3, 4, 5, 6\}$ olacak şekilde 4 farklı kümeleme işlemi, ağırlıklı k-ortalamlar kümeleme algoritması ve geliştirilmiş yeni k-ortalamlar kümeleme algoritması için ayrı ayrı uygulanmıştır. Bu işlemlerin tamamı kendi geliştirdiğimiz yazılım kullanılarak gerçekleştirilmiştir. Bu

yazılım Microsoft Visual Studio aracı kullanılarak C# programlama dilinde geliştirilmiştir. Uygulama arayüzü ve ekran görüntüleri Şekil 4.2.'de verilmiştir.

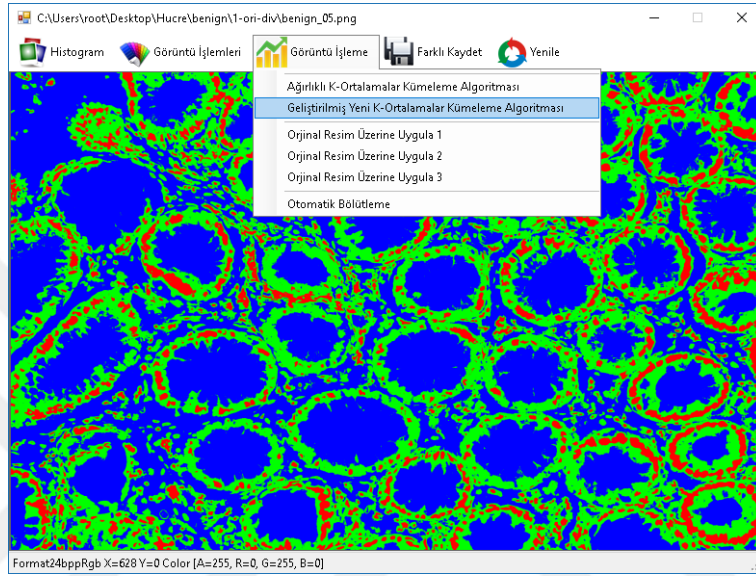


Şekil 4.1. Orijinal kolon tümör görüntüleri: (a) iyi huylu tümör görüntüsü, (b) iyi huylu tümör görüntüsünün çekirdek bölütlemesi için altın standart, (c) orijinal kötü huylu tümör görüntüsü, (d) kötü huylu tümör görüntüsünün çekirdek bölütlemesi için altın standart

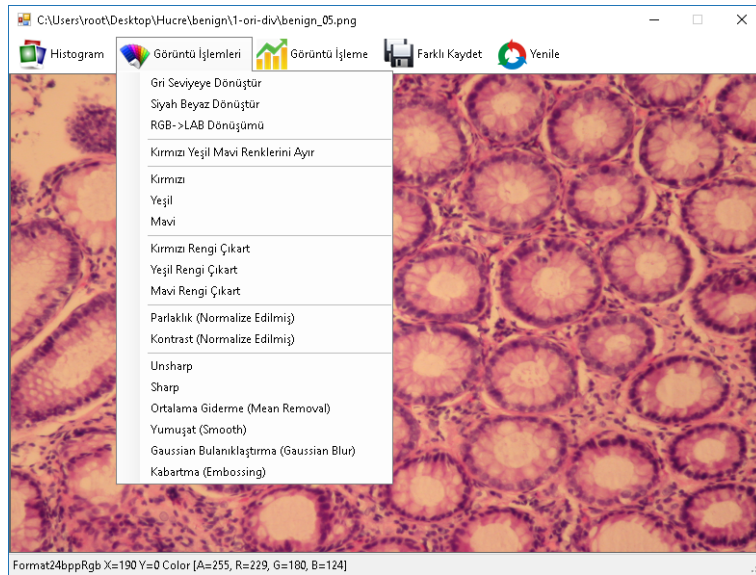
Geliştirilen uygulamada küme sayısına göre 3 küme için sırasıyla kırmızı, yeşil, mavi; 4 küme için sırasıyla kırmızı, sarı, yeşil, mavi; 5 küme için sırasıyla kırmızı, sarı, yeşil, koyu yeşil, mavi; 6 küme için sırasıyla kırmızı, sarı, yeşil, koyu yeşil, mavi, açık mavi renkleri atanmıştır. Bu işlemler sonucunda elde ettiğimiz kümeleme görüntüleri Şekil 4.3., Şekil 4.4., Şekil 4.5., ve Şekil 4.6.'da verilmiştir.



(a)




(b)




(c)

Şekil 4.2. Yazılım ekran görüntüsü: (a) küme sayısı seçim ekranı, (b) k-ortalamlar algoritması uygulama menüsü, (c) görüntü işlemleri uygulama menüsü




Şekil 4.3. Ağırlıklı k-ortalamlar kümeleme algoritması ile iyi huylu tümör görüntülerinin bölütlenmesi: (a) 3 küme, (b) 4 küme, (c) 5 küme, (d) 6 küme

Şekil 4.3.'te ağırlıklı k-ortalamlar kümeleme algoritması kullanılarak iyi huylu tümör görüntülerinin sırasıyla 3 kümeye, 4 kümeye, 5 kümeye ve 6 kümeye bölütlenmiş görüntüleri verilmiştir. Bu görüntülerde küme sayısına göre kırmızı, yeşil, mavi, sarı, koyu yeşil, açık mavi renkleri yukarıda belirtilen ve küme sayısına göre belirlenen şekilde atanmıştır. Kümelenen renkler incelendiğinde küme sayısı kadar renk topaklanmasının olduğu görülmektedir. Fakat yapılan deneyler sonucunda her bölütleme işleminde aynı sonuçların elde edilmediği tespit edilmiştir.




Şekil 4.4. Ağırlıklı k-ortalamlar kümeleme algoritması ile kötü huylu tümör görüntülerinin bölütlenmesi: (a) 3 küme, (b) 4 küme, (c) 5 küme, (d) 6 küme

Şekil 4.4.'te ağırlıklı k-ortalamlar kümeleme algoritması kullanılarak kötü huylu tümör görüntülerinin sırasıyla 3 kümeye, 4 kümeye, 5 kümeye ve 6 kümeye bölütlenmiş görüntüleri verilmiştir. Bu görüntülerde küme sayısına göre kırmızı, yeşil, mavi, sarı, koyu yeşil, açık mavi renkleri yukarıda belirtilen ve küme sayısına göre belirlenen şekilde atanmıştır. Kümelenen renkler incelendiğinde küme sayısı kadar renk olması beklenirken görüntülerde renk sayısının daha az olduğu görülmektedir. Dolayısıyla bölütleme sonucunda elde edilen görüntülerin renk topaklanmasının iyi olmadığı görülmüştür.



Şekil 4.5. Geliştirilmiş yeni k-ortalamlar kümeleme algoritması ile iyi huylu tümör görüntülerinin bölütlenmesi: (a) 3 küme, (b) 4 küme, (c) 5 küme, (d) 6 küme

Şekil 4.5.'te geliştirilmiş k-ortalamlar kümeleme algoritması kullanılarak iyi huylu tümör görüntülerinin sırasıyla 3 kümeye, 4 kümeye, 5 kümeye ve 6 kümeye bölütlenmiş görüntüleri verilmiştir. Bu görüntülerde küme sayısına göre kırmızı, yeşil, mavi, sarı, koyu yeşil, açık mavi renkleri yukarıda belirtilen ve küme sayısına göre belirlenen şekilde atanmıştır. Kümelenen renkler incelendiğinde küme sayısı kadar renk dağılımının olduğu görülmektedir. Ayrıca çekirdek, hücre ve bez ayrımının her kümelemede aynı renk dağılımında olduğu tespit edilmiştir. Dolayısıyla bölütleme sonucunda elde edilen görüntülerin renk topaklanmasının ağırlıklı k-ortalamlar algoritmasına göre daha tutarlı olduğu görülmüştür.



Şekil 4.6. Geliştirilmiş yeni k-ortalamlar kümeleme algoritması ile kötü huylu tümör görüntülerinin bölütlenmesi: (a) 3 küme, (b) 4 küme, (c) 5 küme, (d) 6 küme

Şekil 4.6.'da geliştirilmiş k-ortalamlar kümeleme algoritması kullanılarak kötü huylu tümör görüntülerinin sırasıyla 3 kümeye, 4 kümeye, 5 kümeye ve 6 kümeye bölütlenmiş görüntüleri verilmiştir. Kümelenen renkler incelendiğinde küme sayısı kadar renk dağılımının özellikle 3 küme ve 4 kümede olduğu görülmektedir. Yapılan tüm bu işlemler aynı şartlar altında 3 kere tekrarlanmıştır ve bu tekrarlar sonucunda elde edilen değerler arasındaki korelasyon hesaplanmış, sonuçlar ağırlıklı k-ortalamlar kümeleme algoritması için Tablo 4.1.'de, geliştirilmiş k-ortalamlar kümeleme algoritması için Tablo 4.2.'de gösterilmiştir. Her görüntü için iterasyon sayısı ve işlem zamanı geliştirilen yazılım üzerinden kayıt altına alınmış, bu veriler kullanılarak performansları karşılaştırılmış ve sonuçlar Tablo 4.3.'te gösterilmiştir. Bölütleme doğruluğu ise uzman bir patoloj tarafından oluşturulan altın standart ile bölütleme sonucunda elde edilen görüntüler karşılaştırılarak değerlendirilmiştir.

Tablo 4.1. Ağırlıklı k-ortalamlar kümeleme algoritması ile 3 kere tekrarlanan bölütleme işlemlerinin iterasyon sayısı ve işlem zamanı parametrelerinin korelasyon analizi

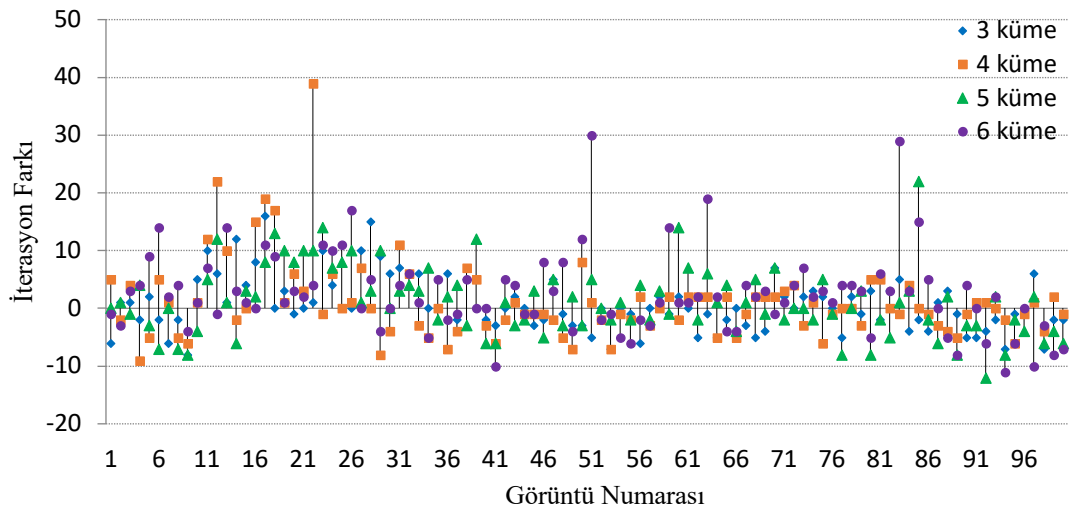
Küme sayısı	1. ve 2. işlem (iterasyon / zaman)	1. ve 3. işlem (iterasyon / zaman)	2. ve 3. işlem (iterasyon / zaman)
3 küme	0,192 / 0,195	0,185 / 0,187	0,183 / 0,184
4 küme	0,119 / 0,121	0,056 / 0,055	-0,013 / -0,010
5 küme	0,022 / 0,024	0,185 / 0,183	-0,018 / -0,016
6 küme	0,012 / 0,013	-0,116 / -0,115	0,027 / 0,027

Tablo 4.1.'de görüldüğü üzere, ağırlıklı k-ortalamlar kümeleme algoritması ile 3 kere aynı şartlar altında tekrarlanarak yapılan bölütleme işleminde iterasyon sayısı ve işlem zamanı, başlangıç küme değerlerinin rasgele olarak verilmesinden dolayı her işlemde farklı sonuç vermiştir. Yapılan bu 3 işlem arasında korelasyonun olmadığı görülmüştür. Dolayısıyla, ağırlıklı k-ortalamlar kümeleme algoritması kullanılarak yapılacak bölütleme işlemlerinde elde edilecek sonuçlar her zaman aynı olmayacaktır.

Table 4.2. Geliştirilmiş k-ortalamlar kümeleme algoritması ile 3 kere tekrarlanan bölütleme işlemlerinin iterasyon sayısı ve işlem zamanı parametrelerinin korelasyon analizi


Küme sayısı	1. ve 2. işlem (iterasyon / zaman)	1. ve 3. işlem (iterasyon / zaman)	2. ve 3. işlem (iterasyon / zaman)
3 küme	1 / 1	1 / 1	1 / 1
4 küme	1 / 1	1 / 1	1 / 1
5 küme	1 / 1	1 / 1	1 / 1
6 küme	1 / 1	1 / 1	1 / 1

Aynı görüntüler üzerinde ağırlıklı k-ortalamlar kümeleme algoritması ile yapılan tüm işlemlerin aynısı geliştirilmiş k-ortalamlar kümeleme algoritması kullanılarak gerçekleştirilmiştir. Aynı şartlar altında tekrarlanan işlemlerde başlangıç küme değerleri geliştirdiğimiz yöntem ile atandığı için, iterasyon sayısı ve işlem zamanı, yapılan her tekrarda aynı sonuçları ve aynı bölütleme görüntüsünü vermiştir. Ayrıca yapılan bu 3 tekrar arasında korelasyonun olduğu Tablo 4.2.'de görülmüştür. Dolayısıyla geliştirilmiş k-ortalamlar kümeleme algoritması kullanılarak yapılacak bölütleme işlemlerinde elde edilecek sonuçlar aynı görüntü için her zaman aynı olacaktır.



Şekil 4.7. Bölütleme işleminde ağırlıklı k-ortalamlar kümeleme algoritması ile geliştirilmiş yeni k-ortalamlar kümeleme algoritması arasındaki iterasyon farkı

Şekil 4.7.'de bölütleme işlemi yapan ağırlıklı k-ortalamlar kümeleme algoritması ile geliştirilmiş k-ortalamlar kümeleme algoritması arasındaki iterasyon farkı gösterilmiştir. Bu grafiğe bakıldığında pozitif bölgede olan değerler, ağırlıklı k-ortalamlar kümeleme algoritmasının iterasyon sayısını, negatif bölgede olan değerler ise geliştirilmiş k-ortalamlar kümeleme algoritmasının iterasyon sayısını göstermektedir. Bu grafiğe göre, geliştirilmiş k-ortalamlar kümeleme algoritmasının, ağırlıklı k-ortalamlar kümeleme algoritmasına göre daha az iterasyon sayısı ile bölütleme yaptığı açıkça görülmüştür.



Şekil 4.8. Bölütleme işleminde ağırlıklı k-ortalamlar kümeleme algoritması ile geliştirilmiş yeni k-ortalamlar kümeleme algoritması arasındaki zaman farkı

Şekil 4.8.'e bakıldığı zaman, pozitif bölge ağırlıklı k-ortalamlar kümeleme algoritmasının işlem zamanını, negatif bölge ise geliştirilmiş k-ortalamlar kümeleme algoritmasının işlem zamanını göstermektedir. Bu grafiğe göre de geliştirilmiş k-ortalamlar kümeleme algoritmasının, ağırlıklı k-ortalamlar kümeleme algoritmasına göre daha az işlem zamanıyla bölütleme yaptığı açıkça görülmüştür.

