

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**DERİ LEZYON GÖRÜNTÜLERİNİN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
YÖNTEMLERİYLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Elif KANCA

**TEMMUZ 2023
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**DERİ LEZYON GÖRÜNTÜLERİNİN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
YÖNTEMLERİYLE SINIFLANDIRILMASI**

Elif KANCA

ORCID : - - -

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"BİLGİSAYAR YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 05 / 06 / 2023

Tezin Savunma Tarihi : 03 / 07 / 2023

Tez Danışmanı : Dr. Öğr. Üyesi Selen AYAS
ORCID : - - -

Trabzon 2023

ÖNSÖZ

Bu tez, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Bilimleri Yüksek Lisans Programı'nda yapılan bir çalışmadır. “Deri Lezyon Görüntülerinin Makine Öğrenmesi ve Derin Öğrenme Yöntemleriyle Sınıflandırılması” adlı çalışmada, deri lezyonlarına ait 2 farklı veri seti çeşitli makine öğrenmesi ve derin öğrenme yöntemleriyle bölütlenmiş ve sınıflandırılmıştır. Elde edilen sonuçlar birbirleriyle karşılaştırılarak bölütleme ve sınıflandırma başarısının artırılması için güncel yaklaşımlar ve bu yaklaşımların bölütleme ve sınıflandırma performansına olan etkileri araştırılmıştır.

Tez çalışması süresince ilgi ve desteğini her zaman hissettiğim danışman hocam Dr. Öğr. Üyesi Selen AYAS'a tavsiye ve tecrübeleri ile bana yol gösterdiği için teşekkür ediyorum.

Son olarak her koşulda yanımda olan anneme, babama ve kardeşlerime en içten sevgi, saygı ve teşekkürlerimi sunuyorum.

Elif KANCA

Trabzon 2023

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Deri Lezyon Görüntülerinin Makine Öğrenmesi ve Derin Öğrenme Yöntemleriyle Sınıflandırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Dr. Öğr. Üyesi Selen AYAS’ın sorumluluğunda tamamladığımı, çalışmalarını kendim yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 03/07/2023

Elif KANCA

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VIII
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XIII
SEMBOLLER DİZİNİ.....	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Literatür Taraması.....	2
1.3. Deri ve Deri Kanseri.....	4
1.3.1. Deri Kanserinde Tanı.....	7
1.3.2. Dermoskopi İnceleme Süreci.....	7
1.3.3. Türkiye ve Dünya’da Deri Kanseri.....	8
1.4. Önışlemler.....	8
1.4.1. Yeniden Boyutlandırma.....	9
1.4.2. DullRazor Algoritması.....	9
1.4.3. Veri Arttırma.....	11
1.5. Özellik Çıkarımı.....	11
1.5.1. Doku Özellikleri.....	11
1.5.2. Şekil Özellikleri.....	13
1.5.3. Renk Özellikleri.....	15
1.6. Görüntü Segmentasyonu.....	16
1.6.1 Otsu Eşikleme Yöntemi.....	16
1.6.2. Aktif Kontur Modeli.....	18
1.6.3. Tamamen Evrişimli Sinir Ağları.....	19
1.6.3.1. Tamamen Evrişimli Sinir Ağları Katmanları.....	19
1.6.3.1.1. Evrişim Katmanı.....	19
1.6.3.1.2. Aktivasyon Katmanı.....	21
1.6.3.1.3. Havuzlama Katmanı.....	22
1.6.3.1.4. Üst Örnekleme.....	23

1.6.3.1.5. Devrik Evrişim	23
1.6.3.1.6. Atlama Bağlantıları	24
1.6.3.1.7. Çıkış Katmanı	24
1.6.3.2. Tamamen Evrişimli Sinir Ağları Mimarileri	25
1.6.3.2.1. Tamamen Evrişimli Ağlar	25
1.6.3.2.2. U-Net	26
1.6.3.2.3. SegNet	27
1.6.3.2.4. DeepLabV3+	28
1.7. Sınıflandırma	30
1.7.1. k-NN	31
1.7.2. Destek Vektör Makineleri	32
1.7.3. Topluluk Öğrenme Yaklaşımları	33
1.7.3.1. AdaBoost Sınıflandırıcı	34
1.7.3.2. Gradyan Arttırma Sınıflandırıcı	35
1.7.3.3. Karar Ağacı Algoritması	36
1.7.3.4. Kolay Topluluk Sınıflandırıcısı	38
1.7.3.5. RUSBoost Sınıflandırıcı	39
1.7.3.6. Dengelenmiş Torbalama Sınıflandırıcısı	41
1.7.3.7. Dengelenmiş Rastgele Orman Sınıflandırıcısı	42
1.7.4. Evrişimli Sinir Ağları	43
1.7.4.1. Evrişimli Sinir Ağları Katmanları	43
1.7.4.1.1. Düzleştirme Katmanı	44
1.7.4.1.2. Tamamen Bağlı Katman	44
1.7.4.1.3. Softmax Katmanı	45
1.7.4.2. Evrişimli Sinir Ağı Modelleri	45
1.7.4.2.1. ResNet-200	45
1.7.4.2.2. EfficientNet	46
1.7.4.3. Evrişim ve Dikkat Ağlarının Birleşimi	48
1.7.4.3.1 CoAtNet	48
1.8. Derin Öğrenme Hiper Parametreleri	50
1.8.1. Devir Sayısı, Yığın Boyutu, Öğrenme Oranı ve Ağırlık Azalması	50
1.8.2. Optimizasyon Algoritması	51
1.8.2.1. Adaptive Moment Estimation(ADAM) Algoritması	51

1.8.2.2.	Çapraz- Entropi Kayıp Fonksiyonu.....	52
1.9.	Transfer Öğrenme.....	53
1.10.	k-kat Çapraz Doğrulama.....	53
1.11.	Performans Ölçüm Metrikleri.....	54
1.11.1.	Segmentasyon Performans Ölçüm Metrikleri	54
1.11.2.	Sınıflandırma Performans Ölçüm Metrikleri.....	55
2.	YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME	56
2.1.	Giriş.....	56
2.2.	Deri Kanserinin Otomatik Tanınması	57
2.2.1.	Veri Setleri.....	57
2.2.1.1.	ISIC2017.....	57
2.2.1.2.	ISIC2019.....	58
2.2.2.	Dermoskopi Görüntülerinin Makine Öğrenmesi ile Sınıflandırılması	59
2.2.2.1.	Önişlemler	59
2.2.2.2.	Dermoskopi Görüntülerinin Bölütlenmesi	60
2.2.2.2.1.	Otsu Metodu	60
2.2.2.2.2.	Aktif Kontur Modeli	62
2.2.2.3.	Dermoskopi Görüntülerinden Özellik Çıkarımı.....	63
2.2.2.4.	Dermoskopi Görüntülerinin Sınıflandırılması.....	63
2.2.2.4.1.	k-NN Yöntemi ile Sınıflandırma	63
2.2.2.4.2.	Destek Vektör Makineleri Yöntemi ile Sınıflandırma	66
2.2.2.4.3.	Kolay Topluluk Sınıflandırıcısı Yöntemi ile Sınıflandırma.....	67
2.2.2.4.4.	RusBoost Sınıflandırıcısı Yöntemi ile Sınıflandırma.....	69
2.2.2.4.5.	Dengelenmiş Torbalama Sınıflandırıcısı Yöntemi ile Sınıflandırma	73
2.2.2.4.6.	Dengelenmiş Rastgele Orman Sınıflandırıcısı Yöntemi ile Sınıflandırma	77
2.2.3.	Dermoskopi Görüntülerinin Tamamen Evrişimli Sinir Ağları ile Bölütlenmesi	78
2.2.3.1.	Verinin Arttırılması.....	78
2.2.3.2.	Tamamen Evrişimli Sinir Ağları ile Bölütleme.....	79
2.2.4.	Dermoskopi Görüntülerinin Derin Öğrenme ile Sınıflandırılması	81
3.	SONUÇLAR.....	83
4.	ÖNERİLER	85
5.	KAYNAKLAR.....	86
ÖZGEÇMİŞ		

ÖZET

DERİ LEZYON GÖRÜNTÜLERİNİN MAKİNE ÖĞRENMESİ VE
DERİN ÖĞRENME YÖNTEMLERİYLE SINIFLANDIRILMASI

Elif KANCA

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Selen AYAS
2023, 92 sayfa

Kanser, hücrelerin kontrolsüz bir şekilde bölünmesi ve yayılmasıdır. Deri kanseri diğer kanser türleri gibi erken teşhisi ve tedavisi oldukça önemli bir kanser türüdür. Tanı aşamasında kullanılan dermoskopi görüntülerini inceleyen kişilerin uzmanlığı, görüntülerdeki çeşitli artefaktlar gibi nedenler görüntüler manuel olarak incelendiğinde teşhis doğruluğunu düşürebilmektedir. Görüntülerin bilgisayar destekli uygulamalar ile incelenmesi daha kesin ve hızlı sonuçlar vermektedir. Ayrıca deri lezyonlarının sınıflandırılması ve segmentasyonu aşamasında da teşhis doğruluğunu düşürücü etkenleri ortadan kaldırmaktadır.

Bu çalışmada, 2 açık veri seti üzerinde segmentasyon ve sınıflandırma işlemleri gerçekleştirilmiştir. İlk olarak dermoskopi görüntülerine yeniden boyutlandırma, DullRazor algoritması gibi çeşitli ön işlemler uygulanmıştır. Otsu Eşikleme veya Aktif Kontur yöntemleriyle ön işlemleri tamamlanan görüntüler bölütlenmiştir. Ardından bölütlenmiş görüntülerin doku, şekil ve renk olmak üzere 13 farklı özellikleri çıkarılarak, özellikler k-NN, SVM, kolay topluluk sınıflandırıcı, RUSBoost Sınıflandırıcı, Dengelenmiş Torbalama Sınıflandırıcı gibi makine öğrenmesi yöntemleri ile sınıflandırılmıştır. Bunun yanı sıra derin öğrenme mimarileri olan ResNet, EfficientNet ve CoAtNet ile sınıflandırılmış ve U-Net, SegNet ve DeepLabv3+ ile segmentasyon işlemleri gerçekleştirilmiştir.