Tablo 4.3. Geliştirilmiş yeni k-ortalamlar kümeleme algoritmasının ağırlıklı k-ortalamlar kümeleme algoritmasına göre iterasyon sayısı ve işlem zamanı parametreleri açısından performans analizi

Küme Sayısı	Ağırlıklı K-Means kümeleme algoritması		Geliştirilmiş K-Means kümeleme algoritması		Performans (%)	
	Iterasyon	Zaman	Iterasyon	Zaman	Iterasyon	Zaman
3 küme	43	49	57	51	32,56	4,08
4 küme	46	49	54	51	17,39	4,08
5 küme	42	46	58	54	38,10	17,39
6 küme	31	35	69	65	122,58	85,71

Tablo 4.3.'te ağırlıklı k-ortalamlar kümeleme algoritması ve geliştirilmiş k-ortalamlar kümeleme algoritması için küme sayısı $k=\{3, 4, 5, 6\}$ olacak şekilde 100 adet resim üzerinde yapılan kümeleme işlemlerinde, kaç tane resimde hangi algoritmanın daha performanslı olduğu verilmiştir. Bu iki algoritma kıyaslandığında, geliştirilmiş k-ortalamlar kümeleme algoritmasının, ağırlıklı k-ortalamlar kümeleme algoritmasına göre ne kadar performans artışı gösterdiği iterasyon ve zaman parametreleri için aşağıda verilen denklem (Denklem 4.1) ile hesaplanmıştır. Buna göre, geliştirilmiş k-ortalamlar kümeleme algoritmasının ağırlıklı k-ortalamlar kümeleme algoritmasına göre daha performanslı olduğu, küme sayısı arttıkça geliştirilmiş k-ortalamlar kümeleme algoritmasının performansının da arttığı görülmüştür.

$$P(\%) = \frac{A_2 - A_1}{A_1} 100 \quad (4.1)$$

Burada A_2 geliştirilmiş k-ortalamlar kümeleme algoritmasının iterasyon ve zaman değeri, A_1 ise ağırlıklı k-ortalamlar kümeleme algoritmasının iterasyon ve zaman değeridir.

Sonraki aşamada bu iki algoritma ile bölütlenmiş görüntülerin orijinal görüntü ile benzerliği bölüm 2.6.'da detaylandırılmış olan histogram tabanlı benzerlik fonksiyonu ile incelenmiş, öklid yakınsaklık modeli ile benzerlik değerleri hesaplanmış ve sonuçlar Tablo 4.4.'te verilmiştir.

Tablo 4.4. Bölütlenmiş görüntülerin orijinal görüntüye benzerliğinin, histogram tabanlı benzerlik yöntemi ile analizi

İşlem Numarası	Ağırlıklı K-Means kümeleme algoritması				Geliştirilmiş K-Means kümeleme algoritması			
	Küme 3	Küme 4	Küme 5	Küme 6	Küme 3	Küme 4	Küme 5	Küme 6
1. işlem	37	34	30	28	63	66	70	72
2. işlem	33	34	37	22	67	66	63	78
3. işlem	31	34	30	34	69	66	70	66
Ortalaması	34	34	32	28	66	66	68	72


Tablo 4.4.'te her bir küme kolonunda verilen değerler, belirtilen algoritma ile bölütlenmiş görüntülerden kaç tanesinin orijinal görüntüye daha çok benzediğinin sayısıdır. Tablo 4.4. incelendiğinde, orijinal görüntüye benzerlik açısından geliştirilmiş k-ortalamar kümeleme algoritması ile bölütlenmiş görüntüler, ağırlıklı k-ortalamar kümeleme algoritması ile bölütlenmiş görüntülere göre, orijinal görüntüye daha çok benzediği görülmüştür. Yapılan analizler sonucunda, geliştirilmiş k-ortalamar kümeleme algoritmasının, küme merkezi değerlerini rasgele olarak atayan ağırlıklı k-ortalamar kümeleme algoritmasından daha performanslı ve daha stabil olduğunu göstermiştir. Ayrıca, bölütleme açısından analiz sonuçları incelendiğinde, geliştirilmiş k-ortalamar kümeleme algoritması ile bölütlenmiş görüntülerin orijinal görüntüye daha çok benzediği ve altın standart ile karşılaştırıldığında da daha iyi bölütlediği görülmüştür.

4.3. Mikroskopik Kolon Görüntülerinin Sınıflandırılması İçin Derin Öğrenme Tabanlı Yeni Bir Yaklaşım

4.3.1. Veri artırma

Veri artırma (data augmentation), daha küçük sayıda olan veri kümesinden, gerçek dünya verilerini temsil edecek şekilde daha büyük bir veri kümesi üretme sürecini


ifade etmektedir. Bu işlemi gerçekleştirmek için çok sayıda veri artırma yöntemi bulunmaktadır. Özellikle derin öğrenme algoritmalarından biri olan evrişimli sinir ağları kullanılan yapılarda görüntü sayısının çok büyük olması gereklidir. Eğer görüntü sayısı küçük olan bir veri setiniz var ise bu durumda veri artırma yöntemi kullanılarak veri kümesinin büyütülmesi aşırı öğrenmeye engel olacaktır. Bu nedenle yapılan bu çalışmada görüntü sayısını artırmak için öncelikle yüksek piksel boyutuna sahip olan, Necmettin Erbakan Üniversitesi, İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurulu izni ile Tıbbi Patoloji Anabilim Dalı arşivinden alınmış olan 62 iyi huylu ve 61 kötü huylu kolon tümör görüntüsünün farklı bölgelerinden kesitler alınarak birbirinden tamamen farklı 464 iyi huylu ve 407 kötü huylu görüntü elde edilmiştir. Bu görüntüler ile ilgili detaylar bölüm 4.1.'de verilmiştir. Aynı şekilde Warwick Üniversitesi, Bilgisayar Bilimleri bölümü web sayfasında yayınlanmış ve araştırma amaçlı çalışmalar için kullanım izni verilmiş görüntülerden elde edilen 74 iyi huylu ve 91 kötü huylu kolon tümör görüntüsünün farklı bölgelerinden kesitler alınarak birbirinden tamamen farklı 354 iyi huylu ve 424 kötü huylu kolon tümör görüntüsü elde edilmiştir.



Şekil 4.9. İyi huylu tümör görüntüsü için uygulanan veri artırım işlemleri: (a) orijinal görüntü, (b) yatay çevirme, (c) dikey çevirme, (d) 90° döndürme, (e) 180° döndürme, (f) 270° döndürme, (g) gauss gürültüsü

Yine aynı şekilde bu görüntüler ile ilgili detaylar da bölüm 4.1.'de verilmiştir. Bu şekilde toplam 818 iyi huylu ve 831 kötü huylu kolon tümör görüntüsü elde edilmiştir.

Bu mikroskobik kolon tümör görüntüleri gerçek dünya verisini temsil edecek şekilde dikey çevirme, yatay çevirme, görüntüyü 90° , 180° ve 270° döndürme ve gauss gürültüsü (gaussian noise) yöntemleri ile veri artırımı işlemine tabi tutulmuştur. Şekil 4.9. ve Şekil 4.10.'da iyi huylu ve kötü huylu tümör görüntülerinin bu veri artırım işlemleri sonucunda elde edilen görüntüleri verilmiştir. Veri artırım yöntemlerini uygularken elde edilen görüntülerin gerçekte var olan bir görüntü olup olmadığına dikkat etmek önemlidir. Örneğin bir araba görüntüsü 180° döndürme işlemine tabi tutulursa ters dönmüş bir araç elde edilecektir. Eğer bu görüntü hurdalık ile ilgili bir derin öğrenme modelinde kullanılmıyorsa anlamsız olacağı aşıkardır. Bu nedenle veri artırım yöntemlerini seçerken elde edilecek görüntünün kuracağınız model için uygun olup olmadığı kontrol edilmelidir. Şekil 4.9. ve Şekil 4.10. incelendiğinde bu tez çalışması için kullanılan mikroskobik kolon tümör görüntüleri için uygulanan veri artırım yöntemleri gerçek dünya verisini temsil edecek şekilde olduğu görülmektedir.



Şekil 4.10. Kötü huylu tümör görüntüsü için uygulanan veri artırım işlemleri: (a) orijinal görüntü, (b) yatay çevirme, (c) dikey çevirme, (d) 90° döndürme, (e) 180° döndürme, (f) 270° döndürme, (g) gauss gürültüsü

Bu çalışmada, belirtilen veri artırım yöntemleri kullanılarak mevcut görüntü sayısı 5726'sı iyi huylu ve 5817'si kötü huylu tümör görüntüsü olmak üzere toplam 11543'e çıkarılmıştır. Görüntüler üzerinde veri artırım yöntemleri kullanılarak yapılan işlemler,

Adobe Photoshop CC uygulamasındaki Automate>Batch menüsü kullanılarak otomatik ve toplu olarak gerçekleştirilmiştir.

4.3.2. Uygulama

Bir görüntüyü muazzam miktarda ayrıntıyla bölütlemek veya sınıflandırmak çok karmaşık bir problemdir. Aynı şekilde, yüksek miktarda ayrıntıya sahip görüntülerin derin öğrenme algoritmaları kullanılarak sınıflandırma işlemlerinin gerçekleştirilmesi yüksek işlem yükü oluşturan karmaşık yapılardır. Bu işlemlerin gerçekleştirilmesi için yüksek işlem yüklerini kaldırabilecek güçlü donanımlar kullanılmaktadır. Özellikle grafik işlem birimleri (GPU) üzerindeki çok sayıdaki işlemciyi paralel hesaplama mimarisi ile kullanılmaktadır. Dolayısıyla derin öğrenme algoritmalarında GPU'lar önemli bir donanım olmaktadır.

Bu tez çalışmada Donanım olarak Gigabyte X299 Aorus Gaming 9 Anakart, Intel Core i7 7800X 2066 Soket 8.25MB önbellek 3.5Ghz işlemci, Kingston DDR4 3000Mhz 64GB RAM, 2 Adet SLI bağlı MSI GeForce GTX 1080Ti Gaming X-Trio 11GB GDDR5X 352 Bit Nvidia ekran kartı, 3x4TB Sata 3.0 7200 Rpm 128MB Önbellekli NAS Harddisk kullanılmıştır. Yazılım olarak Şekil 4.11.'de uygulama arayüzü verilmiş olan, Ubuntu 18.10 işletim sistemi üzerinde web tabanlı bir yazılım olan NVIDIA Digits 6.0 kullanılmıştır. Paralel hesaplama mimarisi olarak NVIDIA'nın grafik işlem birimini (GPU) kullanarak hesaplama performansını arttıran CUDA 9.0 ve derin öğrenme için gereken işlemleri yapmayı sağlayan CuDNN yardımcı kütüphanesi kullanılmıştır. Bu yazılımlar işletim sistemi düzeyinde sanallaştırma için önerilen Docker kullanılarak kurulmuştur. Ayrıca derin öğrenme kütüphanesi olarak Python programlama dili kullanılan Caffe v0.15.14, yitim fonksiyonunda (loss function) minimumu bulmak için optimizasyon işleminde de en çok kullanılan Rasgele Gradyan İnişi (Stochastic Gradient Descent-SGD) algoritması kullanılmıştır.

The screenshot shows the Digits 6.0 web interface. The top navigation bar includes 'DIGITS', 'ulas (Logout)', 'Info', and 'About'. The main content area is titled 'Home' and shows 'No Jobs Running'. Below this, there are buttons for 'Datasets (96)', 'Models (66)', and 'Pretrained Models (0)'. A 'New Model' button is also visible. The 'Group Jobs' section is expanded to show a table of training jobs for the 'K3' group. The table has columns for name, id, framework, status, elapsed, epoch (train) max, learning_rate (train) max, and loss (train) min. All jobs in the table are marked as 'Done' and used the 'caffe' framework.

name	id	framework	status	elapsed	epoch (train) max	learning_rate (train) max	loss (train) min
k3_bir2_googlenet_sgd	20180802-083845-065a	caffe	Done	24m	29.94	0.01	0.0035
k3_bir_ozel1_caffe_googlenet_sgd	20180802-070638-024e	caffe	Done	24m	29.91	0.01	0.0034
k3_par_ozel5_caffe_googlenet_sgd	20180727-101828-ce99	caffe	Done	22m	29.88	0.01	0.00043
k3_par_ozel2_caffe_googlenet_sgd	20180727-081709-e573	caffe	Done	22m	29.88	0.01	0.00098
k3_par_ozel6_caffe_googlenet_sgd	20180726-143139-969f	caffe	Done	22m	29.88	0.01	0.0013
k3_par_ozel3_caffe_googlenet_sgd	20180726-141336-1e8c	caffe	Done	22m	29.88	0.01	0.0014
k3_par2_caffe_googlenet_sgd	20180726-130441-71b3	caffe	Done	24m	29.94	0.01	0.0037
k3_par7_caffe_googlenet_sgd	20180726-105031-a874	caffe	Done	24m	29.94	0.01	0.0007
k3_par_ozel4_caffe_googlenet_sgd	20180725-195535-a956	caffe	Done	22m	29.88	0.01	0.0012
k3_par_ozel1_caffe_googlenet_sgd	20180725-195419-ad1c	caffe	Done	22m	29.88	0.01	0.000032
k3_par10_caffe_googlenet_sgd	20180725-195038-312a	caffe	Done	24m	29.94	0.01	0.0012
k3_par9_caffe_googlenet_sgd	20180725-195019-5465	caffe	Done	24m	29.94	0.01	0.00021
k3_par8_caffe_googlenet_sgd	20180725-194959-6aef	caffe	Done	24m	29.94	0.01	0.0022
k3_par6_caffe_googlenet_sgd	20180725-194918-d102	caffe	Done	24m	29.94	0.01	0.00047
k3_par5_caffe_googlenet_sgd	20180725-194856-33ec	caffe	Done	24m	29.94	0.01	0.0026
k3_par4_caffe_googlenet_sgd	20180725-194834-c614	caffe	Done	24m	29.94	0.01	0.0012
k3_par3_caffe_googlenet_sgd	20180725-194814-5d23	caffe	Done	24m	29.94	0.01	0.00071
k3_par1_caffe_googlenet_sgd	20180725-194731-e760	caffe	Done	24m	29.94	0.01	0.00022

Şekil 4.11. Digits 6.0 web tabanlı uygulama arayüzü

Özellikle son yıllarda kullanılmaya başlanan derin öğrenme algoritmalarından biri olan evrişimli sinir ağları ile yapılan görüntü sınıflandırmalarında özellikle de histopatolojik görüntüler üzerinde veri artırımı işlemi haricinde herhangi bir ön işlem yapılmadan orijinal haliyle sinir ağı modeline girdi olarak verilmektedir. Bu tez çalışmasında, histopatolojik görüntülerden kolon tümör görüntülerinin iyi huylu ve kötü huylu olarak sınıflandırılmasında, işlemleri daha basitleştireceği ve performans olarak iyileştireceği öngörülerek, orijinal görüntünün tamamını tüm detayları ile kullanılması yerine, sınıflandırmadan önce ayrıntıları düşürülmüş şekilde kullanılması önerilmiştir. Bu amaçla orijinal görüntülerin temel özelliklerini kaybetmeden basit ve hızlı bir bölütlenme yöntemiyle ayrıntılarının düşürülmesi yaklaşımı kullanılmıştır. Bu bölütleme yaklaşımı için de yine basit, hızlı ve kararlı bir şekilde işlem yapacak kümeleme tabanlı algoritmaların bir versiyonu olan, bölüm 2.5.2.4.'te detaylı bir şekilde açıklanmış, bölüm 4.2.'de performans analizi ve uygulaması verilmiş olan geliştirilmiş yeni k-ortalama kümeleme algoritması önerilmiştir. Evrişimli sinir ağlarında, bu algoritma ile bölütlenmiş RGB (3 kanallı) görüntülerin kullanılması ile ön işlemden geçmemiş orijinal mikroskopik kolon kanser görüntülerinin kullanılmasının model performansını nasıl etkilediği karşılaştırmalı olarak analiz

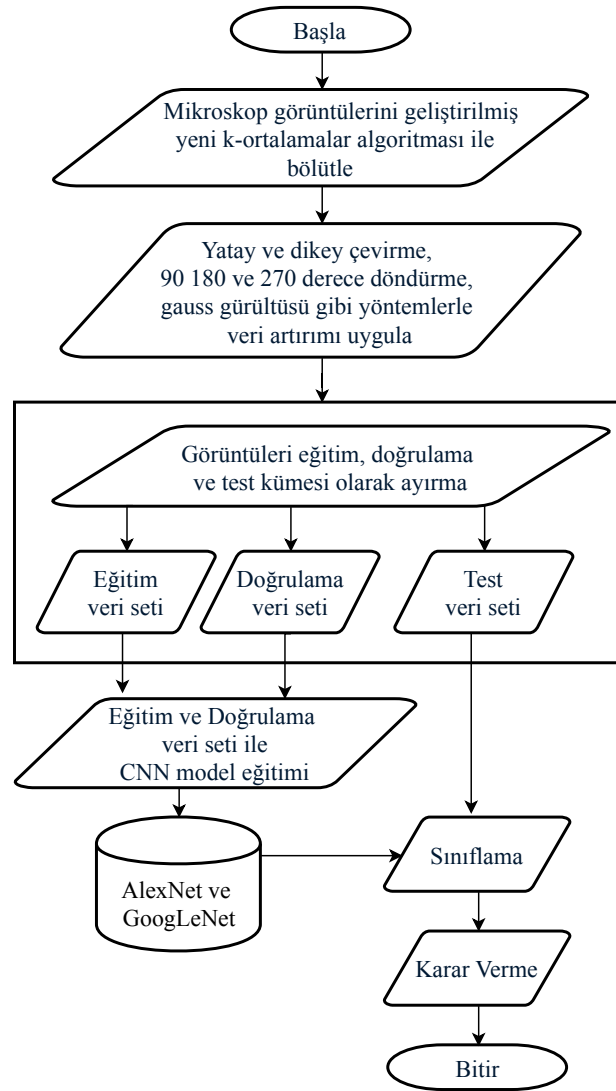
edilmiştir. Bu karşılaştırmalı analizde, derin öğrenme algoritmalarından biri olan evrişimli sinir ağları, model olarak AlexNet ve GoogLeNet mimarisi kullanılmıştır.

Öncelikle orijinal görüntülerden oluşan veri setinin %70'i eğitim (training) kümesinde, %15'i doğrulama (validation) kümesinde kullanılmak üzere ve yine %15'i de test kümesinde kullanılmak üzere rasgele olarak ayrılmıştır. Sonraki adımda, veri kümeleri ile AlexNet ve GoogLeNet modellerinin eğitimi gerçekleştirilmiştir. Bu işlem 10 kere tekrar edilmiştir ve her tekrarda eğitim veri seti, doğrulama veri seti ve test veri seti olarak yeniden veri seti oluşturulmuş ve modeller bu yeni veri seti üzerinde eğitilmiştir. Bu tekrarlarla hangi veri kümesinde model performans sonuçları düşük ve başarısız olduğu tespit edilmiştir. Bu çalışmada tespit edilen bu veri seti “özel” olarak isimlendireceğimiz veri kümesi olarak tanımlanmıştır. Orijinal görüntüden, birbirinden farklı kesitleri almak suretiyle parçalar oluşturulmuş görüntülerin aynı veri kümesinde olması yani birlikte olması durumunu ifade eden veri kümesi ise bu çalışmada “bir” olarak isimlendireceğimiz veri kümesi olarak tanımlanmıştır. Ayrıca orijinal görüntüden, birbirinden farklı kesitleri almak suretiyle parçalar oluşturulmuş görüntülerin aynı veri kümesinde olmaması yani birlikte olmaması durumunu ifade eden veri kümesi bu çalışmada “par” olarak isimlendireceğimiz veri kümesi olarak tanımlanmıştır.

Belirtilen bu yaklaşımlara göre; orijinal görüntüler, ayrı ayrı 3, 4, 5, 6 renk kümesine bölütlenmiş görüntüler kullanılarak, herbir görüntü setinden 4 farklı veri kümesi oluşturulmuştur. Böylelikle orj_par, orj_par_ozel, orj_bir, orj_bir_ozel, k3_par, k3_par_ozel, k3_bir, k3_bir_ozel, k4_par, k4_par_ozel, k4_bir, k4_bir_ozel, k5_par, k5_par_ozel, k5_bir, k5_bir_ozel, k6_par, k6_par_ozel, k6_bir, k6_bir_ozel şeklinde isimlendirilen 20 adet farklı yapıda ve farklı özellikte görüntü kümeleri elde edilmiştir. Toplam 11543 görüntüden oluşan veri kümesi eğitim veri seti, doğrulama veri seti ve test veri seti olarak üç kısma ayrılmıştır. Buna göre; “bir”, “bir_ozel”, “par” ve “par_ozel” isimli veri kümesindeki görüntüler Tablo 4.5.’te gösterildiği şekilde eğitim, doğrulama ve test veri seti olarak ayrılmıştır. Elde edilen tüm kümeler öncelikle AlexNet ve GoogLeNet evrişimli sinir ağları modellerinde kullanılarak eğitilmiş ve test edilmiştir. Önerilen yaklaşımın işleyişi Şekil 4.12.’de verilmiştir.

Tablo 4.5. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu 20 adet farklı veri kümesi için eğitim, doğrulama ve test veri seti görüntü sayısı

Veri Kümesi	Eğitim	Doğrulama	Test	Toplam
par	8099	1722	1722	11543
par_ozel	8099	1722	1722	11543
bir	7973	1806	1764	11543
bir_ozel	8036	1806	1701	11543



Şekil 4.12. Önerilen ESA sınıflandırma yaklaşımı

AlexNet modeli kullanılarak yapılan eğitim sonucunda elde edilen karışıklık matrisi (confusion matrix) sonuçları Tablo 4.6.'da gösterilmiştir. Herbir veri kümesi için model 3 defa çalıştırılmış ve elde edilen en yüksek performans değeri veren eğitim modeli kullanılmıştır. Aynı yöntemle GoogLeNet modeli kullanılarak yapılan eğitim

sonucunda elde edilen karışıklık matrisleri sonuçları Tablo 4.7.'de gösterilmiştir. Tablo 4.6. ve Tablo 4.7.'de iyi huylu tümör b olarak, kötü huylu tümör m olarak, iyi huylu tümör doğruluk yüzdesi b(%) olarak, kötü huylu tümör doğruluk yüzdesi m(%) olarak ve iyi huylu tümör doğruluk yüzdesi ile kötü huylu tümör doğruluk yüzdesi arasındaki mutlak farkta Mutlak Fark (%) olarak gösterilmiştir. Ayrıca, karışıklık matrisini gösteren Tablo 4.6. ve Tablo 4.7.'de, iyi huylu mikroskop görüntüsünün iyi huylu olarak doğru bir şekilde sınıflandırılması doğru pozitif (DP) olarak, iyi huylu görüntülerin kötü huylu olarak yanlış bir şekilde sınıflandırılması yanlış negatif (YN) olarak, aynı şekilde kötü huylu görüntülerin iyi huylu olarak yanlış bir şekilde sınıflandırılması yanlış pozitif (YP) olarak ve kötü huylu görüntülerin kötü huylu olarak sınıflandırılması doğru negatif (DN) olarak gösterilmiştir.

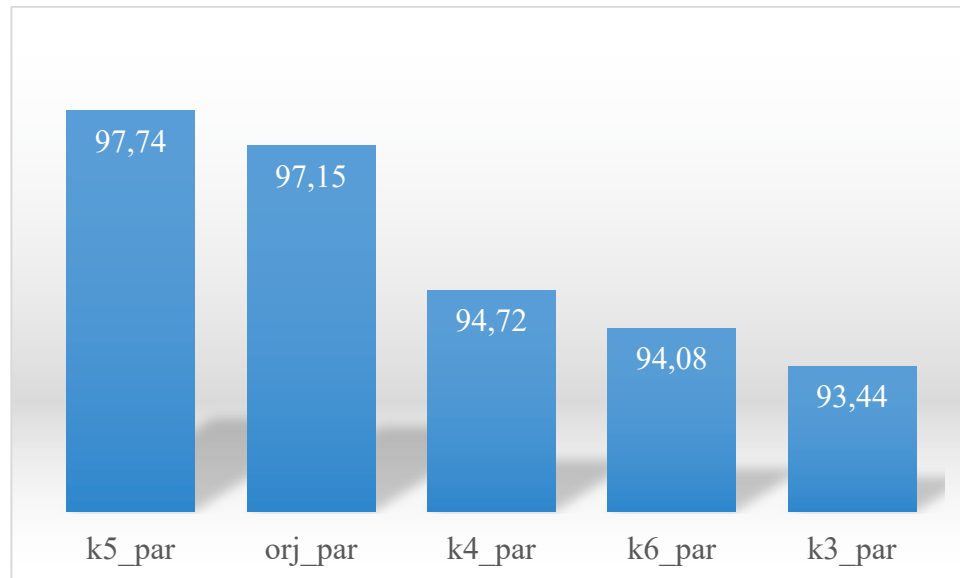
Tablo 4.6. AlexNet modeli kullanılarak oluşturulan ağın test kümesi ile test edilmesi sonucunda elde edilen karışıklık matrisi

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak	Model
	DP	YN	YP	DN			Fark (%)	Doğruluğu (%)
orj_par	830	24	25	843	97,19	97,14	0,05	97,15
orj_par_ozel	386	468	13	855	45,20	98,50	53,30	72,07
orj_bir	898	54	85	727	94,33	89,53	4,80	92,12
orj_bir_ozel	357	539	34	771	38,84	95,78	56,94	66,31
Orijinal Görüntüler Kullanıldığında Model Doğruluğu Ortalaması								81,91
k3_par	790	64	49	819	92,51	94,35	1,84	93,44
k3_par_ozel	795	59	32	836	93,09	96,31	3,22	94,72
k3_bir	902	50	122	690	94,75	84,98	9,77	90,25
k3_bir_ozel	734	162	7	798	81,92	99,13	17,21	90,06
3 Kümeye Bölütlenmiş Görüntüler ile Model Doğruluğu Ortalaması								92,12
k4_par	812	42	49	819	95,08	94,35	0,73	94,72
k4_par_ozel	697	157	33	835	81,62	96,20	14,58	88,97
k4_bir	871	81	69	743	91,49	91,50	0,01	91,50
k4_bir_ozel	666	230	86	719	74,33	89,32	14,99	81,42
4 Kümeye Bölütlenmiş Görüntüler ile Model Doğruluğu Ortalaması								89,15
k5_par	835	19	20	848	97,78	97,70	0,08	97,74
k5_par_ozel	653	201	13	855	76,46	98,50	22,04	87,57
k5_bir	921	31	71	741	96,74	91,26	5,48	94,22
k5_bir_ozel	581	315	10	795	64,84	98,76	33,92	80,89
5 Kümeye Bölütlenmiş Görüntüler ile Model Doğruluğu Ortalaması								90,11

Tablo 4.6. (Devamı)


Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak Fark (%)	Model Doğruluğu (%)
	DP	YN	YP	DN				
k6_par	798	56	46	822	93,44	94,70	1,26	94,08
k6_par_ozel	682	172	35	833	79,86	95,97	16,11	87,98
k6_bir	907	45	127	685	95,27	84,36	10,91	90,25
k6_bir_ozel	638	258	27	778	71,21	96,65	25,44	83,25
6 Kümeye Bölütlenmiş Görüntüler ile Model Doğruluğu Ortalaması								88,89

Tablo 4.6.'da AlexNet model doğruluğu (%) verisine göre par, par_ozel, bir, bir_ozel veri kümesinin orijinal görüntü ve k3, k4, k5, k6 kümeleme görüntüleri kullanmasına göre elde edilen model doğruluk performansının karşılaştırması sırasıyla Şekil 4.13., Şekil 4.14., Şekil 4.15. ve Şekil 4.16.'da gösterilmiştir. Bu şekillerden Şekil 4.13.'te gösterildiği üzere, sadece “par” veri kümesi kullanılarak yapılan model eğitiminde, 5 renk kümesine bölütlenmiş görüntü kullanan modelin, orijinal görüntü kullanılarak eğitilen modele göre %0,59 gibi düşük bir fark ile daha iyi bir doğruluk gösterdiği tespit edilmiştir. Bu düşük fark, test görüntü kümesine eğitim veri kümesinden bilgi sızması durumu oluşmasından kaynaklanmaktadır. Özellikle “par” veri kümesinde, farklı boyutlarda görüntülere ayrılmış alt görüntülerin eğitim veri kümesinde, diğer alt görüntülerin de test kümesinde olması nedeniyle bilgi sızması dediğimiz durum oluşmaktadır.




Şekil 4.13. Orijinal ve k3, k4, k5, k6 bölütlenmiş görüntülerin olduğu “par” veri kümelerinin AlexNet model doğruluklarının karşılaştırması


Şekil 4.14., Şekil 4.15. ve Şekil 4.16. incelendiğinde ise bölütlenmiş görüntü kullanan AlexNet modelinin, orijinal görüntü kullanılarak eğitilen AlexNet modeline göre daha yüksek bir fark ile model doğruluğu gösterdiği tespit edilmiştir.



Şekil 4.14. Orijinal ve k3, k4, k5, k6 bölütlenmiş görüntülerin olduğu “par_ozel” veri kümelerinin AlexNet model doğruluklarının karşılaştırması



Şekil 4.15. Orijinal ve k3, k4, k5, k6 bölütlenmiş görüntülerin olduğu “bir” veri kümelerinin AlexNet model doğruluklarının karşılaştırması



Şekil 4.16. Orijinal ve k3, k4, k5, k6 bölütlenmiş görüntülerin olduğu “bir_ozel” veri kümelerinin AlexNet model doğruluklarının karşılaştırması

Şekiller incelendiğinde “par” ve “bir” veri kümelerinde k5 şeklinde bölütlenmiş görüntülerin kullanıldığı AlexNet modelinde en yüksek model doğruluğu elde edildiği görülmektedir. Aynı şekilde “par_ozel” ve “bir_ozel” veri kümelerinde ise k3 şeklinde bölütlenmiş görüntülerin kullanıldığı ve bu görüntüler ile eğitilmiş olan AlexNet modelinin en yüksek model doğruluğuna sahip olduğu açıkça görülmektedir. Özellikle “par_ozel” ve “bir_ozel” olarak isimlendirilen veri kümelerinde, bölütlenmiş görüntüler kullanılarak eğitilen AlexNet modeli, orijinal-ham görüntüler kullanılarak eğitilen AlexNet modeline göre “par_ozel” veri kümesinde %22, “bir_ozel” veri kümesinde ise %23 gibi büyük bir farkla model doğruluğu gösterdiği tespit edilmiştir. Dolayısıyla AlexNet modeli kullanılarak yapılacak eğitimlerde, modelin eğitimi ve test edilmesi işlemleri bölütlenmiş görüntüler kullanılarak yapılması durumunda, model performansının arttığı açıkça görülmüştür.


Tablo 4.7.’de model doğruluk ortalamaları incelendiğinde GoogLeNet modeli kullanılarak yapılacak eğitimlerde modelin eğitimi ve test işlemleri bölütlenmiş görüntüler kullanılarak hatta 3 kümeyle bölütlenmiş (k3) görüntüler kullanılarak yapılması durumunda modelin performansının arttığı görülmektedir.