Anahtar Kelimeler: Dermoskopi görüntüsü, Sınıflandırma, Segmentasyon

Master Thesis

SUMMARY

CLASSIFICATION OF SKIN LESION IMAGES USING MACHINE LEARNING AND DEEP LEARNING TECHNIQUES

Elif KANCA

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Asst. Prof. Selen AYAS
2023, 92 Pages

Cancer is the uncontrolled division and spread of cells. Skin cancer, like other types of cancer, is a very important type of cancer for early diagnosis and treatment. Reasons such as the expertise of the people who examine the dermoscopy images used in the diagnosis phase and various artifacts in the images can reduce the diagnostic accuracy when the images are examined manually. Examination of images with computer aided applications gives more precise and faster results. In addition, it eliminates the factors that reduce the accuracy of diagnosis during the classification and segmentation of skin lesions.

In this study, segmentation and classification operations were performed on 2 open data sets. First, various pre-processes such as resizing and DullRazor algorithm were applied to dermoscopy images. The preprocessed images are segmented with Otsu Threshold or Active Contour methods. Then, 13 different features of the segmented images, such as texture, shape and color, were extracted and the features were classified by machine learning methods such as k-NN, SVM, easy ensemble classifier, RUSBoost Classifier, Balanced Bagging Classifier. In addition, it was classified with deep learning architectures ResNet, EfficientNet and CoAtNet, and segmentation operations were carried out with U-Net, SegNet and DeepLabv3+.

Key Words: Dermoscopy image, Classification, Segmentation

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1. Dermoskopi görüntülerindeki çeşitli artefaktlar	8
Şekil 1.2. GLCM yön bilgisi	12
Şekil 1.3. (a) 4x4 görüntü kesiti b) görüntüden GLCM oluşumu	12
Şekil 1.4. Dermoskopi görüntüsünün asimetri özelliği	14
Şekil 1.5. (a) Simetrik lezyon, (b) asimetrik lezyon	14
Şekil 1.6. Dermoskopi görüntüsünün çap özelliği	15
Şekil 1.7. Dermoskopi görüntülerindeki renk bileşenleri	16
Şekil 1.8. Evrişim Katmanı	20
Şekil 1.9. (a) ReLU, (b) Sigmoid, (c) Tanh ve (d) Softmax aktivasyon fonksiyonları	21
Şekil 1.10. Havuzlama katmanı	22
Şekil 1.11. Maksimum havuzlama geri yükleme	23
Şekil 1.12. Devrik evrişim	24
Şekil 1.13. Tamamen evrişimli sinir ağlarının katman yapısı	25
Şekil 1.14. Tamamen evrişimli sinir ağlarının genel yapısı	25
Şekil 1.15. U-Net mimarisinin katman yapısı	26
Şekil 1.16. SegNet mimarisinin katman yapısı	27
Şekil 1.17. DeepLabV3+ mimarisinin katman yapısı	29
Şekil 1.18. Atrous yapısı	30
Şekil 1.19. 2 boyutlu özellik uzayında örneğin k-NN algoritmasıyla sınıflandırılması	31
Şekil 1.20. Doğrusal ayrılabilen iki sınıf aracılığıyla hiper düzlemin gösterimi	32
Şekil 1.21. Doğrusal ayrılamayan iki sınıf aracılığıyla hiper düzlemin gösterimi	33
Şekil 1.22. Zayıf öğrencilerin ağırlıklarının değişim gösterimi	34
Şekil 1.23. Örnek bir karar ağacı yapısı	36
Şekil 1.24. Kolay topluluk sınıflandırıcısının çalışma mantığı	38
Şekil 1.25. RUSBoost sınıflandırıcısının çalışma mantığı	40
Şekil 1.26. Rastgele orman sınıflandırıcısı çalışma mantığı	42
Şekil 1.27. Evrişimsel sinir ağlarının katman yapısı	43
Şekil 1.28. Düzleştirme katmanı ve tamamen bağlı katman yapısı	44
Şekil 1.29. ResNet-200 ağının katman yapısı	45
Şekil 1.30. EfficientNet-B0 ağının katman yapısı	46

Şekil 1.31. MBConv bloğunun katman yapısı.....	47
Şekil 1.32. Squeeze and Excitation Bloğu.....	47
Şekil 1.33. CoAtNet mimarisinin katman yapısı.....	48
Şekil 1.34. k-kat çapraz doğrulama aşamaları.....	53
Şekil 1.35. Doğruluk matrisi	54
Şekil 2.1. Tez kapsamı.....	57
Şekil 2.2. ISIC 2017 veri setinin birinci sınıflandırma probleminde yer alan eğitim görüntüleri örnekleri: üst satır: melanom; alt satır: nevus ve seboreik keratoz....	58
Şekil 2.3. ISIC 2019 veri kümesindeki her sınıfa ait örnek görüntüler. Sol üstten sağa: Aktinik keratoz, bazal hücreli karsinom, iyi huylu keratoz, dermatofibroma, melanom, melanosit nevus, skuamöz hücreli karsinom ve vasküler lezyon.....	58
Şekil 2.4. (a) Örnek dermoskopi görüntüsü, (b) Örnek dermoskopi görüntüsünün 224x224 boyutlarına ölçeklendirilmesi.....	59
Şekil 2.5. (a) Önişlem uygulanmamış görüntü, (b) DullRazor algoritması uygulanmış görüntü.....	60
Şekil 2.6. (a) Örnek dermoskopi görüntüsü, (b) maske görüntüsü, (c) Otsu eşikleme ile oluşturulan segmentasyon görüntüsü	61
Şekil 2.7. (a) Örnek görüntü, (b) aktif kontur yöntemi ile bölütlenmiş görüntü, (c) maske görüntüsü, (d) doku görüntüsü	63
Şekil 2.8. Yakın komşuların ağırlıklarının arttırılmasıyla oluşan k-NN sonuçları.....	65
Şekil 2.9. Komşulara herhangi bir ağırlık vermeden oluşan k-NN sonuçları.....	65
Şekil 2.10. Veri setindeki verilerin dağılımları dengeli olduğunda SVM sonuçları.....	66
Şekil 2.11. Veri Setindeki Verilerin Dağılımları Dengesiz Olduğunda SVM sonuçları.....	67
Şekil 2.12. Veri setindeki verilerin dağılımları dengesiz olduğunda dengelenmiş rastgele orman sınıflandırıcı sonuçları	77
Şekil 2.13. Veri setindeki verilerin dağılımları dengeli olduğunda dengelenmiş rastgele orman sınıflandırıcı sonuçları	78
Şekil 2.14. Melanom sınıfının veri arttırma yöntemi ile arttırılmış görüntüleri. Üst satır: sağa sırasıyla orijinal, 90°, 180° ve 270° döndürme ile oluşan görüntüler. Alt satır: üst satırdaki görüntülerin yatay olarak çevrilmiş görüntüleri	79

Şekil 2.15. Segmentasyon için ağırlıklı oylama	80
Şekil 2.16. Segmentasyon modellerinin görsel sonuçları, (a) gerçek segmentasyon, (b) tamamen evrişimli ağ, (c) U-Net, (d) SegNet, (e) DeepLabV3+ ve (f) önerilen topluluk modeli.....	81



TABLÖLAR DİZİNİ

Sayfa No

Tablo 2.1. k-NN Sınıflandırma Sonuçları	64
Tablo 2.2. Kolay topluluk ve Adaboost sınıflandırıcısı ile elde edilen sınıflandırma sonuçları	68
Tablo 2.3. RusBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 50 olduğu sınıflandırma sonucu	69
Tablo 2.4. RusBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 100 olduğu sınıflandırma sonucu	70
Tablo 2.5. RusBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 150 olduğu sınıflandırma sonucu	71
Tablo 2.6. RusBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 200 olduğu sınıflandırma sonucu	71
Tablo 2.7. RusBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 250 olduğu sınıflandırma sonucu	72
Tablo 2.8. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 50 olduğu sınıflandırma sonucu	73
Tablo 2.9. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 100 olduğu sınıflandırma sonucu	74
Tablo 2.10. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 150 olduğu sınıflandırma sonucu.....	75
Tablo 2.11. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 200 olduğu sınıflandırma sonucu.....	75
Tablo 2.12. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 250 olduğu sınıflandırma sonucu.....	76
Tablo 2.13. Tamamen evrişimli sinir ağlarının segmentasyon metrik sonuçları.....	80
Tablo 2.14. ResNet-200, EfficientNet-B7, CoAtNet-0 ve CoAtNet-1 sınıflandırma metrikleri sonuçları.....	82

SEMBOLLER DİZİNİ

ABD	: Amerika Birleşik Devletleri
ABCD	: Asymetry Border Color Diameter
CIELAB	: Commission on Illumination L^*A^*B
CNN	: Convolutional Neural Networks
DNA	: Deoxyribonucleic Acid
DOG	: Difference of Gaussians
FCN	: Fully Convolutional Network
GLCM	: Gri Seviye Eş Oluşum Matrisi
HOG	: Histogram of Oriented Gradients
HSV	: Hue, Saturation, Value
ISIC	: International Skin Imaging Collaboration
k-NN	: k-en yakın komşuluk
ReLU	: Rectified Linear Unit
RGB	: Red, Green, Blue
SVM	: Support Vector Machine

1. GENEL BİLGİLER

1.1. Giriş

Kanser, insan sağlığını etkileyen en büyük sağlık sorunlarından birisidir. Uluslararası Kanser Araştırma Ajansı'nın (IARC) 2020 yılında yayımladığı rapora göre, dünya genelinde melanom hariç 18.1, toplamda 19.3 milyon yeni kanser vakası ve yaklaşık olarak melanom hariç 9.9, toplamda 10 milyon ölüm vakası olacağı bildirilmiştir [1]. Amerikan Kanser Derneği'nin 2023 yılı raporuna göre 89070 yeni vaka ve 7990 ölüm ile ABD'de en çok teşhis edilen kanser türüdür [2]. Deri kanseri diğer kanser türleri gibi erken teşhis edildiğinde tedavide ve cerrahi işlemlerde daha olumlu sonuçlar alınmaktadır ve kanserin tedavi maliyetleri azalmaktadır [3].