Tablo 4.7. GoogLeNet modeli kullanılarak oluşturulan ağın test kümesi ile test edilmesi sonucunda elde edilen karışıklık matrisi


Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak	Model
	DP	YN	YP	DN			Fark (%)	Doğruluğu (%)
orj_par	825	29	22	846	96,60	97,47	0,87	97,04
orj_par_ozel	372	482	16	852	43,56	98,16	54,60	71,08
orj_bir	872	80	51	761	91,60	93,72	2,12	92,57
orj_bir_ozel	379	517	45	760	42,30	94,41	52,11	66,96
Orijinal Görüntüler Kullanıldığında Model Doğruluğu Ortalaması								81,91
k3_par	824	30	20	848	96,49	97,70	1,21	97,10
k3_par_ozel	765	89	20	848	89,58	97,70	8,12	93,67
k3_bir	922	30	55	757	96,85	93,23	3,62	95,18
k3_bir_ozel	816	80	18	787	91,07	97,76	6,69	94,24
3 Kümeye Bölütlenmiş Görüntüler ile Model Doğruluğu Ortalaması								95,05
k4_par	827	27	52	816	96,84	94,01	2,83	95,41
k4_par_ozel	794	60	53	815	92,97	93,99	1,02	93,44
k4_bir	903	49	50	762	94,85	93,84	1,01	94,39
k4_bir_ozel	813	83	31	774	90,74	96,15	5,41	93,30
4 Kümeye Bölütlenmiş Görüntüler ile Model Doğruluğu Ortalaması								94,14
k5_par	837	17	24	844	98,01	97,24	0,77	97,63
k5_par_ozel	717	137	27	841	83,96	96,89	12,93	90,48
k5_bir	919	33	68	744	96,53	91,63	4,90	94,27
k5_bir_ozel	800	96	15	790	89,29	98,14	8,85	93,47
5 Kümeye Bölütlenmiş Görüntüler ile Model Doğruluğu Ortalaması								93,96
k6_par	838	16	36	832	98,13	95,85	2,28	96,98
k6_par_ozel	735	119	59	809	86,07	93,20	7,13	89,66
k6_bir	912	40	86	726	95,80	89,41	6,39	92,86
k6_bir_ozel	811	85	22	783	90,51	97,27	6,76	93,71
6 Kümeye Bölütlenmiş Görüntüler ile Model Doğruluğu Ortalaması								93,30

Tablo 4.7.'deki “par”, “par_ozel”, “bir”, “bir_ozel” veri kümelerinde, orijinal-ham görüntünün ve kümeleme ile bölütlenmiş görüntülerin kullanılmasının GoogLeNet model doğruluğuna etkisi, karşılaştırmalı bir şekilde Şekil 4.17., Şekil 4.18., Şekil 4.19. ve Şekil 4.20.'de gösterilmiştir. Bu şekillerden Şekil 4.17.'de gösterildiği üzere, sadece “par” veri kümesi kullanılarak yapılan GoogLeNet model eğitiminde, 5 renk ve 3 renk kümesine bölütlenmiş görüntü kullanan modelin, orijinal-ham görüntü kullanılarak eğitilen modele göre %1'den düşük bir fark ile daha iyi bir doğruluk gösterdiği tespit edilmiştir. Bu düşük fark, AlexNet modelinde ve GoogLeNet


modelinde de gerçekleşen, eğitim veri kümesinden test veri kümesine bilgi sızması durumundan kaynaklanmaktadır.



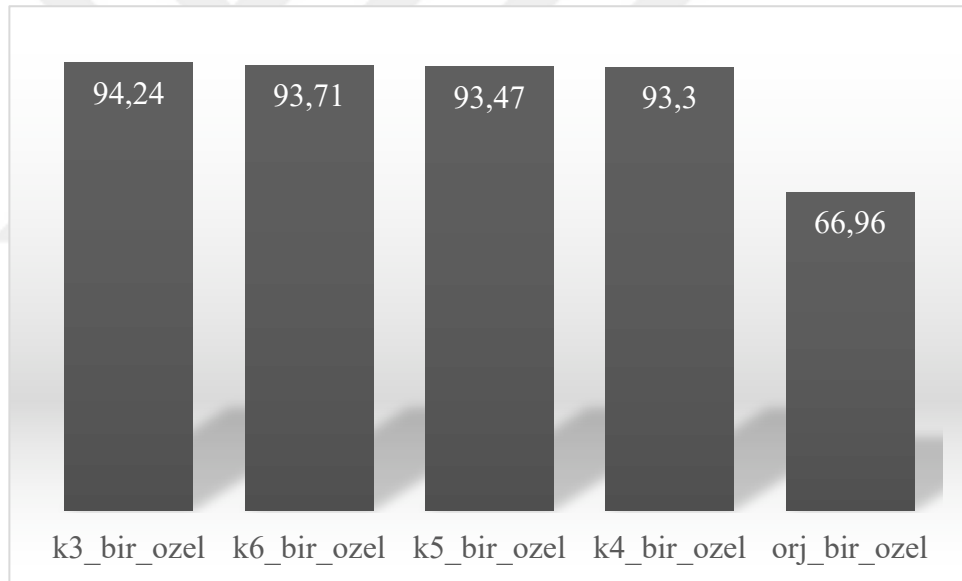
Şekil 4.17. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par” veri kümelerinin GoogLeNet model doğruluklarının karşılaştırması



Şekil 4.18. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par_ozel” veri kümelerinin GoogLeNet model doğruluklarının karşılaştırması



Şekil 4.19. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir” veri kümelerinin GoogLeNet model doğruluklarının karşılaştırması




Şekil 4.20. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir_ozel” veri kümelerinin GoogLeNet model doğruluklarının karşılaştırması

Şekil 4.17., Şekil 4.18., Şekil 4.19. ve Şekil 4.20. incelendiğinde “par” veri kümesinde 5 kümeye bölütlenmiş görüntülerin kullanıldığı ve bu görüntüler ile eğitilmiş GoogLeNet modelinin doğruluğunun en yüksek olduğu görülmektedir. Yine “par” veri kümesinde 3 kümeye bölütlenmiş görüntülerin kullanılması durumunda ikinci en yüksek model doğruluğu elde edildiği görülmektedir. Aynı şekilde “par_ozel”, “bir” ve “bir_ozel” veri kümelerinde ise 3 kümeye (k3) bölütlenmiş görüntülerin kullanıldığı ve bu görüntüler ile eğitilmiş olan GoogLeNet modelinin en yüksek model


doğruluğuna sahip olduğu açıkça görülmektedir. Özellikle “par_ozel”, “bir” ve “bir_ozel” olarak isimlendirilen veri kümelerinde, bölütlenmiş görüntüler kullanılarak eğitilen GoogLeNet modeli, orijinal-ham görüntüler kullanılarak eğitilen GoogLeNet modeline kıyasla “bir” veri kümesinde %2’den büyük bir fark; “par_ozel” ve “bir_ozel” veri kümesinde ise sırasıyla %22 ve %27 gibi büyük bir farkla model doğruluğu gösterdiği tespit edilmiştir.

Evrışimli sinir ağları modellerinden olan AlexNet ve GoogLeNet kullanılarak oluşturulan sinir ağının test görüntüleri ile test edilmesi sonucunda elde edilen model doğruluk yüzdeleri, Tablo 4.6. ve Tablo 4.7.’de incelendiğinde, GoogLeNet modeli histopatolojik kolon kanser görüntülerinin iyi huylu ve kötü huylu olarak sınıflandırılmasında daha başarılı olduğu görülmektedir. Ayrıca 3 kümeye ayrılmış görüntülerin oluşturduğu veri kümesi ile oluşturulan GoogLeNet modeli, diğer veri kümelerinin kullanılmasıyla oluşturulan GoogLeNet modellerine göre daha yüksek sınıflandırma başarımı göstermektedir.


Her ne kadar Tablo 4.6. ve Tablo 4.7.’deki karışıklık matrisi sonuçlarına göre ESA modellerinde bölütlenmiş görüntülerin kullanılması başarımı arttırdığı görülsede bu başarımın güvenilirliğini tıp alanında yaygın bir şekilde kullanılan ROC analizi ile de irdelemek önemlidir. ROC analizi, özellikle tıp alanında uygulanan makine öğrenmesi uygulamalarında, en iyi sınıflandırma başarımına sahip modelin tespit edilmesinde oldukça yaygın kullanılan bir grafiksel analizdir. Bu nedenle, bu çalışmada “par”, “par_ozel”, “bir” ve “bir_ozel” olarak isimlendirdiğimiz farklı veri kümeleri üzerinde uygulanan ESA modellerinin başarımı ROC analizi kullanılarak irdelenmiştir. Yapılan analizde ROC eğrilerinin altında kalan alana yani AUC değerine bakarak ilgili modelin sınıflandırma başarısı belirlenmiştir. 20 farklı veri kümesi üzerinde AlexNet modeli eğitilerek elde edilen performans sonuçlarının ROC eğrileri ve AUC değerleri Şekil 4.21., Şekil 4.22., Şekil 4.23. ve Şekil 4.24.’teki grafiklerde gösterilmiştir.




Şekil 4.21. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par” veri setleri üzerinde eğitilen AlexNet modelinin tahmin gücünü gösteren ROC eğrileri



Şekil 4.22. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par_ozel” veri setleri üzerinde eğitilen AlexNet modelinin tahmin gücünü gösteren ROC eğrileri



Şekil 4.23. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu "bir" veri setleri üzerinde eğitilen AlexNet modelinin tahmin gücünü gösteren ROC eğrileri




Şekil 4.24. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu "bir_ozel" veri setleri üzerinde eğitilen AlexNet modelinin tahmin gücünü gösteren ROC eğrileri


Şekil 4.21., Şekil 4.22., Şekil 4.23. ve Şekil 4.24.'te verilmiş AlexNet modeli tahmin gücünü gösteren ROC eğrilerini incelediğimizde, kolon kanser sınıflandırması için örneklem uzayını iyi temsil etmeyen ve "par_ozel" ve "bir_ozel" olarak

isimlendirdiğimiz veri kümesindeki görüntüler, hiçbir önışlemeden geçirilmeden kullanılması durumunda çok düşük bir AUC değerine sahip olduğu görülmektedir. Fakat önerdiğimiz yöntem ile aynı görüntülerin bölütlenmiş görüntülerini kullanarak AlexNet modeli eğitildiği takdirde AUC değerinin 1'e yakın olduğu görülmektedir. Bu sonuçlara göre, ROC grafikleri Tablo 4.6.'da verilen model doğruluk değerleri ile paralellik göstermektedir.


20 farklı veri kümesi üzerinde GoogLeNet modeli eğitilerek elde edilen performans sonuçlarının ROC eğrileri ve AUC değerleri ise Şekil 4.25., Şekil 4.26., Şekil 4.27. ve Şekil 4.28.'deki grafiklerde gösterilmiştir.




Şekil 4.25. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu "par" veri setleri üzerinde eğitilen GoogLeNet modelinin tahmin gücünü gösteren ROC eğrileri



Şekil 4.26. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “par_ozel” veri setleri üzerinde eğitilen GoogLeNet modelinin tahmin gücünü gösteren ROC eğrileri



Şekil 4.27. Orijinal ve k3, k4, k5, k6 bölütlemiş görüntülerin olduğu “bir” veri setleri üzerinde eğitilen GoogLeNet modelinin tahmin gücünü gösteren ROC eğrileri

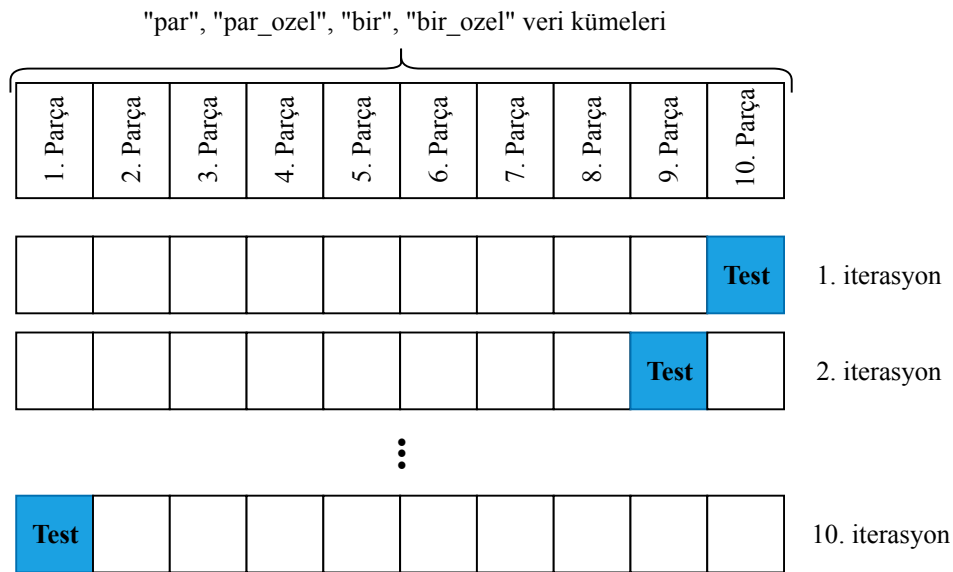


Şekil 4.28. Orijinal ve k3, k4, k5, k6 bölümlenmiş görüntülerin olduğu “bir_ozel” veri setleri üzerinde eğitilen GoogLeNet modelinin tahmin gücünü gösteren ROC eğrileri

Şekil 4.25. ile Şekil 4.28. arasında GoogLeNet modelleri için verilmiş olan ROC grafiklerine baktığımızda, AlexNet modellerinde olduğu gibi, kolon kanser sınıflandırması için örneklem uzayını iyi temsil etmeyen “par_ozel” ve “bir_ozel” olarak isimlendirdiğimiz veri kümesindeki görüntüler, hiçbir önışlemeden geçirilmeden kullanılması durumunda çok düşük bir AUC değerine sahip olduğu görülmektedir. Dolayısıyla, önerdiğimiz yaklaşım ile bölütlenmiş görüntü kümesini kullanan AlexNet ve GoogLeNet modelleri ile görüntülerin orijinal-ham hallerini kullanan AlexNet ve GoogLeNet modelleri arasındaki performans farkının istatistiksel olarak anlamlı olduğu tespit edilmiştir.

Veri kümelerinde kullanılan görüntülerin model performansına ve başarıma olan etkisi karışıklık matrisi ile ortaya konulmuştur ve ROC eğrileri ile elde edilen sonuçların güvenilirliği ve hangi veri kümesi ile hangi ESA modeli kullanıldığında daha iyi sonuçlar verdiği analiz edilmiştir. Ve kümeleme yöntemi ile bölütlenmiş görüntüler ile eğitilmiş GoogLeNet modelinin daha performanslı olduğu ortaya konulmuştur. Fakat başarılı olan modelimizin eğitim ve test aşamasında veri kümelerindeki görüntülerin dağılımından kaynaklı performansı etkileyen sonuçlar veya hatalar olabilir. Bu hataları elimine etmek, elde edilen model performansının veri kümesinin dağılımdan bağımsız

olarak doğruluğunu ve güvenilirliğini sağlamak için k-katlı çapraz doğrulama yöntemi kullanılarak veriler eğitim ve test olmak üzere 10 parçaya ayrılmıştır. Bir parçası test kümesi geriye kalan diğer parçalar eğitim kümesi olacak şekilde 10 farklı eğitim ve test kümesi oluşturulmuştur. ESA modeli ayrı ayrı herbir eğitim kümesi ile eğitilmiş ve test kümesi ile test edilmiştir. Elde edilen performans değerlerinin ortalaması alınarak modelin gerçek performans değeri elde edilmiştir. GoogLeNet modeli, veri kümesinde 3 kümeye bölütlenmiş görüntüler ve orijinal görüntüler kullanılarak ayrı ayrı eğitilmiştir. K-katlı çapraz doğrulama işlemleri Şekil 4.29.'da gösterildiği şekilde gerçekleşmiştir. Burada herbir parçanın “par”, “par_ozel”, “bir” ve “bir_ozel” kümeleri için bu bölümün başında belirtilen yaklaşıma uygun şekilde eşit parçalara ayrılmasına dikkat edilmiştir. Bu nedenle k-katlı çapraz doğrulama yönteminde “par” ve “bir” veri kümeleri için K sayısı 10, “par_ozel” için ise K sayısı 6 ve “bir_ozel” için ise K sayısı 7 olarak seçilmiştir. Böylelikle seçilen veri kümesindeki verilerin dağılımının model performansına olan pozitif veya negatif etkisi elimine edilmiştir.



Şekil 4.29. K-katlı çapraz doğrulama yöntemi

Uygulanan k-katlı çapraz doğrulama yöntemi sonucunda orijinal görüntülerin olduğu “par”, “par_ozel”, “bir”, “bir_ozel” veri kümelerinin GoogLeNet modeli kullanılarak elde edilen performans sonuçları ve ortalaması sırasıyla Tablo 4.8., Tablo 4.9., Tablo 4.10. ve Tablo 4.11.’de verilmiştir.