Deri lezyonlarından elde edilen dermoskopi görüntüleri dermatologlar tarafından tanı için kullanılmaktadır. Ancak, insan görüşü ile yapılan inceleme öznel, zaman alıcı ve hataya meyilli olmakla birlikte tecrübeli dermatologlar arasında bile farklı teşhis sonuçlarının ortaya çıkmasına sebep olmaktadır. Dermoskopi görüntülerinde bulunan vücut kılları, mürekkep izleri, cetvel izleri, jel görünimleri gibi çeşitli artefaktlar da tanı doğruluğu düşmektedir. Bu sebeple bilgisayarlı otomatik teşhis dermatologlar tarafından deri lezyonlarının tanısı aşamasında sıklıkla kullanılmaktadır.

Bu tez çalışmasında bölütlenen dermoskopi görüntülerinden çıkarılan çeşitli özellikler ilk olarak k-NN sınıflandırıcı ile sınıflandırılmıştır. Veri setinde bulunan sınıflardaki veri sayılarının dengesiz ayrılması sebebiyle sınıflandırma doğruluğunu arttırmak adına farklı bölütleme tekniği ile bölütlenmiş görüntüler k-NN sınıflandırıcıda kullanılan aynı özellikler çıkarılarak SVM, çeşitli topluluk algoritmaları ile sınıflandırılmış ve sınıflandırma başarıları arttırılmıştır. Veri setinin geleneksel makine öğrenmesi yöntemleriyle sınıflandırılmasından sonra veriler çeşitli evrimsel sinir ağları, evrimsel sinir ağlarının ve öz-dikkat mekanizmasının birlikte kullanıldığı popüler modeller ile sınıflandırılmış ve başarıları karşılaştırılmıştır. Veri setinin segmentasyonu için dört farklı tamamen evrimsel sinir ağı kullanılmıştır ve bu dört modelin çıktısı için ağırlıklı çoğunluk oylaması yapılarak segmentasyon başarıları arttırılmıştır. Çalışmada programlama dili olarak MATLAB ve Python kullanılmıştır.

1.2.Literatür Taraması

Deri lezyon analizinin otomatikleştirilmesi için yapılan çalışmalar incelenirken tez kapsamında kullanılan veri setleriyle yapılan sınıflandırma çalışmaları özetlenmiştir.

Vidya vd. [4], deri lezyonunun renk, sınır, simetri ve çap özellikleri için ABCD kuralı, doku özellikleri için GLCM, şekil ve kenar özellikleri için HOG özellik çıkarımını kullanmışlardır. Sınıflandırma için k-NN yöntemi kullanılarak duyarlılık ve özgüllük değerleri sırasıyla %86.2 ve %85 olarak hesaplanmıştır.

Çelebi vd. [5], otomatik sınır algılama yöntemi ile deri lezyon bölgesini arka plan piksellerinden ayırmışlardır. Lezyon bölgesinden çıkarılan şekil, renk ve doku özellikleri özellik seçim algoritması ile belirlenmiş ve belirlenen özellikler destek vektör makinaları ile sınıflandırılmıştır. Sınıflandırma sonucunda %92 duyarlılık elde edilmiştir.

Chang vd. [6], lezyonların renk, şekil ve doku özelliklerini kullanarak lezyonları destek vektör makineleri ile sınıflandırmışlardır ve %85.63 duyarlılık ve %90.64 özgüllük elde etmişlerdir.

Daghrir vd. [7], International Skin Imaging Collaboration 2017 veri setindeki iyi ve kötü huylu lezyonları içeren 640 dermoskopi görüntüsü kullanarak k-NN, SVM ve oluşturdukları 9 katmanlı CNN sınıflandırıcısını kullanarak nihai sonucu çoğunluk oylamasının verdiği bir yöntem sunmuşlardır. Sırayla uygulanan DOG filtresi, Otsu yöntemi, morfolojik genişleme ve kıl maskesi ile kıl artefaktları kaldırılır. Bölütleme için MorphGAC kullanıldıktan sonra oluşturulan lezyonların dokusal, renk ve sınır özellikleri belirlenir. k-NN, SVM, CNN ve çoğunluk oylamasında sırasıyla %57.3, %71.8, %85.5 ve %88.4 doğruluk elde etmişlerdir.

Serener vd. [8], AlexNet, ResNet-18 ve ResNet-50 ağlarını kullanarak International Skin Imaging Collaboration 2019 veri setindeki skuamöz hücreli karsinom ve bazal hücreli karsinom örneklerini sınıflandırmışlardır. Sınıflandırma sonucunda en yüksek karakteristik eğri performansı 0.80 olarak bulunmuştur.

Steppan vd. [9], ISIC 2019 veri setini kullanarak ilk olarak kenarları siyah olan dermoskopi görüntülerini kaldırmışlardır. Ardından çevirme, döndürme ve ölçeklendirme işlemleriyle görüntü sayısı arttırılmıştır. Görüntülerin sınıflandırılması için ImageNet ile önceden eğitilmiş EfficientNet-B4 ve EfficientNet-B5 ağlarını kullanmışlardır. Model

tahminleri, ters sınıf frekansı ile çarpılıp gerçek olasılık dağılımlarına yaklaşılmak için normalleştirilir. Sonuç aşamasında, EfficientNet-B4 ve EfficientNet-B5 ağıları için sırasıyla 0.57 ve 0.60 doğruluk elde etmişlerdir.

Deri lezyon analizinin otomatikleştirilmesi için yapılan çalışmalar incelenirken tez kapsamında kullanılan veri setleriyle yapılan segmentasyon çalışmaları özetlenmiştir.

Jaisakthi vd. [10], International Skin Imaging Collaboration 2017 veri setinin segmentasyonu için ön işleme ve yarı denetimli öğrenme algoritmasından oluşan bir yöntem oluşturmuşlardır. Ön işleme aşamasında görüntülerdeki çeşitli gürültüler, filtreleme tekniği kullanılarak giderilmişlerdir. Görüntüler kullanılarak oluşturulan histogram yardımı ile deri lezyonlarının renkleri belirlenmiş ve aynı renkteki deri lezyonları k-ortalama kümeleme ile renk özelliklerine göre bölümlere ayrılmıştır. Elde edilen bölümlerden cilt lezyonları, flood fill algoritması ve bağlantılı bileşen etiketleme kullanılarak bölümlere ayrılır. Segmentasyon sonucunda doğrulama seti için 0,548 puan elde edilmiştir. Doğrulama seti için yüksek hassasiyet ve doğruluk, düşük Jaccard indeks değeri elde edildiği belirtilmiş ancak sonuçlar verilmemiştir.

Li vd. [11], International Skin Imaging Collaboration 2017 veri setini kullanarak segmentasyon için iki farklı tamamen evrişimli artık ağ önermişlerdir. İlk olarak dermoskopi görüntüleri merkezi kalacak şekilde kesilmiş ve yeniden ölçeklendirilmiştir. Veri setinde bulunan sınıflar veri dengesizliği problemini aşacak şekilde farklı açılarda döndürülmüş ve veri sayısı arttırılmıştır. Segmentasyon sonucunda Jaccard indeksi değeri 0,75 olarak bulunmuştur.

Yuan vd. [12], RGB renk kanallarına ek olarak HSV renk uzayı ve CIELAB renk uzayındaki L kanalı kullanmışlardır. 29 katmandan oluşan tamamen konvolüsyonel-dekonvolüsyonel sinir ağı ile segmente edilen International Skin Imaging Collaboration 2017 dermoskopi görüntülerinde sonuç olarak ortalama 0.784 Jaccard indeksi elde etmişlerdir.

Huang vd. [13], deri lezyonu segmentasyonu için O şeklinde yinelemeli bir dikkat sınıfı özelliğinden yararlanan tekrarlanan dikkat konvolüsyon ağı(O-Net) önermişlerdir. O-Net segmentasyon sonucunda oluşan özellik haritalarını ağa yinelemeli bir şekilde girdi olarak verir. Bu sayede kabadan inceye doğru dikkat özellik bilgileri çıkarılır. O-Net,

International Skin Imaging Collaboration 2017 veri setinde %87,04 Jaccard indeksi ve %80,36 Dice katsayısı sonuçları elde etmiştir.

Goyal vd. [14], çok sınıflı semantik segmentasyon için tamamen evrişimli ağ önermişlerdir. Tamamen evrişimli ağın performansını arttırmak için hibrit bir kayıp işlevi ve iki katmanlı transfer öğrenme kullanmışlardır. Oluşturulan ağı International Skin Imaging Collaboration 2017 veri setinde değerlendirmiş ve çok sınıflı segmentasyonda FCN-8, nevus sınıfında %78,5, melanom sınıfında %65,3 ve seboreik keratoz sınıfında %55,7 Dice skoru ve %84,62 genel doğruluk elde etmişlerdir.

Gilani vd. [15], lezyon sınırlarını bölümlere ayırmak için ResNet ve U-Net mimarilerini birleştiren Res-Unet toplu mimarisi önermişlerdir. Görüntüler ağa girmeden önce görüntü iç boyama yöntemi kullanarak International Skin Imaging Collaboration 2017 veri setiyle eğitilen 0,772 Jaccard indeksi elde etmişlerdir.

Akyel vd. [16], LinkNet ve EfficientNet modellerinin iyi özelliklerini kullanarak LinkNet-B7 modeli önermişlerdir. Bu model ile veri kaybını en aza indirmek için görüntüler 16 dilime ayırmışlardır. Gürültü giderme aşamasında, kıl, jel ve su kabarcıkları, mürekkep ve cetvel izleri, bazı görüntülerde bulunan siyah çerçeveler de giderilmiştir. Gürültü giderme ve sonrasında lezyon segmentasyonu için doğruluk değerleri sırası ile %95,72 ve %97,80 olarak hesaplanmıştır.

Khan vd. [17], DenseNet77 kodlayıcı tabanlı Unet mimarisi sunmuşlardır. DenseNet77 kodlayıcısında hesaplanan kilit noktalar, U-Net mimarisinin kod çözücüsü tarafından bölümlere ayrılır. Bu mimaride International Skin Imaging Collaboration 2017 veri setinde %99,21 segmentasyon doğruluğu elde edilmiştir.

1.3.Deri ve Deri Kanseri

Deri, insan vücudun dış yüzeyini kaplayan ve koruyan en büyük organıdır. İnsan derisinin toplam yüzeyi $1.6-1.85 m^2$ ve yağsız ağırlığı 3.5 kilogramdır [18]. Kalınlığı 1 mm'nin onda biri olan deri, epidermis, epidermisin altındaki dermis ve en alt tabaka olan deri alt dokusu olmak üzere üç katmandan oluşmaktadır. Epidermis, deri tabakasının en dış kısmını oluşturur, su geçirmez bir bariyer sağlar ve deri tonunun oluşmasında etkilidir.

Epidermisin kalınlığı, avuç içi ve ayak tabanı gibi temas gerektiren noktalarda 1 mm kadardır ve stratum basale(bazal hücre tabakası), stratum spinosum, stratum granulosum(granüler tabaka), stratum lucidum(önleyici tabaka) ve stratum corneum(boynuzsu tabaka) olmak üzere 5 ana bölümden oluşmaktadır. Epidermis, stratum basale, stratum spinosum, stratum granulosum ve stratum corneum olmak üzere 4 ana bölümden oluşmaktadır. Temel maddesi deriye dayanıklılık sağlayan kolajen olan dermis katmanı, bağ dokusu, kıl folikülleri, kan damarları, lenfatik damarlar ve ter bezleri içermektedir ve deri metabolizmasına yardımcı olmaktadır. Dermis, papiller dermis(üst alt tabaka) ve retiküler dermis(alt tabaka) olmak üzere iki ana tabakadan oluşmaktadır. Deri alt dokusu ise yağ ve bağ dokudan oluşmaktadır. Bu doku sayesinde deri kemiklerin üzerinde kalır ve deri vücuda bağlanmış olur [19,20].

Derinin temel olarak işlevlerinden olan buharlaşma, terleme gibi yöntemlerle ısıyı koruyarak veya serbest bırakarak termal dengenin ve su dengesinin düzenlenmesine yardımcı olur. Deri, sağlam ve esnek yapısı sayesinde dışarıdan gelen ultraviyole ışığa, çeşitli mikroorganizmalara ve fiziksel hasarlara karşı koruma sağlar. Deride bulunan kıllar ve sinirler sayesinde üç çeşit dokunma duyusu olan basınç(ağrı), şekil(dokunma) ve ısı hissedilir. Deri, patojenlerin vücuda girişini engelleyerek bağışıklık gelişimi sağlamaktadır. Kalsiyum emilimi ve D vitamini sentezi gibi kimyasal süreçlerin başlatıldığı endokrin aktivite; su, üre ve amonyak salınımı gibi ekzokrin aktiviteyi gerçekleştirir [19,20].

Deri kanseri, mutasyonları tetikleyen onarılmamış DNA hasarının neden olduğu en dış deri tabakasını olan epidermisteki hücrelerde meydana gelen kontrol dışı büyümedir. Bu mutasyonlar anormal deri hücrelerinin hızla çoğalmasına ve kötü huylu tümörlerin oluşmasına neden olur. Deri kanseri; deri tonu, deri kanserinin boyutu, türü ve vücuttaki konumu nedeniyle bir kişiden diğerine göre oldukça farklılık gösterebilir [21].

Deri kanserinin bazı türleri şu şekildedir:

- Bazal hücreli karsinom, epidermisin bazal tabakasından kaynaklanan, yavaş büyüyen ve lokal olarak doku hasarı oluşturabilen bir deri tümörüdür. Kıl folikülü bulunan epidermisten köken alan bazal hücreli karsinoma derinin en sık görülen malin tümörüdür. Metastaz potansiyeli çok düşük olmasına karşın, lokal olarak vücut bütünlüğünü bozma özelliğine sahiptir [22].

- Skuamöz hücreli karsinom, deri ve mukozalardaki epitelyal keratinositlerden kaynaklanan, hızlı büyüyen, lokal vücut bütünlüğünü bozma ve metastaz özellikleri bulunan bir tümördür [22].
- Melanom, vücutta bulunan nöro ektodermal kökenli pigment üreten hücreler olan melanositlerin bir tümör çeşididir [23].
- Melanosit nevus, halk dilinde ben olarak bilinen deri rengine, mavi, kırmızı-kahverengi ya da siyah renkte olan lezyonlardır. Açık deri tipi, çil, açık saç ve göz rengine sahip kişilerde daha sık görülmektedir [24].
- Aktinik keratoz, yaşlı kişilerin kontrolsüz güneşte kalmasına bağlı olarak güneşte kalan bölgelerinde görülen anormal hücre değişikliğidir. Erken tanısı ve tedavisi yapılmadığında skuamöz hücreli karsinom yani kanser olma olasılığı vardır [25].
- İyi huylu keratoz(Güneş lentigo/seboreik keratoz/ planus benzeri keratoz), orta yaş ve üzeri kişilerde sıklıkla vücudun yüz, sırt ve göğüs gibi bölgelerinde, dermatologlar tarafından tanısı diğer lezyonlara göre bir nevi daha kolay olan bir deri lezyonudur. Bu lezyonlar deriye yapışmış olarak görünürler ve ten rengi/sarımsı, gri-kahverengi ve siyah olabilirler [26].
- Dermatofibroma, deri dermisini merkez edinmiş yaygın olarak herhangi bir yerinde görülen pembe/açık kahverengi veya koyu kahverengi/siyah renkte olabilen lezyonlardır [27,28]. Genellikle herhangi bir soruna neden olmamakla birlikte bazen ağrılı, hassas veya kaşıntıya neden olabilirler [28].
- Vasküler lezyon, genellikle bebek ve çocuklarda baş ve boyun bölgelerinde görülen hücre bozukluklarıdır [29]. Vasküler lezyonun lazer ile tedavisi son yıllarda sık kullanılan bir yöntem haline gelmiştir [30].
- Bu türler dışında daha az rastlanan türler de bulunmaktadır.

Deri kanserinin temel nedenlerinden güneşin zararlı ultraviyole(UV) ışınları ve UV solaryum kullanımı, bireyin açık tenli ya da çilli olması, ailede deri kanseri geçmişi olması, vücuttaki ben sayısının fazla olması, radyasyona yoğun şekilde maruz kalmak, bağışıklık sisteminin zayıf olması [31] olarak sıralanabilir.

1.3.1. Deri Kanseri Tanı

Deri kanseri diğer kanser türleri gibi erken teşhis edildiğinde, dermatologlar tarafından tedavi edilebilir ve tamamen ortadan kaldırılma olasılığı yüksektir. [31] numaralı referansa göre deri kanserinde yaygın görülen belirtiler şu şekildedir:

- Deride yeni bir lezyon veya mevcut olan lezyonun şeklinde, boyutunda ve rengindeki değişiklik
- Ağrılı veya kaşıntılı lezyon
- İyileşmeyen yara
- Pullu, kabuklu bir yüzeye sahip lezyon

1.3.2. Dermoskopi İnceleme Süreci

Dermatoskopi olarak da bilinen dermoskopi, farklı büyütme teknikleri, polarize olmayan ışık ve yüzey yansımalarını engelleyecek bir sıvı veya sadece polarize ışık kullanılarak deri bütünlüğünü bozmadan epidermis, yüzeysel damar ağ tabakası gibi derinin bütün katmanlarının değerlendirilmesine olanak sağlayan bir tanı sistemidir [32]. Dermatoskop, deri yüzeyi mikroskopisidir ve deride bulunan lezyonların tanısında dermatologlar tarafından riski incelemek ve erken tanı koymak için kullanılan bir cihazdır. Geleneksel dermatoskop cihazı ile deriye belirli açılarla ışık gönderilir ve deriden yansıyan ışık değerlendirilir. Dijital dermatoskop bilgisayara entegre edilmiş dermoskopi cihazı ile oluşturulmuş sistemi ifade etmektedir. Bu görüntüleme sistemi çok küçük olan deri lezyonlarını daha yakından incelenebilmektedir. Dijital dermatoskopi sayesinde görüntüler 10-100 kat büyütülür ve lezyonların olduğu bölgeler işaretlenerek sisteme kaydedilir. Dijital dermatoskopi sayesinde daha önce kaydedilmiş olan görüntüler incelenebilir ve bu görüntülerden risk skoru oluşturulabilir. Oluşturulan risk skoru neticesinde lezyonun alınıp alınmayacağı veya takip edileceğine dermatolog karar verir. Takip edilmesine karar verilen lezyonların kaydedilmiş görüntüleri sayesinde ilerideki muayenelerde lezyonların özelliklerindeki değişimler incelenebilir [33].


1.3.3. Türkiye ve Dünya’da Deri Kanseri

Türkiye Cumhuriyeti Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü Türkiye Kanseri İstatistikleri 2017 raporuna göre, 2013 yılında 681 vaka sayısı, %0.0 ölüm bildirimi; 2014 yılında 610 vaka sayısı, 0.3 ölüm bildirimi; 2015 yılında 618 vaka sayısı, 1.1 ölüm bildirimi; 2016 yılında 645 vaka sayısı, 0.6 ölüm bildirimi ve 2017 yılında 687 vaka sayısı, 0.3 ölüm bildirimi raporlanmıştır. Bu yıllar arasında yeni vaka sayısı ve ölüm oranları bazı hastalıklara göre daha yüksektir [34].

2020 yılında deri kanseri 1,5 milyon yeni vaka ile en çok teşhis edilen kanser türleri arasındadır. Bu vakalar arasında 325 bini yeni melanom vakasıdır ve 57 bin ölüm bulunmaktadır [35]. Her yıl dünyada 2-3 milyon kişi melanom dışı deri kanseri, 132 bin kişi melanom kanseri olmaktadır. Teşhis edilen her üç kanserden birisi deri kanseridir [36].

1.4.Ön İşlemler

Segmentasyon ve sınıflandırma işlemlerinde ilk adım olarak görüntülerin modele uygun giriş boyutlarına indirgenmesi ve görüntüdeki piksellerde bulunan çeşitli gürültülerin kaldırılması yapılacak işlemlerin başarısını arttırmaktadır.