Tablo 4.8. K-katlı çapraz doğrulama ile oluşturulan, orijinal görüntülerin olduğu “par” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak	Model
	DP	YN	YP	DN			Fark (%)	Doğruluğu (%)
par1	564	3	10	564	99,47	98,26	1,21	98,86
par2	559	8	12	562	98,59	97,91	0,68	98,25
par3	531	36	14	560	93,65	97,56	3,91	95,62
par4	532	35	5	569	93,83	99,13	5,3	96,49
par5	547	20	24	550	96,47	95,82	0,65	96,14
par6	552	15	12	562	97,35	97,91	0,56	97,63
par7	558	9	19	555	98,41	96,69	1,72	97,55
par8	541	26	4	570	95,41	99,30	3,89	97,37
par9	555	12	1	573	97,88	99,83	1,95	98,86
par10	525	42	13	561	92,59	97,74	5,15	95,18
Ortalaması					96,37	98,02	2,50	97,20

“par” veri kümesinin orijinal-ham görüntüleri k-katlı çapraz doğrulama yöntemi ile K=10 olacak şekilde parçalara ayrılmış ve sırasıyla her bir parçası test verisi diğer parçaları eğitim verisi olacak şekilde 10 iterasyonda GoogLeNet modeli eğitilmiş ve test edilmiştir. Her bir iterasyonda elde edilen model doğruluk değerleri ve bu doğruluk değerlerinin ortalaması Tablo 4.8.’de verilmiştir. Buna göre “par” veri kümesinin orijinal-ham görüntüleri kullanılarak eğitilen GoogLeNet modelinin ortalama performansı %97,20 olarak hesaplanmıştır. Ayrıca modelin iyi huylu tümörü doğru tahmin etme başarısı ile kötü huylu tümörü doğru tahmin etme başarısı arasındaki mutlak fark hesaplanmış ve Tablo 4.8.’de verilmiştir. Elde edilen mutlak fark ortalaması ise %2,5 olarak hesaplanmıştır. Bu mutlak fark ne kadar düşük olursa model daha kararlı bir şekilde her iki sınıf içinde aynı performansı göstererek sınıflandırma yapmıştır denilmektedir.

Tablo 4.9. K-katlı çapraz doğrulama ile oluşturulan, orijinal görüntülerin olduğu “par_ozel” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak	Model
	DP	YN	YP	DN			Fark (%)	Doğruluğu (%)
par_ozel1	428	482	19	905	47,03	97,94	50,91	72,68
par_ozel2	876	34	4	920	96,26	99,57	3,31	97,93

Tablo 4.9. (Devamı)

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak Fark (%)	Model Doğruluğu (%)
	DP	YN	YP	DN				
par_ozel3	874	36	6	918	96,04	99,35	3,31	97,71
par_ozel4	869	41	37	887	95,49	96,00	0,51	95,75
par_ozel5	873	37	19	905	95,93	97,94	2,01	96,95
par_ozel6	882	28	29	895	96,92	96,86	0,06	96,89
Ortalaması					87,95	97,94	10,02	92,99

“par_ozel” veri kümesinin orijinal-ham görüntüleri k-katlı çapraz doğrulama yöntemi ile $K=6$ olacak şekilde parçalara ayrılmış ve 6 iterasyonda GoogLeNet modeli eğitilmiş ve test edilmiştir. Her bir iterasyonda elde edilen model doğruluk değerleri, bu doğruluk değerlerinin ortalaması ve sınıflar arası mutlak fark ortalaması Tablo 4.9.’da verilmiştir. GoogLeNet modelinin ortalama performansı %92,99 ve mutlak fark ortalaması %10,02 olarak hesaplanmıştır.

Tablo 4.10. K-katlı çapraz doğrulama ile oluşturulan, orijinal görüntülerin olduğu “bir” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak Fark (%)	Model Doğruluğu (%)
	DP	YN	YP	DN				
bir1	575	27	1	580	95,51	99,83	4,32	97,63
bir2	455	119	23	544	79,27	95,94	16,67	87,55
bir3	467	37	6	575	92,66	98,97	6,31	96,04
bir4	465	53	12	555	89,77	97,88	8,11	94,01
bir5	527	26	5	541	95,30	99,08	3,78	97,18
bir6	565	2	55	547	99,65	90,86	8,79	95,12
bir7	478	68	33	478	87,55	93,54	5,99	90,44
bir8	454	113	12	555	80,07	97,88	17,81	88,98
bir9	506	61	70	560	89,24	88,89	0,35	89,06
bir10	485	33	26	555	93,63	95,52	1,89	94,63
Ortalaması					90,27	95,84	7,40	93,06

“bir” veri kümesinin orijinal-ham görüntüleri k-katlı çapraz doğrulama yöntemi ile $K=10$ olacak şekilde parçalara ayrılmış ve 10 iterasyonda GoogLeNet modeli eğitilmiş ve test edilmiştir. Elde edilen performans değerleri Tablo 4.10.’da verilmiştir. GoogLeNet modelinin ortalama performansı %93,06 ve sınıflar arası mutlak fark ortalaması %7,4 olarak hesaplanmıştır.

Tablo 4.11. K-katlı çapraz doğrulama ile oluşturulan, orijinal görüntülerin olduğu “bir_ozel” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak	Model
	DP	YN	YP	DN			Fark (%)	Doğruluğu (%)
bir_ozel1	303	495	108	718	37,97	86,92	48,95	62,87
bir_ozel2	665	70	16	754	90,48	97,92	7,44	94,29
bir_ozel3	602	63	13	750	90,53	98,30	7,77	94,68
bir_ozel4	699	71	87	662	90,78	88,38	2,4	89,60
bir_ozel5	594	71	27	743	89,32	96,49	7,17	93,17
bir_ozel6	713	78	67	696	90,14	91,22	1,08	90,67
bir_ozel7	663	128	6	708	83,82	99,16	15,34	91,10
Ortalaması					81,86	94,06	12,88	88,05

“bir_ozel” veri kümesinin orijinal-ham görüntüleri k-katlı çapraz doğrulama yöntemi ile $K=7$ olacak şekilde parçalara ayrılmış ve 7 iterasyonda GoogLeNet modeli eğitilmiş ve test edilmiştir. Elde edilen performans değerleri Tablo 4.11.’de verilmiştir. GoogLeNet modelinin ortalama performansı %88,05 ve sınıflar arası mutlak fark ortalaması %12,88 olarak hesaplanmıştır.

Aynı görüntülerin 3 kümeye bölütlenmiş görüntülerinin olduğu “par”, “par_ozel”, “bir”, “bir_ozel” veri kümelerinin GoogLeNet modeli kullanılarak elde edilen performans sonuçları ve ortalaması ise sırasıyla Tablo 4.12., Tablo 4.13., Tablo 4.14. ve Tablo 4.15.’te verilmiştir.

Tablo 4.12. K-katlı çapraz doğrulama ile oluşturulan, 3 kümeye bölütlenmiş görüntülerin olduğu “par” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak	Model
	DP	YN	YP	DN			Fark (%)	Doğruluğu (%)
par1	549	18	9	565	96,83	98,43	1,6	97,63
par2	561	6	4	570	98,94	99,30	0,36	99,12
par3	553	14	3	571	97,53	99,48	1,95	98,51
par4	565	2	22	552	99,65	96,17	3,48	97,90
par5	549	18	30	544	96,83	94,77	2,06	95,79
par6	552	15	9	565	97,35	98,43	1,08	97,90
par7	559	8	17	557	98,59	97,04	1,55	97,81

Tablo 4.12. (Devamı)

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak Fark (%)	Model Doğruluğu (%)
	DP	YN	YP	DN				
par8	552	15	14	560	97,35	97,56	0,21	97,46
par9	554	13	7	567	97,71	98,78	1,07	98,25
par10	538	29	16	558	94,89	97,21	2,32	96,06
Ortalaması					97,57	97,72	1,57	97,64

“par” veri kümesinin 3 kümeye bölütlenmiş görüntüleri 7-katlı çapraz doğrulama yöntemi ile parçalara ayrılmış ve 7 iterasyonda GoogLeNet modeli eğitilmiş ve test edilmiştir. Elde edilen performans değerleri Tablo 4.12.’de verilmiştir. GoogLeNet modelinin ortalama performansı %97,64 ve sınıflar arası mutlak fark ortalaması %1,57 olarak hesaplanmıştır. Tablo 4.8.’de verilmiş olan “par” veri kümesinin orijinal-ham görüntüler ile test edilmiş GoogLeNet model performansı ile karşılaştırıldığında performans olarak, bölütlenmiş görüntüler ile eğitilen GoogLeNet modelinin çok küçük bir fark ile daha iyi olduğu görülmüştür. Bu fark çok anlamlı gibi görülmesede sınıflar arası mutlak fark ortalamasına baktığımızda ise bölütlenmiş görüntüler kullanan GoogLeNet modelinin her iki sınıf içinde aynı kararlılıkta sonuç verdiği görülmektedir.

Tablo 4.13. K-katlı çapraz doğrulama ile oluşturulan, 3 kümeye bölütlenmiş görüntülerin olduğu “par_ozel” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak Fark (%)	Model Doğruluğu (%)
	DP	YN	YP	DN				
par_ozel1	875	35	23	901	96,15	97,51	1,36	96,84
par_ozel2	894	16	16	908	98,24	98,27	0,03	98,26
par_ozel3	897	13	23	901	98,57	97,51	1,06	98,04
par_ozel4	893	17	37	887	98,13	96,00	2,13	97,06
par_ozel5	882	28	26	898	96,92	97,19	0,27	97,06
par_ozel6	892	18	14	910	98,02	98,48	0,46	98,26
Ortalaması					97,67	97,49	0,85	97,59

“par_ozel” veri kümesinin 3 kümeye bölütlenmiş görüntüleri 6-katlı çapraz doğrulama yöntemi ile parçalara ayrılmış ve 6 iterasyonda GoogLeNet modeli eğitilmiş ve test edilmiştir. Elde edilen performans değerleri Tablo 4.13.’te verilmiştir. GoogLeNet

modelinin ortalama performansı %97,59 ve sınıflar arası mutlak fark ortalaması %0,85 olarak hesaplanmıştır.

Tablo 4.14. K-katlı çapraz doğrulama ile oluşturulan, 3 kümeye bölütlenmiş görüntülerin olduğu “bir” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak	Model
	DP	YN	YP	DN			Fark (%)	Doğruluğu (%)
bir1	579	23	3	578	96,18	99,48	3,30	97,80
bir2	508	66	14	553	88,50	97,53	9,03	92,99
bir3	487	17	26	555	96,63	95,52	1,11	96,04
bir4	482	36	21	546	93,05	96,30	3,25	94,75
bir5	529	24	24	522	95,66	95,60	0,06	95,63
bir6	561	6	27	575	98,94	95,51	3,43	97,18
bir7	509	37	61	450	93,22	88,06	5,16	90,73
bir8	535	32	43	524	94,36	92,42	1,94	93,39
bir9	564	3	57	573	99,47	90,95	8,52	94,99
bir10	501	17	55	526	96,72	90,53	6,19	93,45
Ortalaması					95,40	93,75	3,64	94,54

“bir” veri kümesinin 3 kümeye bölütlenmiş görüntüleri 10-katlı çapraz doğrulama yöntemi ile parçalara ayrılmış ve 10 iterasyonda GoogLeNet modeli eğitilmiş ve test edilmiştir. Elde edilen performans değerleri Tablo 4.14.’te verilmiştir. GoogLeNet modelinin ortalama performansı %94,54 ve sınıflar arası mutlak fark ortalaması %3,64 olarak hesaplanmıştır. Tablo 4.10.’da verilmiş olan “bir” veri kümesinin orijinal-ham görüntüler ile test edilmiş GoogLeNet model performansı ile karşılaştırıldığında performans olarak bölütlenmiş görüntüler ile eğitilen GoogLeNet modelinin performansının %1,48’lik bir fark ile daha iyi olduğu görülmüştür. Sınıflar arası mutlak fark ortalamasına baktığımızda, bölütlenmiş görüntüler kullanan GoogLeNet modelinin %3,76’lık bir fark ile her iki sınıf içinde aynı kararlılıkta sonuç verdiği görülmektedir.

“bir_ozel” veri kümesinin 3 kümeye bölütlenmiş görüntüleri 7-katlı çapraz doğrulama yöntemi ile parçalara ayrılmış ve 7 iterasyonda GoogLeNet modeli eğitilmiş ve test edilmiştir. Elde edilen performans değerleri Tablo 4.15.’te verilmiştir. GoogLeNet

modelinin ortalama performansı %93,08 ve sınıflar arası mutlak fark ortalaması %3,88 olarak hesaplanmıştır.

Tablo 4.15. K-katlı çapraz doğrulama ile oluşturulan, 3 kümeye bölütlenmiş görüntülerin olduğu “bir_ozel” veri kümesi için karışıklık matrisi ve GoogLeNet performans sonuçları

Veri Kümesi	b-b	b-m	m-b	m-m	b (%)	m (%)	Mutlak Fark (%)	Model Doğruluğu (%)
	DP	YN	YP	DN				
bir_ozel1	781	17	38	788	97,87	95,40	2,47	96,61
bir_ozel2	720	15	25	745	97,96	96,75	1,21	97,34
bir_ozel3	608	57	35	728	91,43	95,41	3,98	93,56
bir_ozel4	694	76	29	720	90,13	96,13	6,00	93,09
bir_ozel5	621	44	40	730	93,38	94,81	1,43	94,15
bir_ozel6	755	36	36	727	95,45	95,28	0,17	95,37
bir_ozel7	724	67	35	679	91,53	95,10	3,57	93,22
Ortalaması					92,89	93,29	3,88	93,08

Tablo 4.8. ve Tablo 4.15. arasındaki tablolarda verilen orijinal-ham görüntülerin ve 3 kümeye bölütlenmiş görüntülerin GoogLeNet modeli kullanılarak eğitilmesi ve test edilmesi sonucunda elde edilen performans sonuçlarının ortalaması karşılaştırmalı olarak Tablo 4.16.’da verilmiştir.

Tablo 4.16. Orijinal ve 3 kümeye bölütlenmiş görüntülerin GoogLeNet ortalama performans sonuçları karşılaştırması

Veri Kümesi	3 kümeye bölütlenmiş görüntü			Orijinal görüntü		
	b (%)	m (%)	Model Doğruluğu (%)	b (%)	m (%)	Model Doğruluğu (%)
par	97,57	97,72	97,64	96,37	98,02	97,20
par_ozel	97,67	97,49	97,59	87,95	97,94	92,99
bir	95,40	93,75	94,54	90,27	95,84	93,06
bir_ozel	92,89	93,29	93,08	81,86	94,06	88,05
Ortalama	95,88	95,56	95,71	89,11	96,47	92,83

Tablo 4.16. incelendiğinde sayısal olarak 3 kümeye bölütlenmiş görüntüler kullanılarak eğitilen ESA model performansının, aynı görüntülerin orijinal görüntüsü kullanılarak eğitilen ESA model performansından yüksek olduğu görülmektedir. Ayrıca iyi huylu tümör sınıflandırma başarımı ile kötü huylu tümör sınıflandırma başarımı arasında sınıflandırma dengesine baktığımız zaman da 3 kümeye bölütlenmiş

görüntüler kullanılarak eğitilen ESA modelinde daha dengeli sınıflandırma sonuçlarına sahip olduğu görülmektedir.