Şekil 1.1. Dermoskopi görüntülerindeki çeşitli artefaktlar

Şekil 1.1.’de International Skin Imaging Collaboration veri setine ait siyah çerçeve, kalem ve cetvel izleri, kıllar, görüntüde oluşan parlaklıklar ve deriye sürülen jel sebebiyle oluşan lekeler gibi çeşitli artefaktların bulunduğu bazı dermoskopi görüntüleri gösterilmiştir.

1.4.1.Yeniden Boyutlandırma

Görüntülerin yeniden boyutlandırılması, belirtilen ölçek faktörleri ile her eksen boyunca ölçeklendirilmesidir. Görüntü küçültülmesi piksellerin kaldırılması, görüntünün büyültülmesi de piksel eklenmesi anlamına gelir. Her iki durumda da bozulmalar meydana gelir. Görüntü yeniden boyutlanırken görüntünün yapısının korunması isteniyorsa en boy oranının korunması gerekmektedir. Boyutlar yeniden oluşturulurken verilerin kaybolmaması adına en yakın komşu, kübik, alan ve lineer gibi çeşitli enterpolasyon yöntemleri[37] kullanılır. En yakın komşu enterpolasyonu, yalnızca bir komşu pikselin kullanıldığı yöntemdir. Kübik enterpolasyon, görüntünün 4x4 komşu pikseli üzerinde hareket eder ve yeni pikseli oluşturmak için 16 pikselin ağırlıklı ortalamasını alınır. Alan enterpolasyonunda örnekleme için piksel alan ilişkisi kullanılarak görüntü boyutu küçültülür. Lineer enterpolasyonda görüntünün 2x2 komşu pikseli üzerinde hareket eder ve yeni pikseli oluşturmak için 4 pikselin ağırlıklı ortalamasını alınır.

1.4.2. DullRazor Algoritması

DullRazor Algoritması [38] ile lezyon görüntüleri üzerindeki kıl artefaktlarının giderilmesi ve böylece segmentasyon ve sınıflandırma doğruluğunun artırılması için amacıyla önerilmiş bir algoritmadır. DullRazor Algoritması ile RGB renk kanallarına koyu kıl piksellerini yumuşatmak için 0° (yatay), 45° (çapraz) ve 90° (dikey) olmak üzere üç yön için ayrı ayrı morfolojik kapatma işlemi uygulanır. Eşitlik (1)'de gösterildiği gibi görüntü ise, üç yönde de morfolojik kapatma sonuçlarının maksimum sonucu alınarak elde edilir.

$$G_r = |O_r - \max \{O_r \cdot S_0, O_r \cdot S_{45}, O_r \cdot S_{90}\}| \quad (1)$$

G_r , orijinal görüntünün kırmızı kanalının gri tonlamalı morfolojik kapatma görüntüsü; O_r , orijinal görüntünün kırmızı kanalı; S_0, S_{45}, S_{90} yatay, çapraz(köşegen) ve dikey yöndeki yapı öğeleridir. $\cdot$ gri tonlamalı kapatma işlemini ifade etmektedir. Kapatma işlemi görüntüde birleşik olmayan parçaları birbirine yakınlaştırır.

Eşitlik(1)'deki gibi orijinal renk bandı ile genelleştirilmiş gri tonlamalı kapatma uygulanmış görüntü arasındaki mutlak fark alınır ve eşitlik(2)'de eşik uygulanarak ikili kıl

maskesi oluşturulur. İkili maske kıl olan ve olmayan bölgeleri ayırır. Kırmızı kanaldaki (x, y) konumundaki ikili kıl maskesi pikseli $M_r(x, y)$ eşitlik (2)'deki gibi hesaplanmaktadır.

$$M_r(x, y) = 1, \text{ eğer } G_r(x, y) > T ; M_r(x, y) = 0, \text{ diğer durumlar} \quad (2)$$

Burada T, önceden belirlenmiş eşik değeridir. Aynı işlemler diğer renk kanalları için de yazılabilir. Yeşil ve mavi kanallar için aynı eşik değeri yazılabilir.

Orijinal sonuç kıl maskesi, M_r (kırmızı renk kanalının ikili maskesi), M_g (yeşil renk kanalının ikili maskesi), M_b (mavi renk kanalının ikili maskesi) olmak üzere üç renk kanalının birleşimi olarak eşitlik (3)'te hesaplanır.

$$M = M_r \cup M_g \cup M_b \quad (3)$$

Sonuç kıl maskesinin içindeki her piksel için, kıl olmayan bölgelere ulaşana kadar ilgili pikselden yayılan yukarı, aşağı, sol, sağ ve dört köşegen olmak üzere sekiz ayrı yönde çizgi çizilir. Bu sekiz çizgi parçası, ilgili pikseli merkez alan dört düz çizgi oluşturur. Çizgilerin uzunlukları hesaplanır. En uzun satır 50 pikselden uzun, diğer satırlar 10 pikselden kısa olmalıdır. Aksi takdirde, piksel kıl pikseli olarak kabul edilmez.

Bir pikselin kıl pikseli olduğu belirlendiğinde, orijinal görüntüde o piksele karşılık gelen piksele interpolasyon uygulanarak renk ataması yapılır. Renk ataması yapılacak pikseller seçilirken işlem yapılacak piksele en yakın pikseller kıl rengine yakın değerler alacağı için 11 piksel uzaklıkta kıl içermeyen pikseller seçilmelidir.

$$I_n(x, y) = I_2(x_2, y_2) * \frac{D(I(x, y), I_1(x_1, y_1))}{D(I_1(x_1, x_1), I_2(x_2, y_2))} + I_1(x_1, y_1) * \frac{D(I(x, y), I_2(x_2, y_2))}{D(I_1(x_1, x_1), I_2(x_2, y_2))} \quad (4)$$

Burada $I(x, y)$ değiştirilen piksel değeri; $I_1(x_1, y_1)$ ve $I_2(x_2, y_2)$ kıl olmayan piksel değerleri; $I_n(x, y)$ yeni renk değeri; $D(A(a, b), B(c, d)) = \sqrt{(c - a)^2 + (d - b)^2}$ olarak ifade edilebilir.

DullRazor Algoritmasında dikkat edilmesi gereken birinci etken, eşik değerinin ayırıcı bir değer olması gerektiğidir. Aksi takdirde kıl piksellerinin konumları tam olarak

belli olmadığı için görüntü gürültülü olur. Diğer bir etken ise görüntünün en boy oranının 1 olmasıdır, aksi takdirde artefaktlar tam olarak giderilemeyecektir.

1.4.3. Veri Arttırma

Veri arttırma işlemi, oluşturulan modelde işlenecek veri sayısını arttırmak için mevcut olan verilere farklı yöntemler uygulayarak veri setindeki veri sayısının artırılmasıdır[39]. Mevcut olan verilerin uzamsal özellikleri değiştirilerek görüntüye uygulanan açı değiştirme, yakınlaştırma-uzaklaştırma, kontrast ve parlaklık arttırma gibi görüntü işleme yöntemleri ile veri arttırımı yapılabilir[40]. Bu sayede modelin başarısı artırılabilir veya veri setinde bulunan sınıfların örnek sayıları dengelenebilir.

1.5. Özellik Çıkarımı


Özellik çıkarımı, her sınıfa ait özgü olan bilgilerin çıkarılması işlemidir. Bu sayede her sınıf ayırt edici bilgileriyle diğer sınıflardan kolay bir şekilde ayrılabilir. Sınıflardan belirleyiciliği iyi olan özelliklerin çıkarılması sınıflandırma ve segmentasyon başarısını arttırmaktadır.

1.5.1. Doku Özellikleri

Gri Seviye Eş Oluşum Matrisi (GLCM) görüntüdeki piksellerin uzamsal ilişkisini kullanarak doku analizi yapılan bir yöntemdir [41]. Görüntüdeki x gri seviye pikselinin görüntüdeki başka bir piksel olan y gri seviye pikseline belirli yön(θ) ve komşuluk değerleriyle(d) ne sıklıkla uzamsal ilişki oluşturduğunun hesaplandığı bir matristir. GLCM oluşturulurken yön bilgisi için 0° , 45° , 90° ve 135° açıları kullanılırken, komşuluk bilgisi için 1 veya 2 değerleri kullanılmaktadır. Görüntüye ait her pikselin gri seviye değeri eşitlik (5)'teki gibi hesaplanır.

$$P(i, j) = \frac{P(i, j, d, \theta)}{\sum_{i=1} \sum_{j=1} P(i, j, d, \theta)} \quad (5)$$

Burada i , referans pikseli, j komşu pikseli, $P(i, j)$ eş oluşum matrisini, d komşuluk bilgisi ve θ yön bilgisidir.



Şekil 1.2. GLCM yön bilgisi

Şekil 1.2’de referans alınan * pikselinin yön bilgisi kullanılarak $0^\circ, 45^\circ, 90^\circ, 135^\circ$ komşu pikselleri gösterilmiştir.

	1	2	3	4	5
1	0	1	1	0	2
2	0	0	2	0	1
3	1	0	0	0	0
4	1	0	0	0	1
5	0	1	0	1	0

Şekil 1.3.(a) 4x4 görüntü kesiti b) görüntüden GLCM oluşumu

Herhangi bir 4x4 boyutlu görüntü parçası ve görüntüden oluşturulmuş GLCM sırasıyla Şekil 1.3.(a) ve 1.4.(b)'de verilmektedir. İlk olarak matris oluşturulmadan önce kesit içerisindeki en büyük değer, oluşturulacak GLCM boyutu olarak belirlenir. Bu örnek için en büyük değer 5 olduğu için GLCM boyutu 5x5 olarak belirlenmiştir. Matrisin boyutları belirlendikten sonra 4x4 boyutlu görüntünün 0° yön bilgisi ve $d=1$ komşuluk bilgisi kullanılarak geçişler yapılmıştır. Görüntü kesitinde 1 değerinden sonra yatay olarak(0°) 5

değerinin 2 kez geldiği gözlemlenmiştir. Bu yüzden birinci satır değeri, ikinci sütun değeri olmak üzere (1,5) konumundaki değer 2 olarak belirlenmiştir. Tekrar sayısının olmadığı durumlarda piksel sayısı 0 olarak belirlenir. GLCM matrisleri köşegen boyunca simetrik olabilir veya olmayabilir. Şekil 1.3.(b)'de simetrik olmayan bir GLCM matrisi gösterilmiştir.

GLCM ile görüntünün zıtlık, enerji, homojenlik ve korelasyon gibi dokusal özellikleri çıkarılır. Eşitlik (6)'da gösterilen zıtlık özelliği, homojenlik özelliğinin tam tersi olup görüntüdeki lokal değişim miktarını belirlemektedir. Eşitlik (7)'de gösterilen enerji özelliği, dokulardaki bozuklukları algılamaktadır ve görüntü dağılımları düzgün ise enerji değeri yüksek, düzgün değilse enerji değeri düşük çıkmaktadır. Eşitlik (8)'de gösterilen homojen özelliği, eş oluşum matris elemanlarının diyagonale yakınlığını ölçmektedir. Eşitlik (9)'da gösterilen korelasyon özelliği ise görüntüdeki gri tonlu komşu piksellerin doğrusallık ilişkisinin bir ölçütüdür.

$$Zıtlık = \sum_{i,j=0}^{l-1} P_{i,j} (i - j)^2 \quad (6)$$

$$Enerji = \sqrt{\sum_{i,j=0}^{l-1} P_{i,j}^2} \quad (7)$$

$$Homojenlik = \sum_{i,j=0}^{l-1} \frac{P_{i,j}}{1+(i-j)^2} \quad (8)$$


$$Korelasyon = \sum_{i,j=0}^{l-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (9)$$

Burada i , referans pikseli, j komşu pikseli, $P_{i,j}$ eş oluşum matrisini, l satır veya sütun sayısını, $\mu_{i,j}$ GLCM ortalamasını, $\sigma_{i,j}$ GLCM standart sapmasını ifade etmektedir.

1.5.2.Şekil Özellikleri

ABCD kuralı [42] olarak bilinen ve lezyonun asimetri(asymetry), sınır(border), renk(color) ve çap(diameter) özellikleri kullanılır.


Asimetri özelliği, ilgili lezyonun iyi huylu olup olmadığını ayırt etmek için kullanılan en önemli yöntemlerden birisidir. Lezyonun en uzun ve en kısa eksen uzunluğu oranıdır. Asimetri özelliği 0-1 arasında değer almaktadır, oran 1 değerine yaklaştıkça lezyonun simetri özelliği artmaktadır.



Şekil 1.4. Dermoskopi görüntüsünün asimetri özelliği

Şekil 1.4'te lezyonun en uzun ve en kısa eksenleri gösterilmektedir.

Sınır özelliği, lezyonun sınır bilgilerini içermektedir. Sınır özelliği düzenli ve düzensiz sınır olarak ikiye ayrılabilir. İyi huylu lezyonlarda sınır daha düzenliyken melanomada sınır düzensiz bir yapıya sahiptir [43].



Şekil 1.5. (a) Simetrik lezyon, (b) asimetrik lezyon

Şekil 1.5.(a) sınır yapısı düzenli lezyon yapısını, Şekil 1.5.(b) düzensiz lezyon yapısını göstermektedir.

Sınır özelliği eşitlik (10) ile hesaplanmaktadır.

$$B = \frac{4\pi A}{P^2} \quad (10)$$

Burada, A lezyonun alanını, P lezyonun çevresini, B ise sınır özellik değerini ifade etmektedir.

Çap özelliği, lezyonun sınır bilgilerinden elde edilen noktalardan Öklid uzaklık mesafesi en büyük olan değeri veren $p_1 = (x_1, y_1)$ ve $p_2 = (x_2, y_2)$ noktaları arasındaki mesafedir. Melanom, genellikle iyi huylu lezyonlardan daha büyük çap değerine sahiptir [42].



Şekil 1.6. Dermoskopi görüntüsünün çap özelliği

Şekil.6'da deri lezyonu için maksimum mesafeyi veren iki nokta ve aralarındaki mesafe gösterilmiştir.

1.5.3.Renk Özellikleri

Renk özelliklerini oluşturan RGB renk bileşenlerinden kırmızı, yeşil ve mavi [0,255] arasında değerler almaktadır. Bu renklerin her birinin farklı değerler alması sonucunda görünür spektrumdaki 16,7 milyon farklı renk ortaya çıkmaktadır. R,G,B değerlerinin 0 olması ile siyah, 255 olması ile beyaz renk elde edilmektedir.

Dermoskopi görüntülerinde melanom genellikle iki renkten fazla olma eğiliminde iken, iyi huylu lezyonlar melanomların aksine tek renk içerirler. Özellikle melanomlar, beyaz, kırmızı, açık ve koyu kahverengi, siyah ve gri-siyah şüpheli renklerini içermektedir [42].

Renk özellikleri olarak genellikle giriş görüntülerinin RGB renk kanallarının ortalama değerleri ve standart sapma değerleri kullanılmaktadır. Ortalama değer her bir görüntüde ilgili alandaki R,G,B değerlerinin toplanıp alandaki piksel sayına bölünmesidir. Her bir renk kanalı için standart sapma değeri görüntülerin renk kanallarının ortalamalarının ilgili piksel değerinden sapmalarının karelerinin karekökü olarak ifade edilir.



Şekil 1.7. Dermoskopi görüntülerindeki renk bileşenleri

Şekil 1.7’de ilgili lezyonu oluşturan renk bileşenleri verilmiştir.

1.6. Görüntü Segmentasyonu

Görüntü segmentasyonu, görüntünün aynı özniteliklere sahip bölgelerinin farklı olan bölgelerinden ayrılması işlemidir. Özellik çıkarma ve sınıflandırma aşamalarından önce olduğu için ve bu aşamaların başarılarını etkileyeceği için görüntülerin doğru bir şekilde segmente edilmesi önemlidir.

Temel olarak semantik ve instance segmentasyon olmak üzere iki segmentasyon yöntemi bulunmaktadır. Semantik segmentasyon, bir görüntüde bulunan tüm nesneleri piksel düzeyinde algılayarak farklı sınıflara ait nesnelere sahip bölgeleri çıkarır. Instance segmentasyon, semantik segmentasyondan farklı olarak her piksele farklı bir sınıf atar, bu sebepten aynı sınıftaki iki farklı nesne birbirinden farklı renklere sahiptir [44].

1.6.1.Otsu Eşikleme Yöntemi

RGB görseller 3 kanaldan oluşan matrislerdir. Bu görseller gri-seviyeye dönüştürülürse renksiz bir hale gelir ve 3 kanal tek kanala indirilmiş olur. Tek kanallı görsellerde arka plandan bağımsız nesneler farklı piksel değerlerine sahip olduğu için bir eşik değeri belirlenerek nesne arka plandan ayrılmış olur.

Otsu eşikleme yönteminde[45], histogramı oluşturulan görüntüler için sınıf içi varyansı en aza indiren bir eşik değeri(t) belirlenir ve eşik değerine göre görüntü iki sınıfa bölünür. Histogram, görüntüdeki her renk değerinden ne kadar mevcut olduğunu gösteren bir sütun grafiğidir.

Eşitlik(11)'de gösterilen histogram yardımıyla, $Sınıf_1$ ve $Sınıf_2$ için ayrı olarak küme olasılık fonksiyonları(q_1 ve q_2), eşitlik (12) eşitlik (13)'deki gibi hesaplanır:

$$P(i) = \frac{n_i}{n} \quad (11)$$

$$q_1(t) = \sum_{i=1}^t P(i) \quad (12)$$

$$q_2(t) = \sum_{i=t+1}^I P(i) \quad (13)$$

Burada i ilgili pikseli, n_i pikselin tekrarlanma sıklığını ve n ise görüntüdeki piksel sayısını ifade etmektedir. Piksel yoğunluk değerleri $Sınıf_1$ için $[1,t]$ ve $Sınıf_2$ için $[t+1,I]$ arasındadır. I maksimum piksel değeridir. $[0-255]$ aralığındaki bir görüntü için bu değer 255'tir. Bu sayede görüntüdeki her pikselin görüntüde bulunma sıklığı hesaplanmış olur.

Ortalama değerleri $Sınıf_1$ için μ_1 ve $Sınıf_2$ için μ_2 olmak üzere sırasıyla eşitlik (14) ve eşitlik (15)'teki gibi hesaplanır.

$$\mu_1(t) = \sum_{i=1}^t \frac{iP(i)}{q_1(t)} \quad (14)$$

$$\mu_2(t) = \sum_{i=t+1}^I \frac{iP(i)}{q_2(t)} \quad (15)$$

Burada μ , sınıf merkez değerini ifade etmektedir.

$t=1$ değerinden başlayarak 255'e kadar her değer için eşitlik (16) ve eşitlik (17)'de varyans hesaplanır.

$$\sigma_1^2(t) = \sum_{i=1}^t [i - \mu_1(t)]^2 \frac{iP(i)}{q_1(t)} \quad (16)$$

$$\sigma_2^2(t) = \sum_{i=t+1}^I [i - \mu_2(t)]^2 \frac{iP(i)}{q_2(t)} \quad (17)$$

Son olarak eşitlik(18)'de maksimum değeri veren t değeri eşik değeri olarak seçilir.

$$\sigma_w^2(t) = q_1(t)\sigma_1^2(t) + q_2(t)\sigma_2^2(t) \quad (18)$$

Eşik değeri yanlış olarak seçilirse, bazı sınıfların varyansı büyük olacaktır. Bu yöntemde amaç sınıfın kendi içinde varyansının minimum, sınıflar arası varyansın maksimum olmasıdır.

1.6.2.Aktif Kontur Modeli

Aktif kontur modeli, görüntülerdeki segmentasyon sonucunu olumsuz etkileyen gürültülerin etkilerini ortadan kaldırarak ilgili bölgenin sınır çizgilerinin elde edilmesini sağlayan algoritmadır[46]. Bu model ile segmente edilecek görüntünün bulunduğu bölgeye kullanıcı yılan adı verilen bir başlangıç noktası ve başlangıç noktasından başlanılarak nesnenin sınırlarının belirlendiği kapalı bir eğri konturu yerleştirir. İç ve dış enerji toplamaları kullanılarak oluşturulan enerji fonksiyonu ile konturun uyumu ölçülür. Oluşturulan enerjiyi minimize etmek için yani oluşturulan konturun nesnenin sınırlarına daha iyi uyum sağlaması için enerji fonksiyonu belirli bir enerji eşiğini aşana kadar veya belirli bir iterasyona ulaşana kadar kontur hattı güncellenir. Güncelleme sona erdiğinde nesnenin sınırlarına denk bir kontur elde edilmiş olur.