Tablo 4.17. K-katlı çapraz doğrulama sonucunda elde edilen GoogLeNet ortalama performans sonuçları ile 3 kümeye bölütlenmiş görüntülerin GoogLeNet performans sonuçları karşılaştırması

Veri Kümesi	Standart veri kümesi ile GoogLeNet performansı			K-katlı çapraz doğrulama ile GoogLeNet performansı		
	b (%)	m (%)	Model Doğruluğu (%)	b (%)	m (%)	Model Doğruluğu (%)
	par	96,49	97,70	97,10	97,57	97,72
par_ozel	89,58	97,70	93,67	97,67	97,49	97,59
bir	96,85	93,23	95,18	95,40	93,75	94,54
bir_ozel	91,07	97,76	94,24	92,89	93,29	93,08
Ortalama	93,50	96,60	95,05	95,88	95,56	95,71

Tablo 4.17.'de ise 3 kümeye bölütlenmiş görüntülerin Tablo 4.7.'de gösterilen ve GoogLeNet modeli ile elde edilen model doğruluk oranlarının, k-katlı çapraz doğrulama yöntemiyle elde edilen GoogLeNet model doğruluk oranları ile karşılaştırılması verilmiştir. Buna göre de GoogLeNet modeli ile k-katlı çapraz doğrulama sonucunda elde edilen model doğruluk oranının, Tablo 4.7.'de gösterilen GoogLeNet modeli doğruluk oranları ile aynı ve tutarlı olduğu görülmüştür.

Ayrıca Tablo 4.8. ve Tablo 4.15. arasındaki tablolarda da kötü huylu tümör ve iyi huylu tümör sınıflandırma başarımı arasındaki mutlak farka yani varyansa baktığımız zaman yine 3 kümeye bölütlenmiş görüntüler kullanılarak eğitilen ESA modelinde daha dengeli ve kararlı sınıflandırma yaptığı görülmektedir. Buna ek olarak özellikle orijinal görüntüler kullanılarak eğitilen ESA modelinin başarısız olduğu “ozel” veri kümesinde, 3 kümeye bölütlenmiş görüntüler kullanılarak eğitilen ESA model doğruluğunun çok daha yüksek olduğu ve genel anlamda tüm veri kümelerinde birbirine yakın ve dengeli başarı performansı sağladığı görülmektedir.

BÖLÜM 5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, histolojik incelemeleri H&E rutin boyama yöntemi ile yapılan, insana ait renkli kolon doku örnekleri kullanılmıştır. Boyanmış bu renkli doku örneklerinin görüntüleri, üzerine dijital kamera monte edilmiş bir ışık mikroskobu kullanılarak çekilmiştir. Yapılan bu çalışma iki aşamada gerçekleştirilmiştir. İlk aşamada kolon tümör görüntülerinin basit ve hızlı bir şekilde bölütlenmesi amaçlanmıştır. Bunun için geliştirilmiş (augmented) yeni k-ortalamlar kümeleme algoritması kullanılmıştır. Sonraki aşamada ise kolon kanser görüntülerinin kötü huylu ve iyi huylu tümör olarak sınıflandırılması için bölütlenmiş görüntülerin kullanıldığı derin öğrenme tabanlı yeni bir yaklaşım uygulanmıştır.

Yapılan bu çalışmanın ilk aşamasında, RGB renk uzayında, 100 adet mikroskobik kolon doku görüntüleri üzerinde, geliştirilmiş k-ortalamlar kümeleme algoritması ve ağırlıklı k-ortalamlar kümeleme algoritması kullanılarak bölütleme işlemi gerçekleştirilmiştir. Ağırlıklı k-ortalamlar kümeleme algoritması ile geliştirilmiş k-ortalamlar kümeleme algoritması iterasyon sayısı ve işlem zamanı parametreleri açısından karşılaştırılmış ve önerilen geliştirilmiş k-ortalamlar kümeleme algoritması performansının bu parametreler açısından daha performanslı olduğu görülmüştür. Bu karşılaştırma işlemlerinde 3, 4, 5 ve 6 küme olmak üzere farklı küme sayılarına göre görüntü kümeleme işlemi gerçekleştirilmiştir. Yapılan tüm işlemler aynı şartlar altında 3 defa tekrarlanmış ve elde edilen sonuçlar incelenerek algoritmaların kararlılık durumları incelenmiştir. Elde edilen sonuçlara göre, geliştirilmiş k-ortalamlar kümeleme algoritmasının ağırlıklı k-ortalamlar kümeleme algoritmasına göre daha performanslı olduğu, 3 kümeye ayrılmış görüntülerde iterasyon sayısı olarak %32,56'lık bir performans artışı, işlem zamanı olarak ise %4,08'lik bir performans artışı elde edilmiştir. Küme sayısı arttıkça geliştirilmiş k-ortalamlar kümeleme algoritmasının performansının da arttığı tespit edilmiştir. Ayrıca, ilk küme merkezi

değerlerini rasgele veya doğrusal olmayan bir yöntemle belirleyen, k-ortalamlar kümeleme algoritması ve bunların geliştirilmiş versiyonları olan algoritmalar ile bölütlenmiş görüntülerin, her işlem tekrarında farklı olduğu görülmüştür. Önerdiğimiz yeni geliştirilmiş k-ortalamlar kümeleme algoritmasında ise aynı şartlar altında tekrarlanan tüm işlemlerde elde edilen bölütlenmiş görüntülerin aynı olduğu tespit edilmiştir. Elde edilen bölütlenmiş görüntülerin renk topaklaması açısından orijinal görüntü ile olan benzerlikleri histogtam tabanlı benzerlik algoritması ile hesaplanmış ve geliştirilmiş k-ortalamlar kümeleme algoritması ile bölütlenmiş görüntülerin benzerlik değerinin 1'e yakın olduğu hesaplanmıştır. Dolayısıyla geliştirilmiş k-ortalamlar kümeleme algoritması ile elde edilen bölütlenmiş görüntülerin renk topaklanmasının orijinal görüntüye daha çok benzediği tespit edilmiştir. Sonuç olarak, mikroskobik görüntülerin bölütlenmesi uygulamalarında önerdiğimiz geliştirilmiş k-ortalamlar kümeleme algoritmasının, bölütleme işlemlerinde iterasyon ve işlem zamanı açısından daha başarılı ve performanslı olduğu ve geliştirilmiş k-ortalamlar kümeleme algoritması ile bölütlenmiş görüntülerin orijinal görüntüye daha benzer sonuçlar verdiği tespit edilmiştir.

Kısaca özetlemek gerekirse, yapılan çalışmanın ilk aşamasında, başlangıç küme merkez değerlerinin bölütleme açısından çok önemli bir kriter olduğu ortaya konulmuş ve başlangıç küme merkez değerlerinin rasgele veya doğrusal olmayan bir yöntemle atanması durumunda elde edilecek bölütleme görüntülerinin her tekrarda farklı sonuç verdiği tespit edilmiştir. Bu durum, görüntü analiz sistemleriyle kanser tanısı için istenmeyen bir durumdur. Bu nedenle kolon kanseri görüntü analiz sistemlerinde hızlı ve basit bir bölütleme işlemi yapmak için k-ortalamlar kümeleme algoritması ve ağırlıklı k-ortalamlar kümeleme algoritması yerine; aynı tutarlılıkta olan ve daha performanslı sonuçlar üreten geliştirilmiş k-ortalamlar kümeleme algoritması tavsiye edilmektedir.

Yapılan bu çalışmanın ikinci aşamasında ise evrişimli sinir ağları modellerinden AlexNet ve GoogLeNet modelleri kullanılarak kolon tümör sınıflandırması üzerine yeni bir yaklaşım uygulanmıştır. Bu yaklaşımda kolon tümörüne ait 136 iyi huylu tümör görüntüsü ve 152 kötü huylu tümör görüntüsü olmak üzere toplam 288 görüntü

kullanılmış ve bu görüntülerden birbirinden farklı kesitler alınarak 818 iyi huylu tümör görüntüsü ve 831 kötü huylu tümör görüntüsü elde edilmiştir. Sonraki aşamada ise gerçek dünya verisini temsil edecek şekilde dikey çevirme, yatay çevirme, görüntüyü 90°, 180° ve 270° döndürme ve gauss gürültüsü ekleme yöntemleri ile veri artırımı işlemleri uygulanmış ve derin öğrenme için 11543 görüntü elde edilmiştir. Derin öğrenme tabanlı yeni yaklaşımda, evrişimli sinir ağlarının orijinal-ham görüntüler kullanılarak eğitilmesi yerine, ilk aşamada uygulanan bölütleme yöntemi ile renk kümelerine bölütlenmiş görüntüler kullanılarak eğitilmesi önerilmiştir. Önerilen bu yaklaşımın performansını belirlemek için “par”, “par_ozel”, “bir” ve “bir_ozel” şeklinde olmak üzere hem orijinal görüntüler hem de bölütlenmiş görüntüler için oluşturulmuş toplam 20 farklı yapıda ve farklı özellikte veri setleri kullanılmıştır. Oluşturulan veri setleri AlexNet ve GoogLeNet evrişimli sinir ağları modellerinde kullanılarak eğitilmiş ve test edilmiştir. Test sonuçlarına göre karmaşıklık matrisleri oluşturulmuş, ROC eğrileri çizilmiş ve AUC değerleri hesaplanmıştır.

Sonuçlar karşılaştırıldığında, “par” veri seti kullanılarak yapılan model eğitiminde, bölütlenmiş görüntü kullanan AlexNet modelinin (%97,74), orijinal görüntü kullanılarak eğitilen AlexNet modeline (%97,15) göre %0,59 oranında bir fark ile daha iyi bir doğruluk performansı gösterdiği tespit edilmiştir. Model doğruluk performanslarının birbirine yakın değerlerde çıkmasının sebebinin, eğitim veri kümesi ile test veri kümesi arasında oluşabilecek bilgi sızmasından (information leak) kaynaklandığı düşünülmektedir. “bir” veri seti kullanılarak yapılan model eğitiminde ise %2,1 oranında bir fark ile bölütlenmiş görüntü kullanan AlexNet modelinin daha iyi bir doğruluk performansı gösterdiği tespit edilmiştir. “par_ozel” veri seti kullanılarak yapılan model eğitiminde, bölütlenmiş görüntü kullanan AlexNet modelinin, orijinal görüntü kullanılarak eğitilen AlexNet modeline göre %22,65 oranında; “bir_ozel” veri seti kullanılarak yapılan model eğitiminde ise %23,75 oranında bir fark ile daha iyi bir doğruluk performansı gösterdiği tespit edilmiştir. Sonuç olarak, bölütlenmiş görüntüler kullanılarak eğitilen AlexNet modelinin maksimum %23 oranında bir performans artışı gösterdiği tespit edilmiştir.

Aynı veri kümelerinin GoogLeNet derin öğrenme modeli ile eğitilmesi durumunda, bölütlenmiş görüntü kullanan GoogLeNet modelinin, orijinal görüntü kullanılarak eğitilen GoogLeNet modeline göre “par” veri seti için %1’den düşük bir fark ile daha iyi bir doğruluk performansı gösterdiği görülmüştür. Bunun yanı sıra, bölütlenmiş görüntü kullanan GoogLeNet modelinin; “bir” veri seti için %2,61 oranında bir fark ile daha iyi bir doğruluk performansı gösterdiği; “par_ozel” veri seti için %22,59 oranında bir fark ile daha iyi bir doğruluk performansı gösterdiği ve “bir_ozel” veri seti için ise %27,28 oranında bir fark ile daha iyi bir doğruluk performansı gösterdiği tespit edilmiştir. Sonuç olarak, bölütlenmiş görüntüler kullanılarak eğitilen GoogLeNet modelinin maksimum %27 oranında bir performans artışı gösterdiği tespit edilmiştir. Ayrıca kullanılan GoogLeNet modelinin, kolon tümör görüntülerinin iyi huylu tümör ve kötü huylu tümör olarak sınıflanmasında, AlexNet modeline göre daha başarılı olduğu görülmüştür. Bununla birlikte eğitim ve test veri setlerinde veri dağılımının dengesiz olduğu durumlarda (par_ozel ve bir_ozel veri setlerinde), standart derin öğrenme modellerinin model doğruluk performanslarının çok düşük olduğu ancak önerilen yaklaşımı kullanan derin öğrenme modellerinin model doğruluk performansının ise çok yüksek olduğu görülmüştür. Bu nedenle derin öğrenme tabanlı kolon tümör görüntü sınıflandırması için orijinal-ham görüntülerin kullanılması yerine, çalışmanın ilk aşamasında önerdiğimiz geliştirilmiş k-ortalamlar algoritması ile bölütlenmiş görüntülerin kullanılması model sınıflandırma başarısı açısından tavsiye edilmektedir.

Derin öğrenme yöntemleri büyük veri setlerinde daha iyi sonuçlar vermektedir. Bu nedenle bu çalışmalar çok daha büyük veri setleri kullanılarak geliştirilebilir. Ancak büyük veri setleri ile çalışmak daha fazla hesap yükünü ve işlem karmaşıklığını da beraberinde getirmektedir. Bunun için de daha güçlü donanım kullanılarak çalışılması tavsiye edilmektedir. Ayrıca bu çalışmada önerilen yaklaşım, AlexNet ve GoogLeNet modellerine ilave olarak diğer VGGNet, ResNet gibi modellerde kullanılarak ileri çalışmalar yapılabilir.

Bu çalışmada görüntülerin bölütlenmesi aşamasında önerilen geliştirilmiş k-ortalamlar kümeleme algoritmasında kullanılan ilk küme merkezi belirleme

yönteminin performansı rasgele ve doğrusal olmayan yöntemler ile karşılaştırılmıştır. Bu yöntem diğer rasgele örnekleme yöntemleri, mesafe optimizasyon yöntemleri ve yoğunluk tahmin yöntemleri gibi küme başlatma yöntemleri ile de karşılaştırılabilir. Ancak bu yöntemler seçilirken hızlı, kararlı ve hesaplama yükü düşük bir yöntem seçilmesi uygun olacaktır. Çünkü seçilen yöntem ile bölütlenen görüntüler derin öğrenme modellerinde girdi olarak kullanılacaktır. Bölütleme aşamasındaki işlem süresi ve işlem yükü derin öğrenme modelini ve tüm sistemi etkileyen önemli bir aşamadır. Örnek olarak süre açısından her bir görüntü için fazladan gelecek 1sn'lik işlem yükü bir milyon gibi büyük görüntü veri setlerinde yaklaşık 227 saatlik bir gecikmeye sebep olacaktır.



KAYNAKLAR

- Abutaleb, A.S. 1989. Automatic thresholding of gray level pictures using two-dimensional entropy. *Comput. Vision Graphics Image Process.*, 47: 22-32.
- Adams, R., Bischof, L. 1994. Seeded Region Growing. *IEEE Transactions on Pattern and Analysis and Machine Intelligence*, 16(6): 641-647.
- Al-Daoud, M.B. 2007. A New Algorithm for Cluster Initialization. *International Journal of Computer and Information Engineering*, 1(4): 1031-1033.
- Al-Daoud, M.B., Roberts, S.A. 1996. New methods for the initialisation of clusters. *Pattern Recognition Letters*, 17(5): 451-455.
- Albayrak, S. 2001. Color quantization by modified k-means algorithm. *Pakistan Journal of Applied Science*, 1(4): 508-511.
- Albayrak, S., Karşlıgil, M.Y. 2001. The color clustering in color images with weighted k-means method. 9th Signal Processing and Application Congress (SİU 2001), 609-614.
- Altunbay, D., Cigir, C., Sokmensuer, C., Gunduz-Demir, C. 2010. Color graphs for automated cancer diagnosis and grading. *IEEE Transactions on Biomedical Engineering*, 57(3): 665-674.
- Amidi, A., Amidi, S. 2019. Evrişimli Sinir Ağları El Kitabı (Çevirmen Kızrak, A., Kömeçoğlu, Y.). <https://stanford.edu/~shervine/1/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks/>, Erişim Tarihi: 15.05.2019.
- Andrej, K., Janez, B., Andrej, K. 2011. Introduction to the Artificial Neural Networks. *Artificial Neural Networks-Methodological Advances and Biomedical Applications*, Kenji Suzuki, IntechOpen, doi: 10.5772/15751.
- Arora, J., Khatter, K., Tushir, M. 2019. Fuzzy C-Means Clustering Strategies: A Review of Distance Measures. In *Software Engineering*, Springer, 153-162.
- Arthur, D., Vassilvitskii, S. 2007. k-means++: the advantages of careful seeding. *Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms*, Society for Industrial and Applied Mathematics Philadelphia, PA, USA, 1027-1035.
- Atalay, M., Çelik, E. 2017. Büyük Veri Analizinde Yapay Zeka ve Makine Öğrenmesi Uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22): 155-172.

- Awan, R., Al-Maadeed, S., Al-Saady, R. 2018. Using spectral imaging for the analysis of abnormalities for colorectal cancer: When is it helpful?. *PloS one*, e0197431, 13(6): 1-21.
- Ayech, M.W., Ziou, D. 2015. Segmentation of Terahertz imaging using k-means clustering based on ranked set sampling. *Expert Systems with Applications*, 42(6): 2959-2974.
- Basha, S.S., Ghosh, S., Babu, K.K., Dubey, S.R., Pulabaigari, V., Mukherjee, S. 2018. Rccnet: An efficient convolutional neural network for histological routine colon cancer nuclei classification. 15th International Conference on Control, Automation, Robotics and Vision (ICARCV), 1222-1227.
- Bengtsson, E., Wahlby, C., Lindblad, J. 2004. Robust cell image segmentation methods. *Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications*, 14(2): 157-167.
- BenTaieb, A., Kawahara, J., Hamarneh, G. 2016. Multi-loss convolutional networks for gland analysis in microscopy. *IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, 642-645.
- Bhargavi, K., Jyothi, S. 2014. A Survey on Threshold Based Segmentation Technique in Image Processing. *International Journal of Innovative Research & Development*, 3(12): 234-239.
- Boykov, Y., Funka-Lea, G. 2006. Graph cuts and efficient n-d image segmentation. *Int. J. Comput. Vision*, 70(2): 109-131.
- Boyle, P., Levin, B. 2008. *World Cancer Report 2008*. International Agency for Research on Cancer (IARC), Lyon-France.
- Bradley, P.S., Fayyad, U.M. 1998. Refining Initial Points for K-Means Clustering. In: *Proceedings of the 15th International Conference on Machine Learning (ICML98)*, 91-99.
- Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R.L., Torre, L.A., Jemal, A. 2018. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*, 68(6): 394-424.
- Bychkov, D., Turkki, R., Haglundb, C., Linder, N., Lundin, J. 2016. Deep learning for tissue microarray image-based outcome prediction in patients with colorectal cancer. In *Medical Imaging 2016: Digital Pathology*. International Society for Optics and Photonics, 9791: 1-6.
- Camilus, K.S., Govindan, V.K. 2012. A Review on Graph Based Segmentation. *I.J. Image, Graphics and Signal Processing*, 5: 1-13.
- Canny, J. 1986. A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(6): 679-698.
- Celebi, M.E., Kingravi, H.A., Vela, P.A. 2013. A comparative study of efficient initialization methods for the k-means clustering algorithm. *Expert Systems with Applications*, 40: 200-210.

- Chen, J., Shao, H., Hu, C. 2017. Colorimetry and Image Processing. In: Image Segmentation Based on Mathematical Morphological Operator, IntechOpen, 23-41.
- Cheng, C., Peng, G., Hwang, W. 2009. Subband Weighting With Pixel Connectivity for 3-D Wavelet Coding. *IEEE Transactions on Image Processing*, 18(1): 52-62.
- Cheng, G., Guo, W. 2017. Rock images classification by using deep convolution neural network. In *Journal of Physics: Conference Series*, IOP Publishing, 012089, 887(1): 1-6.
- Cheng, H.D., Jiang, X.H., Sun, Y., Wang, J. 2001. Color image segmentation: advances and prospects. *Pattern Recognition*, 34 (12): 2259-2281.
- Cirillo, M.D., Mirdell, R., Sjöberg, F., Pham, T.D. 2019. Tensor Decomposition for Colour Image Segmentation of Burn Wounds. *Scientific Reports*, 9(1): 3291.
- Cui, S., Wang, Y., Qian, X., Deng, Z. 2013. Image Processing Techniques in Shockwave Detection and Modeling. *Journal of Signal and Information Processing*, 4: 109-113.
- Çatal Reis, H., Bayram, B. 2016. Bone Tumor Segmentation From CT Images. *Sigma J. Eng. & Nat. Sci.*, 7(2): 173-180.
- De Maesschalck, R., Jouan-Rimbaud, D., Massart, D.L. 2000. The Mahalanobis distance. *Chemometrics and Intelligent Laboratory Systems*, 50: 1-18.
- Demir, C., Gultekin, S., Yener, B. 2005. Learning the topological properties of brain tumors. *Computational Biology and Bioinformatics*, *IEEE/ACM Transactions on*, 2(3): 262-270.
- Demiralay, M. 2005. Hiyerarşik kümeleme metotları ile veri madenciliği uygulamaları. Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- Deng, Y., Manjunath, B. S. 2001. Unsupervised segmentation of color-texture regions in images and video. *IEEE Trans. Pattern Anal. Mach. Intell.*, 23(8): 800-810.
- Diaz-Cely, J., Arce-Lopera, C., Mena, J.C., Quintero, L. 2019. The Effect of Color Channel Representations on the Transferability of Convolutional Neural Networks. In *Science and Information Conference*, Springer, Cham, 27-38.
- Doyle, W. 1962. Operations Useful for Similarity-Invariant Pattern Recognition. *Journal of the ACM (JACM)*, 9(2): 259-267.
- Ekicioglu, G., Ozkan, N., Salvaazar, E. 2005. Hematoksilen-eozin (hematoxylin-eosin). *Aegean Pthology Journal*, 2(2): 58-61.
- Elmas, Ç. 2016. Yapay Zeka Uygulamaları. Seçkin Yayıncılık, 3. Basım, Ankara, 1-448.
- Fabijanska, A. 2011. Graph Based Image Segmentation, *Automatyka*, 15(3): 93-103.
- Farjam, R., Soltanian-Zadeh, H., Jafari-Khouzani, K., Zoroofi, R. A. 2007. An image analysis approach for automatic malignancy determination of prostate pathological images. *Cytometry Part B: Clinical Cytometry*, 72B(4): 227-240.
- Felzenszwalb, P.F., Huttenlocher, D.P. 2004. Efficient graph-based image segmentation. *International journal of computer vision*, 59(2): 167-181.

- Forsyth, D.A., Ponce, J. 2012. *Computer Vision: A Modern Approach*, Second Edition, Pearson Education, 1-760.
- Fränti, P., Sieranoja, S. 2019. How much can k-means be improved by using better initialization and repeats? *Pattern Recognition*, 93: 95-112.
- Glasbey, C.A., Horgan, G.W. 1995. *Image Analysis for the Biological Sciences*, 1st Edition. Wiley Publisher, 1-230.
- GLOBOCAN 2018. Cancer Incidence and Mortality Worldwide. <http://globocan.iarc.fr/>, Erişim Tarihi: 01.09.2018.
- Goh, T.Y., Basah, S.N., Yazid, H., Safar, M.J.A., Saad, F.S.A. 2018. Performance analysis of image thresholding: Otsu technique. *Measurement*, 114: 298-307.
- Gonzalez, R.C., Woods, R.E. 2002. *Digital Image Processing*, 2nd Edition, Prentice-Hall, 1-793.
- Gonzalez, R.C., Woods, R.E. 2008. *Digital Image Processing*, 3rd Edition, Pearson Education International, 1-954.
- Gonzalez, R.C., Woods, R.E. 2014. *Sayısal Görüntü İşleme* (Telatar, Z., Tora, H., Arı, F., Kalaycıoğlu, A., Çev.). 3. Baskıdan Çeviri, Palme Yayıncılık, 1-954.
- Goodfellow, I., Bengio, Y., Courville, A. 2018. *Derin Öğrenme* (Yarman Vural, F., Cinbiş, R.G., Kalkan, S., Çev.). 1. Baskı, Buzdağı Yayınevi, Ankara, 1-848.
- Graham, S., Chen, H., Gamper, J., Dou, Q., Heng, P.A., Snead, D., Tsang, Y.W., Rajpoot, N. 2019. MILD-Net: Minimal information loss dilated network for gland instance segmentation in colon histology images. *Medical image analysis*, 52: 199-211.
- Graves, D., Pedrycz, W. 2010. Kernel-based fuzzy clustering and fuzzy clustering: a comparative experimental study. *Fuzzy Set. Syst.*, 161(4): 522-543.
- Gunduz-Demir, C. 2007. Mathematical modeling of the malignancy of cancer using graph evolution. *Mathematical Biosciences*, 209(2): 514-527.
- Gunduz-Demir, C., Kandemir, M., Tosun, A. B., Sokmensuer, C. 2010. Automatic segmentation of colon glands using object-graphs. *Medical Image Analysis*, 14(1): 1-12.
- Gülbağ, A. 2006. *Yapay Sinir Ağı ve Bulank Mantık Tabanlı Algoritmalar ile Uçucu Organik Bileşiklerin Miktersal Tayini*, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği EABD, Doktora Tezi.
- Halkidi, M., Batistakis, Y., Vazirgiannis, M. 2001. On Clustering Validation Techniques. *Journal of Intelligent Information Systems*, 17(2/3): 107-145.
- Hançer, E. 2016. *Yapay Arı Koloni Algoritması Tabanlı Görüntü Kümeleme Yöntemlerinin Geliştirilmesi*. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Doktora Tezi.
- Haykin, S. 2009. *Neural Networks and Learning Machines*. 3rd Edition, Pearson Education (US), New York, NY, United States, 936.

- He, J., Lan, M., Tan, C.L., Sung, S.Y., Low, H.B. 2004. Initialization of Cluster Refinement Algorithms: A Review and Comparative Study. *IEEE International Joint Conference on Neural Networks*, 1: 297-302.
- He, K., Zhang, X., Ren, S., Sun, J. 2016. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- He, Y., Ni, L.M. 2019. A Novel Scheme Based on the Diffusion to Edge Detection. *IEEE Transactions on Image Processing*, 28(4): 1613-1624.
- Hettiarachchia, R., Petersa, J.F. 2017. Voronoï region-based adaptive unsupervised color image segmentation. *Pattern Recognition*, 65: 119-135.
- Horowitz, S.L., Pavlidis T. 1974. Picture segmentation by a directed split-and-merge procedure. *Proceedings of the 2nd International Joint Conference on Pattern Recognition*, Copenhagen, Denmark, 424-433
- Howard, A., Rorres, C. 2014. *Elementary Linear Algebra (Applications Version)*. 11th Edition, Wiley, 131–182.
- Hussain, Z. 1991. *Digital Image Processing: Practical Applications of Parallel Processing Techniques*, 1st Edition, Ellis Horwood Limited, 1-406.
- Ioffe, S., Szegedy, C. 2015. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *arXiv preprint arXiv:1502.03167*.
- Isik, H., Sezgin, E., Avunduk, M.C. 2010. A new software program for pathological data analysis. *Comp. in Bio. and Med.*, 40(8): 715-722.
- Ismkhan, H. 2018. I-k-means+: An iterative clustering algorithm based on an enhanced version of the k-means. *Pattern Recognition*, 79: 402-413.
- İnik, Ö., Ülker, E. 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, 6(3): 85-104.
- Jahne, B. 2005. *Digital Image Processing*, 6th revised and extended edition, Springer, 1-597.
- Jain, K.A., Mao, J., Mohiuddin, K.M. 1996. Artificial Neural Networks: A Tutorial. *Computer*, 3: 31-44.
- Jeong, S. 2001. Histogram-Based Color Image Retrieval. *Psych221/EE362 project report*, 1-21.
- Jermyn, I.H., Ishikawa, H. 1999. Globally Optimal Regions and Boundaries. *Proc. Seventh Int'l Conf. Computer Vision*, 904-910.
- Jermyn, I.H., Ishikawa, H. 2001. Globally Optimal Regions and Boundaries as Minimum Ratio Cycles. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 23(10): 1075-1088.
- Jordan, M.I., Mitchell, T.M. 2015. Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245): 255-260.
- Juang, L.H., Wu, M.N. 2010. {MRI} brain lesion image detection based on color-converted k-means clustering segmentation. *Measurement*, 43(7): 941-949.

- Kainz, P., Pfeiffer, M., Urschler, M. 2017. Segmentation and classification of colon glands with deep convolutional neural networks and total variation regularization. *PeerJ*, 5:e3874, DOI:10.7717/peerj.3874
- Kalviainen, H., Hirvonen, P., Xu, L., Oja, E. 1995. Probabilistic and non-probabilistic hough transforms: overview and comparisons. *Image and Vision Computing*, 13(4): 239-252.
- Kancherla, K., Mukkamala, S. 2013. Early lung cancer detection using nucleus segmentation based features. *Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)*, 91-95. doi:10.1109/CIBCB.2013.6595393.
- Kanser Dairesi Başkanlığı 2019. Kanser Nedir. <https://hsgm.saglik.gov.tr/tr/kanser-nedir-belirtileri.html>, Erişim Tarihi: 20.01.2019.
- Kapade, S.D. 2015. Swarm intelligence based graph partitioning for image segmentation. Suresh Gyan Vihar University, Department of Mathematical Science, PhD Thesis.
- Kapur, J.N., Sahoo, P.K., Wong, A.K. 1985. A new method for gray- level picture thresholding using the entropy of the histogram. *Comput. Vision Graphics Image Process.*, 29: 273–285.
- Kara, F., İltar, H., Keskinliç, B. 2018. Türkiye Kanser İstatistikleri 2015. T.C. Sağlık Bakanlığı, Halk Sağlığı Genel Müdürlüğü, Ankara, 48.
- Karaş, İ.R. 2018. Graf Nedir? Nerelerde Kullanılır? http://web.karabuk.edu.tr/ismail.karas/759/Sunu1_esas.pdf, Erişim Tarihi: 5.11.2018.
- Kather, J. N., Krisam, J., Charoentong, P., Luedde, T., Herpel, E., Weis, C-A., Gaiser, T., Marx, A., Valous, N.A., Ferber, D., Jansen, L., Reyes-Aldasoro, C.C., Zornig, I., Jager, D., Brenner, H., Chang-Claude, J., Hoffmeister, M., Halama N. 2019. Predicting survival from colorectal cancer histology slides using deep learning: A retrospective multicenter study. *PLoS medicine*, e1002730, 16(1): 1-22.
- Kaur, M., Goyal, P. 2013. A Review on Region Based Segmentation. *International Journal of Science and Research (IJSR)*, 4(4): 3194-3197.
- Khan, A.M., Ravi, S. 2013. Image Segmentation Methods: A Comparative Study. *International Journal of Soft Computing and Engineering (IJSCE)*, 3(4): 84-92.
- Khan, M.W. 2014. A survey: Image segmentation techniques. *International Journal of Future Computer and Communication*, 3(2): 89-93.
- Khan, S.S., Ahmad, A. 2004. Cluster center initialization algorithm for k-means clustering. *Pattern Recognition Letters*, 25(11): 1293-1302.
- Khojasteh, P., Aliahmad, B., Kumar, D.K. 2019. A novel color space of fundus images for automatic exudates detection. *Biomedical Signal Processing and Control*, 49: 240-249.
- Kızrak, M.A., Bolat, B. 2018. Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3): 263-286.
- Konar, A. 2000. *Artificial Intelligence and Soft Computing: Behavioral and Cognitive Modeling of the Human Brain*. 1st Edition, CRC Press LLC, Boca Raton, 1-816.