Enerji fonksiyonu, iç enerjisi yani kontur düzgünlüğünü(gerginlik ve esneklik bozulmaları) ölçen $E_{iç}$ ve görüntünün çizgi ve kenar özelliklerine göre algoritmayı yönlendiren dış enerjisinin $E_{dış}$ bir fonksiyonudur. Bu enerjiler de $c(s) = (X(s), Y(s))$ yılanını oluşturan $(X(s), Y(s))$ noktalar kümesinin iki fonksiyonudur. $E_{yılan}$ ile ifade edilen enerji fonksiyonu, $E_{iç}$ ve $E_{dış}$ sırasıyla (19-21) eşitlikleri kullanılarak hesaplanmaktadır.

$$E_{yılan} = E_{iç} + E_{dış} \quad (19)$$

$$E_{iç} = \frac{1}{2} \int_0^1 \left\{ \alpha \left[\left(\frac{dX(s)}{ds} \right)^2 + \left(\frac{dY(s)}{ds} \right)^2 \right] + \beta \left[\left(\frac{dX(s)}{ds} \right)^2 + \left(\frac{dY(s)}{ds} \right)^2 \right] \right\} ds \quad (20)$$

$$E_{dış} = - \int_0^1 f(X(s), Y(s)) ds \quad (21)$$

(20) eşitliğindeki α ve β sırasıyla konturun gerilmesine ve bükülmesine(katılık) karşı direncin derecesini ifade eden negatif olmayan iki ağırlıklandırma parametresidir. $s \in [0,1]$ yılanın(çizginin) uzunluğunu ifade etmektedir.

(21) eşitliğindeki $f(x, y) = |\nabla I(x, y)|^2$, I orijinal veya Gauss Kernel filtresi uygulanmış görüntüyü, ∇ gradyanı temsil etmektedir. Gauss filtresi uygulanarak görüntü yumuşatılır ve görüntüdeki gereksiz detaylar da kaldırılarak algoritmada düşük enerjili konumlara hareket önlenir ve daha belirgin kısımlara hareket sağlanır. Yılanın enerji minimizasyonu yinelemeli olarak en aza indirilmelidir. Gradyan(∇) işleminde ise enerjiyi minimize etmek için her yinelemede γ negatif gradyanında bir adım atılır.

1.6.3. Tamamen Evrişimli Sinir Ağları

Tamamen evrişimsel sinir ağları[47], görüntüleri piksel düzeyinde sınıflandıran ve sınıflandırma, nesne tespiti ve anlamsal bölütleme için kullanılan ağlardır. Evrişimsel sinir ağları, girdilerden evrişim katmanları sayesinde özellikler çıkarır ve ağ sonunda tamamen bağlı katmanlar sayesinde sınıflandırma veya regresyon çıktısı üretirler. Tamamen evrişimsel sinir ağları ise tamamen evrişimsel katmanlardan oluşur ve çıktı giriş ile aynı boyutlu olan bir segmentasyon haritasıdır. CNN’de kullanılan parametre sayısı tamamen evrişimsel sinir ağlarında kullanılan parametre sayısından daha fazladır ve daha yavaş çalışmaktadır.

1.6.3.1. Tamamen Evrişimli Sinir Ağları Katmanları


Tamamen evrişimli sinir ağları evrişim, aktivasyon, havuzlama, üst örnekleme, devrik evrişim, atlama bağlantıları ve çıkış katmanlardan oluşan ağlardır.

1.6.3.1.1. Evrişim Katmanı

Evrişim katmanı görüntü üzerinde gezen filtreler yardımıyla görüntü üzerindeki önemli özellikleri çıkartan ve çıktı boyutunu küçülten bir işlemdir. Örneğin, bir görüntü üzerinde gezdirilen X filtresi yatay çizgileri bulurken Y filtresi dikey çizgileri bulabilir. Evrişim katmanı, girdi özellik haritalarını evrişimli filtrelerle işleme sokar ve özellikleri çıkarmak için çıktı özellik haritalarını bir sonraki katmana iletir. Oluşan özellik haritası eşitlik (22) ile ifade edilmektedir.

$$h_i = \sum_i w_i \times x_i + b \quad (22)$$

Burada i nöronu için girdi özellik haritası x_i , çıktı özellik haritası h_i , evrişim çekirdeği w_i ve sapma b olarak temsil edilmektedir.



Şekil 1.8. Evrişim katmanı


Şekil 1.8.'de örnek bir 3x3 boyutlu filtrenin görüntünün belirli bir kısmına uygulanışı gösterilmiştir. Görüntüdeki piksel değeri ile filtredeki değer çarpılır ve oluşan tüm değerler toplanarak özellik haritasının değerini oluşturur. $35 \times 1 + 60 \times 2 + 61 \times 1 + 105 \times 2 + 201 \times 4 + 89 \times 2 + 48 \times 1 + 3 \times 2 + 15 \times 1 = 1497$ değeri özellik haritasında ilgili pikselle yerleştirilir.

Evrişim katmanı için kullanılan bazı parametreler şu şekildedir:

- Çekirdek boyutu: Çekirdek boyutu, görüntüde özelliklerin çıkarıldığı alanı göstermektedir[48]. Parametre sayısının azalması, daha karmaşık özelliklerin yakalanması gibi nedenlerden dolayı genellikle 7x7 boyutuna kadar seçilen pikseller kullanılmaktadır.
- Adım: Adım, evrişim katmanında filtre görüntüyü tararken örnekleme adımlarının büyüklüğünü belirlemektedir[49]. Genellikle 1 değeri olarak seçilmektedir.
- Dolgu: Dolgu, havuz boyutunun girdiyi aşması sebebiyle sınırların hesaplamaya giremediği durumlarda, girdinin etrafına satır ve sütun pikselleri ekleme işlemidir[50].
- Giriş ve Çıkış kanalları: Evrişim katmanı, belirli sayıda aldığı girdinin kanal sayısına göre özellik haritası üretir. Kanal sayısı, giriş ve çıkış kanal sayısını da belirlemektedir[51].

1.6.3.1.2. Aktivasyon Katmanı

Evrişim katmanını, doğrusallığı engellemek için çıktı özellik haritalarına uygulanan bir aktivasyon fonksiyonu takip eder.



Şekil 1.9.(a) Tanh, (b)ReLU, (c) Sigmoid ve (d) Linear aktivasyon fonksiyonları

Yaygın olarak kullanılan aktivasyon fonksiyonlarından[52] ReLU, Sigmoid, Tanh, Softmax fonksiyonları Şekil 1.9.'da sırasıyla gösterilmiştir.

$$f(x) = \max(0, x) \quad (23)$$

Eşitlik (23)'te verilen ReLU aktivasyon fonksiyonunda x değeri pozitif ise x değerini, negatif ise sıfır değerini döndürür.

$$f(x) = \frac{1}{1+e^{-x}} \quad (24)$$

Eşitlik (24)'te verilen Sigmoid aktivasyon fonksiyonunda x değerleri $[0,1]$ arasına sıkıştırılır. Bu fonksiyon ikili sınıflandırma problemlerinde kullanılmaktadır.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (25)$$

Eşitlik (25)'te verilen Tanh aktivasyon fonksiyonunda x değerleri $[-1,1]$ arasına sıkıştırılır. Bu fonksiyon 0 merkezilik özelliğine sahip olduğu için ortalaması sıfırdır.


$$f(x)=x \quad (26)$$

Eşitlik (26)'da verilen Linear aktivasyon fonksiyonu aldığı girişi çıkışa iletir.

(23-26) eşitlikleri için x ve x_i girişi, n sınıf sayısını, $f_i(x)$ ve $f(x)$ çıkışı, e üstel fonksiyonu ifade etmektedir.

1.6.3.1.3.Havuzlama Katmanı

Havuzlama katmanı [53], alt örnekleme yaparak evrişim katmanından çıkan özelliklerin boyutunu küçültmektedir. Bu sayede ağ parametrelerinin sayısı da küçülmektedir. Havuzlama katmanının maksimum ve ortalama havuzlama gibi türleri bulunmaktadır. Maksimum havuzlama, görüntü üzerindeki filtredeki maksimum değeri hesaplarken ortalama havuzlama değerlerin ortalamasını hesaplamaktadır.




Şekil 1.10. Havuzlama katmanı

Şekil 1.10.'da maksimum havuzlama örneği yer almaktadır. Geçerli olan ilk matristen 5, ikinci matristen 6, üçüncü matristen 4, dördüncü matristen 2 değerleri alınarak 4x4 boyutlu matrisin boyutları 2x2 boyutlarına küçültülmüştür.

1.6.3.1.4. Üst Örneklemeye

Üst örneklemeye katmanı, görüntünün boyutunu ve çözünürlüğünü arttıran bir işlemdir. Bu sayede görüntünün eksik bilgileri de doldurulur ve ayrıntılı bir görüntü elde edilmiş olunur.

Üst örneklemeye yapılırken en yakın komşu, çivi yatağı ve maksimum havuzdan çıkarma gibi yöntemler kullanılmaktadır. En yakın komşu yönteminde, piksel değerleri en yakın komşusu kullanılarak yapılır. Çivi yatağı yönteminde, boş pikselleri doldurmak için sıfırlar kullanılır. Maksimum havuzdan çıkarma yönteminde ise piksellerin konumları kullanılarak üst örneklemeye yapılmaktadır.




Şekil 1.11. Maksimum Havuzlama Geri Yükleme

Şekilde 1.11.'de verilen girdiye önce maksimum havuzlama uygulanmış ve daha sonra konumları kullanılarak üst örneklemeye yapılmıştır. Üst örneklemeye katmanı, görüntüyü yeniden boyutlandırarak maksimum havuzlama katmanlarındaki maksimumların konumlarını hatırlayarak ve havuzdan çıkarma katmanlarındaki değeri tam olarak ilgili konuma kopyalayarak maksimum havuzlamayı geri döndüren işlemdir. Geriye kalan pikseller 0 ile doldurulur.