- Kriesel, D. 2007. A Brief Introduction to Neural Networks <http://www.dkriesel.com/>, Erişim Tarihi: 20.04.2019
- Krizhevsky, A., Sutskever, I., Hinton, G. E. 2012. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* 25 (2), 1097–1105.
- Kumar, V.V., Rao, N.G., Rao, A.L.N., Krishna, V.V. 2009. IHBM: Integrated Histogram Bin Matching For Similarity Measures of Color Image Retrieval, *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 2(3): 109-120.
- Kurt, F. 2018. Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi. Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği EABD, Yüksek Lisans Tezi.
- LeCun, Y., Bengio, Y., Hinton, G. 2015. Deep learning. *Nature*, 521(7553): 436-444.
- LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W., Jackel, L.D. 1989. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4): 541–551.
- LeCun, Y., Boser, B.E., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W.E., Jackel, L.D. 1990. Handwritten digit recognition with a back-propagation network. In *Advances in neural information processing systems*, 396-404.
- LeCun, Y., Bottou, L., Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Lillie, R.D., Fullmer, H.M. 1976. *Histopathologic technic and practical histochemistry*. A Blakiston publication, McGraw-Hill, 1-942.
- Lin, C., Chen, C., Lee, H., Liao, J. 2014. Fast K-means algorithm based on a level histogram for image retrieval. *Expert Systems with Applications*, 41: 3276–3283.
- Lin, Z., Jin, J., Talbot, H. 2000. Unseeded region growing for 3D image segmentation. In *Selected papers from the Pan-Sydney workshop on Visualisation-Volume 2*, 31-37.
- MacQueen, J.B. 1967. Some Methods for Classification and Analysis of Multivariate Observations. In *Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability*, 281-297.
- Mahalanobis, P.C. 1936. On the generalised distance in statistics. *Proceedings of the National Institute of Sciences of India*, 2(1): 49-55.
- Marr, D., Hildreth, E. 1980. Theory of Edge Detection. *Proceedings of the Royal Society of London*, B207(1167): 187-217.
- MarTech 2019. Machine Learning for Smarter Marketing <http://vincejeffs.com/>, Erişim Tarihi: 01.04.2019.
- Mat-Isa, N.A., Mashor, M.Y., Othman, N.H. 2005. Seeded region growing features extraction algorithm; its potential use in improving screening for cervical cancer. *International Journal of the Computer, The Internet and Management*, 13(1): 61-70.

- Meila, M., Heckerman, D. 2001. An Experimental Comparison of Model-Based Clustering Methods. *Machine Learning*, 42: 9-29.
- Mercan, C.A. 2015. An Approach For The Chest Tube Detection in Chest Radiographs Using Convolutional Neural Network. İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, Hesaplamalı Bilim ve Mühendislik Anabilim Dalı, Doktora Tezi.
- Mignotte, M. 2008. Segmentation by fusion of histogram-based-means clusters in different color spaces. *Trans. Img. Proc.*, 17(5): 780-787.
- Morkūnas, M., Treigys, P., Bernatavičienė, J., Laurinavičius, A., Korvel, G. 2018. Machine learning based classification of colorectal cancer tumour tissue in whole-slide images. *Informatica*, 29(1): 75-90.
- Muthukrishnan, R., Radha, M. 2011. Edge Detection Techniques For Image Segmentation. *International Journal of Computer Science & Information Technology (IJCSIT)*, 3(6): 259-267.
- Naqvi, S.F.H., Ayubi, S., Nasim, A., Zafar, Z. 2019. Automated Gland Segmentation Leading to Cancer Detection for Colorectal Biopsy Images. In: *Future of Information and Communication Conference*. Springer, Cham, 75-83.
- Negnevitsky, M. 2005. *Artificial Intelligence: A Guide to Intelligent Systems*. Pearson Education Limited, Second Edition, England, 1-435.
- Ng, A., Mourri, Y.B., Katanforoosh, K. 2017. *Deep Learning Specialization: Convolutional Neural Networks*, Coursera, <https://www.coursera.org/learn/convolutional-neural-networks>, Erişim Tarihi: 03.07.2017.
- Nikhil, R.P., Sankar, K.P. 1993. A Review on Image Segmentation Techniques. *Pattern Recognition*, 26(9): 1277-1294.
- Otsu, N. 1979. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1): 62-66.
- Özkan, Y. 2008. *Veri Madenciliği Yöntemleri*, 1. Basım, Papatya Yayıncılık, 1-216.
- Öztemel, E. 2006. *Yapay Sinir Ağları*. Papatya Yayıncılık, 2. Basım, İstanbul, 1-232
- Pan, Z., Lu, J.A. 2007. Bayes-based region-growing algorithm for medical image segmentation. *Computing in Science Engineering*, 9(4): 32-38.
- Patil, D.D., Deore, S.G. 2013. Medical image segmentation: A review. *International Journal of Computer Science and Mobile Computing*, 2(1): 22-27.
- Pena, J.M., Lozano, J.A., Larranaga, P. 1999. An empirical comparison of four initialization methods for the K-Means algorithm. *Pattern Recognition Letters*, 20: 1027-1040.
- Pham, D.L., Xu, C., Prince, J.L. 2000. A survey of current methods in medical image segmentation. in: *Annual Review of Biomedical Engineering*, 2: 315-338.
- Pohle, R., Toennies, K.D. 2001. Segmentation of medical images using adaptive region growing. *Proc. SPIE*, 4322: 1337–1346. doi:10.1117/12.431013.

- Prasath, P., Perumal, K., Thangavel, K., Manavalan, R. 2014. A novel approach to gene selection of leukemia dataset using different clustering methods. in: G. S. S. Krishnan, R. Anitha, R. S. Lekshmi, M. S. Kumar, A. Bonato, M. Graa (Eds.), Computational Intelligence, Cyber Security and Computational Models, Advances in Intelligent Systems and Computing, Springer India, 246: 63-69.
- Prewitt, J.M.S. 1970. Object Enhancement and Extraction, in Picture Processing and Psychopictorics, Lipkin, B. and Rosenfeld, A., Eds., Academic Press, New York, 75-149.
- Pun, T. 1980. A new method gray-level picture thresholding using the entropy of the histogram. *Signal Process.*, 2: 223-237.
- Pun, T. 1981. Entropic thresholding: a new approach. *Computer Vision, Graphics and Image Processing*, 16: 210-239.
- Purutçuoğlu, V., Ayyıldız, E. 2014. *Biyoinformatik Alanında İstatistik*, 1. Basım, Nobel Yayıncılık, 1-244.
- Raza, S.E.A., Cheung, L., Shaban, M., Graham, S., Epstein, D., Pelengaris, S., Khan, M., Rajpoot, N.M. 2019. Micro-Net: A unified model for segmentation of various objects in microscopy images. *Medical image analysis*, 52: 160-173.
- Ridler, T., Calvard, S. 1978. Picture thresholding using an iterative selection method. *IEEE Transactions on Systems, Man and Cybernetics*, 8: 630-632.
- Roberts, L.G. 1965. Machine Perception of Three-Dimensional Solid, in *Optical and Electro-Optical Information Processing*, Tippet, J.T., Eds., MIT Press, Cambridge.
- Sachin, R., Sowmya, V., Govind, D., Soman, K.P. 2017. Dependency of various color and intensity planes on CNN based image classification. In *International symposium on signal processing and intelligent recognition systems*, Springer, Cham., 167-177.
- Sachs, H., Steibitz, M., Wilson, R.J. 1988. An Historical Note: Euler's Königsberg Letters. In *Journal of Graph Theory*, 12(1): 133-39.
- Sağlam, A., 2016. Minimum Yayılan Ağaç Tabanlı Sıralı Görüntü Bölütleme. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Saini, R., Dutta, M., Kumar, R. 2012. A comparative study of several image segmentation techniques. *Journal of Information and Operations Management*, 3(1):21-24.
- Sarkar, S., Soundararajan, P. 2000. Supervised learning of large perceptual organization: Graph spectral partitioning and learning automata. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 22(5): 504-525.
- Sathya, B., Manavalan, R. 2011. Image segmentation by clustering methods: Performance analysis. *International Journal of Computer Applications*, 29(11): 27-32.
- Senthilkumaran, N., Vaithegi, S. 2016. Image Segmentation by Using Thresholding Techniques for Medical Images. *Computer Science & Engineering: An International Journal (CSEIJ)*, 6(1): 1-13.

- Sezgin, M., Sankur, B. 2004. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, 13(1): 146-165.
- Shapiro, L.G., Stockman, G.C. 2001. *Computer Vision*, 1st Edition. Prentice Hall Publisher, 1-580.
- Sharma, N., Aggarwal, L.M. 2010. Automated medical image segmentation techniques. *Journal of Medical Physics*, 35(1): 3-14.
- Shi, J. Malik, J. 1997. Normalized cuts and image segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 731-737.
- Shi, J., Malik, J. 2000. Normalized cuts and image segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.*, 22(8): 888-905.
- Simonyan, K., Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Singh, K.K., Singh, A. 2010. A study of image segmentation algorithms for different types of images. *IJCSI International Journal of Computer Science Issues*, 7(5): 414-417.
- Sirinukunwattana, K., Pluim, J.P.W., Chen, H., Qi, X., Heng, P., Guo, Y.B., Wang, L.Y., Matuszewski, B.J., Bruni, E., Sanchez, U., Böhm, A., Ronneberger, O., Cheikh, B.B., Racoceanu, D., Kainz, P., Pfeiffer, M., Urschler, M., Snead, D.R.J., Rajpoot, N.M. 2017. Gland segmentation in colon histology images: The glas challenge contest. *Medical Image Analysis*, 35: 489-502.
- Sirinukunwattana, K., Raza, S.E.A., Tsang, Y.W., Snead, D.R., Cree, I.A., Rajpoot, N.M. 2016. Locality sensitive deep learning for detection and classification of nuclei in routine colon cancer histology images. *IEEE Transactions on Medical Imaging*, 35(5): 1196-1206.
- Sirinukunwattana, K., Snead, D.R.J., Rajpoot, N.M. 2015. A Stochastic Polygons Model for Glandular Structures in Colon Histology Images. *IEEE Transactions on Medical Imaging*, 34(11): 2366-2378.
- Smith, J.R., Chang, S.F. 1996. Tools and techniques for color image retrieval, In: *IST/SPIE-Storage and Retrieval for Image and Video Databases IV*, 2670, 426-437.
- Sobel, I., Feldman, G. 1968. A 3×3 Isotropic Gradient Operator for Image Processing. *The Stanford Artificial Intelligence Project*, 271-272.
- Sobel, I.E. 1970. *Camera Models and Machine Perception*, PhD Dissertation, Stanford University, California.
- Song, F., Wang, Y., Guo, Y., Zhu, C., Liu, J., Jin, M. 2018. A Channel-level Pruning Strategy for Convolutional Layers in CNNs. *International Conference on Network Infrastructure and Digital Content (IC-NIDC)*, 135-139.
- Stoer, M., Wagner, F. 1994. A Simple Min-Cut Algorithm. *Proceedings of the 2nd Annual European Symposium on Algorithms, Lecture Notes in Computer Science*, 855: 141-147.

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. 2015. Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. 2016. Rethinking the inception architecture for computer vision. IEEE Conference on Computer Vision and Pattern Recognition, 2818-2826.
- Szeliski, R. 2011. Computer Vision: Algorithms and Applications (Texts in Computer Science). 2011 Edition, Springer, 1-812.
- Tenekeci, M.E., Pehlivan, H., Gümüşçü, A., Karadağ, K. 2017. Vessel segmentation in angiography images with multi-scale filters. 2017 25th Signal Processing and Communications Applications Conference (SIU), Antalya, 1-4.
- Tiwari, S. 2018. An Analysis in Tissue Classification for Colorectal Cancer Histology Using Convolution Neural Network and Colour Models. International Journal of Information System Modeling and Design (IJISMD), 9(4): 1-19.
- Tobias, O.J., Seara, R. 2002. Image segmentation by histogram thresholding using fuzzy sets. IEEE Transactions on Image Processing, 11(12):1457-1465.
- Trussell, H.J. 1979. Comments on 'Picture thresholding using an iterative selection method'. IEEE Transactions on Systems, Man and Cybernetics, 9:1-311.
- Turing, A.M. 1950. Computing Machinery and Intelligence. Mind 49: 433-460.
- Vasuki, A., Govindaraju, S. 2017. Deep Neural Networks for Image Classification. Deep Learning for Image Processing Applications, 31:27-49.
- Verma, S., Khare, D., Gupta, R., Chandel, G. 2013. Analysis of image segmentation algorithms using matlab. in: V.V. Das (Ed.), Proceedings of the Third International Conference on Trends in Information, Telecommunication and Computing, Lecture Notes in Electrical Engineering, Springer New York, 150: 163-172.
- Wang, C., Shi, J., Zhang, Q., Ying, S. 2017. Histopathological image classification with bilinear convolutional neural networks. 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 4050-4053.
- Wang, S., Siskind, J. 2001. Image Segmentation With Minimum Mean Cut. Proceedings of the Eighth International Conference on Computer Vision, 1:517-524.
- Wang, S., Siskind, J.M. 2003. Image Segmentation with Ratio Cut. IEEE Transactions on Pattern Analysis and Machine Intelligence, 25(6): 675-690.
- Wang, Y.H. 2010. Tutorial: Image Segmentation. National Taiwan University, Taipei, 1-36.
- White, R.G. 1986. Low level segmentation of noisy imagery (No. RSRE-MEMO-3900). Royal Signals and Radar Establishment Malvern, United Kingdom.
- Xu, J., Luo, X., Wang, G., Gilmore, H., Madabhushi, A. 2016. A Deep Convolutional Neural Network for segmenting and classifying epithelial and stromal regions in histopathological images. Neurocomputing, 191: 214-223.

- Yarbuğ Karakayalı, F. 2019. Kolorektal Kanser Nedir. <http://www.fezyarbugkarakayali.com.tr/hastaliklar/kolon-ve-rektum-kanseri/kolorektal-kanser-nedir/>, Erişim Tarihi: 20.01.2019.
- Yogesani, K., Jrgensen, T., Albrechtsen, F., Tveter, K.J., Danielsen, H.E. 1996. Entropy-based texture analysis of chromatin structure in advanced prostate cancer. *Cytometry*, 24(3): 268-276.
- Yoon, H., Lee, J., Oh, J.E., Kim, H.R., Lee, S., Chang, H.J., Sohn, D.K. 2019. Tumor Identification in Colorectal Histology Images Using a Convolutional Neural Network. *Journal of digital imaging*, 32(1): 131-140.
- Yurtsever, M., Yurtsever, U. 2019. Use of a convolutional neural network for the classification of microbeads in urban wastewater. *Chemosphere*, 216: 271-280.
- Yurtsever, U., Evirgen, H., Avunduk, M.C. 2018. A New Augmented K-Means Algorithm for Seed Segmentation in Microscopic Images of the Colon Cancer. *Technical Gazette*, 25(2): 382-389.
- Zhaoa, W., Denga, C., Ngo, C. 2018. k-means: A revisit. *Neurocomputing*, 291: 195-206.
- Zweng, A., Rittler, T., Kampel, M. Evaluation of histogram-based similarity functions for different color spaces. in: P. Real, D. Diaz-Pernil, H. Molina-Abril, A. Berciano, W. Kropatsch (Eds.), *Computer Analysis of Images and Patterns*, Vol. 6855 of *Lecture Notes in Computer Science*, Springer Berlin Heidelberg, 2011, pp. 455-462. doi:10.1007/978-3-642-23678-5_54.

ÖZGEÇMİŞ

Ulaş Yurtsever, 1977 yılında Bingöl'de doğdu. İlk, orta ve lise eğitimini Antalya'da tamamladı. 1994 yılında Sakarya Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü'nü kazandı. 1 yıl İngilizce hazırlık eğitimi gördükten sonra lisans eğitimini 1999 yılında bitirdi. 2002 yılında Sakarya Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü'nde yüksek lisans eğitimini tamamladı. 1999 yılında Sakarya Üniversitesi'nde araştırma görevlisi olarak çalışmaya başladı aynı yıl içinde SAÜ Bilgi İşlem Dairesi Başkanlığı yazılım projelerinde görevlendirildi. Yazılım Teknolojileri Şube Müdürlüğünde çok sayıda yazılım projesinde görev aldı. Bilgi İşlem Dairesi Başkanlığında Yazılım Uzmanı, Veritabanı Yöneticisi, Proje Yöneticisi, Yazılım Grup Başkanı ve Yazılım Teknolojileri Şube Müdürü gibi farklı görevlerde bulundu. 2009 yılına kadar Sakarya Üniversitesi Veritabanı Yöneticisi görevini de yürüttü. 2005 yılında Sakarya Üniversitesi Bilgisayar Araştırma ve Uygulama Merkezi (BAUM)'nin kurulmasında görev aldı ve 2013 yılına kadar BAUM Müdür Yardımcısı olarak görev yaptı. 2013 yılından beri Sakarya Üniversitesi, Adapazarı Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü'nde Öğretim Görevlisi olarak görev yapmaktadır.