1.6.3.1.5. Devrik Evrişim

Transpoze evrişim olarak da adlandırılan devrik evrişim[54], evrişim katmanının tersi bir çalışma prensibine sahiptir. Azaltılmış çözünürlük özelliğini, orijinal çözünürlüğe döndürmeyi amaçlamaktadır. Veriye yaptığı eklemeler sayesinde kaybolan bilgiler yeniden kazanılır.



Şekil 1.12. Devrik evrişim

Şekil 1.12.'de gösterilen giriş ve filtreye adım:2 olarak devrik evrişim uygulanmıştır. Filtre girişte ilk olarak (0,0) konumuna getirilmiş ve 0 değeriyle çarpılarak (0,0,0,0) değerlerini elde etmiştir. Filtre (0,1) konumuna geldiğinde 1 değeriyle çarpılarak (0,1,2,3) değerleri elde edilmiştir. Filtre (1,0) konumuna geldiğinde 2 değeri ile çarpılarak (0,2,4,6) değerleri elde edilmiştir. Filtre (1,1) konumuna geldiğinde 3 değeri ile çarpılarak (0,3,6,9) değerleri elde edilmiştir. Adım boyutu 2 olduğu için 4x4 boyutlarında yeni bir matris elde edilmiştir. Elde edilen matrise yerleştirilen çapımlar ile devrik evrişim işleminin sonucu elde edilmiştir.

1.6.3.1.6. Atlama Bağlantıları

Atlama bağlantıları[55], tamamen evrişimli sinir ağlarında kodlayıcı ve kod çözücü kısımlarını birbirine bağlayan bağlantılardır. Kodlayıcı kısmından elde edilen düşük seviyeli özellik haritaları ile kod çözücü kısmındaki yüksek seviyeli aynı boyutlu üst örnekleme veya devrik evrişim işlemleriyle elde edilen özellik haritalarını birleştirerek segmentasyon başarısını artırır.

1.6.3.1.7. Çıkış Katmanı

Nihai segmentasyon haritasını üretmek için kullanılan çıkış katmanıdır. Bu katman sayesinde özellik haritaları istenilen sınıf veya kanal sayısına eşitlenir.

1.6.3.2. Tamamen Evrişimli Sinir Ağları Mimarileri

Tamamen evrişimli sinir ağları, görüntüleri piksel düzeyinde sınıflandırarak segmentasyon işlemi yapmaktadırlar. Elde edilen düşük seviyeli ve yüksek seviyeli özellik haritaları ve bu özellik haritalarının birbirine bağlanmasıyla daha iyi segmentasyon sonucu elde edilmektedir. Başarılı ve popüler olan tamamen evrişimli ağlar, U-Net, SegNet ve DeepLabV3+ mimarileri gösterilmiştir.




Şekil 1.13. Tamamen evrişimli sinir ağlarının katman yapısı

Şekil 1.13.'te tamamen evrişimli sinir ağlarının genel yapısı olan kodlayıcı(mavi kısım), kod çözücü(pembe kısım) gösterilmiştir.

1.6.3.2.1. Tamamen Evrişimli Ağlar

Tamamen evrişimli ağlar [56], görüntü piksellerinin sınıflara dönüştürülmesi sırasında kullanılmaktadır. Klasik CNN'de kullanılan tam bağlı katmanlar, sınıflandırmayı piksel düzeyinde gerçekleştirmek için tamamen evrişimli katmanlarla değiştirilmiştir.




Şekil 1.14. Tamamen evrişimli sinir ağlarının genel yapısı

Şekil 1.14.'te gösterildiği gibi havuzlama katmanından gelen tahminleri, farklı havuzlama katmanının üst örneklenmiş bir versiyonuyla birleştirerek, FCN-32'ler, FCN-16'lar ve FCN-8'ler tahminleri oluşturulur. FCN-32, giriş görüntüsünü küçültmek için konvolüsyon ve havuzlama katmanlarından oluşan bir kodlayıcı kullanır. Kodlayıcı kısmından sonra, üst örnekleme işlemi ile özellik haritalarını giriş görüntüsünün boyutuna geri getirir. Son olarak, 1x1 konvolüsyon katmanı ile çıktıyı elde eder. FCN-16, FCN-32'nin bir genişletmesidir. Kodlayıcı kısmı aynıdır, ancak kod çözücü (decoder) kısmında bir atlama bağlantısı vardır. Atlama bağlantısı, kodlayıcının daha düşük seviye özellik haritalarını çözücünün ilgili katmanlarına ekler. Atlama bağlantısı sayesinde daha ayrıntılı segmentasyon sonuçları elde edilir. FCN-8, FCN-16'nın bir genişletmesidir. Kodlayıcı ve çözücü kısımlar aynıdır, ancak iki atlama bağlantısı vardır. Daha fazla atlama bağlantısı, daha yüksek ayrıntı ve keskinlik sağlar. Böylece FCN-8s modeli ile diğer modellere göre bölütleme detayları iyileştirilmiş ve daha ince bölütleme sonuçları elde edilmiştir.

1.6.3.2.2.U-Net

U-Net[57] daha az veriyle daha iyi segmentasyon sonucu veren bir ağıdır. Daralma yolu ve genişleme yolundan ve 23 katmandan oluşan U şeklinde simetrik bir mimaridir. Daralma yolu, sırasıyla 3x3 boyutlu evrişim, ReLU aktivasyon fonksiyonu ve 2x2 maksimum havuzlama katmanından, genişleme yolu ise sırasıyla 3x3 boyutlu evrişim, ReLU aktivasyon fonksiyonu ve 2x2 devrik evrişim katmanından oluşmaktadır.



Şekil 1.15. U-Net mimarisinin katman yapısı

Şekil 1.15.'te U-Net mimarisi gösterilmiştir. Daralma yolunda görüntülerdeki yükseklik ve genişlikteki boyut azaltma işlemi (maksimum, ortalama ya da ortanca


havuzlama katmanı gibi), genişleme yolunda ise boyut artırma yöntemi kullanılmaktadır. Bu sayede segmente edilmiş görüntünün çözünürlüğü artırılmaktadır. Yerelleştirme için U-Net boyunca çözünürlüğü artırılmış öznetelikler ile örneklenen çıktı birleştirilir ve bölütlenmiş çıktı haritası elde edilir.

U-Net mimarisinde, önceki evrişim katmanlarından ters evrişim katmanlarına bilgi aktarmak için atlamalı bağlantılar kullanılır. Aktarılan bilgi, evrişim katmanlarında çıkarılan özelliklerin konumudur. Bu sayede ağ, görüntüde özelliklerin nereden geldiğini öğrenir.

Birleştirme işlemi sayesinde, özellik çıkarma ve özellik yerelleştirme bilgileri birleştirilir. Özellik çıkarma işleminde özellikler önceki katmandan üst örneklendirilmiş katmana geçer. Özellik yerelleştirmesinde ise özelliğin konumu evrişim katmanından getirilir. Bu bilgiler birleştirilerek modelin performansı artırılır ve ağı eğitmek için gerekli olan veri sayısı azalır.

1.6.3.2.3.SegNet

SegNet[58], kodlayıcı ağı, kod çözücü ağı ve piksel bazında sınıflandırmaya olanak sağlayan Softmax sınıflandırıcısından oluşan 26 katmanlı tamamen evrişimli bir sinir ağı mimarisidir. Kodlayıcı kısmındaki katmanlar VGG16 ağının ilk 13 katmanına denk gelmektedir. Bu sayede bazı mimarilere göre parametre sayısı önemli ölçüde azalmaktadır. Kod çözücü kısmında ise her kodlayıcı katmanına denk gelen 1, toplamda 13 katman bulunmaktadır. Nihai kod çözücü çıktısında ise her piksel için sınıf olasılıkları üretmesi için çok sınıflı Softmax sınıflandırıcısı bulunmaktadır.



Şekil 1.16. SegNet mimarisinin katman yapısı

Şekil 1.16'da SegNet mimarisinin yapısı gösterilmiştir. Kodlayıcı kısmında her kodlayıcıda evrişim işlemi ile özellik haritaları oluşturulur ve eleman bazında ReLU aktivasyon fonksiyonu uygulanır. 2x2 boyutlu pencere ve 2 adım ile maksimum havuzlama

gerçekleşir ve elde edilen çıktı 2 faktörü ile alt örneklenir. Peş peşe gelen maksimum havuzlama(alt örnekleme) katmanı, güçlü bir sınıflandırma için artı sağlarken, özellik haritalarının uzamsal çözünürlüğünde kayba neden olmaktadır. Sınır detayının kayıplı olması segmentasyon sonucunun hatalı olmasına sebebiyet vermektedir. Bu nedenle alt örnekleme yapılmadan önce sınır bilgilerinin saklanması gerekmektedir. Ancak belleğin yeterli olmadığı durumlarda yalnızca maksimum havuzlama konumlarının bilgileri saklanır.


Kod çözücü kısmında kod çözücü katmanlarına karşılık gelen kodlayıcı kısmındaki özellik haritalarının saklanan maksimum havuzlama indeksleri kullanılarak üst örnekleme yapılır.

Nihai kod çözücünün çıkışındaki yüksek boyutlu özellik gösterimi, eğitilebilir bir Softmax sınıflandırıcıyı beslemektedir. Bu katman her pikseli bağımsız olarak sınıflandırır ve segmentasyon sonucunda her piksel değeri maksimum olasılığa sahip sınıfa karşılık gelir.

1.6.3.2.4.DeepLabV3+

DeepLabV3+[59], giriş görüntülerindeki her piksele anlamsal etiketler atamanın amaçlandığı semantik görüntü segmentasyonu için kullanılan bir derin öğrenme modelidir. DeepLabv3 ağına segmentasyon başarısını arttırmak ve zaman tüketimi sorununu çözmek için kod çözücü ağı eklenmesiyle DeepLabv3+ ağı oluşturulmuştur[59]. Bu sayede bellek tüketimini azaltmak için kullanılan birden çok alt örneklemenin yol açtığı oluşan özellik haritası çözünürlüğünün küçülmesi ve dolayısıyla bölütlemeye gerekli unsur olan sınır bilgilerinin kaybolması ve düşük doğruluk gibi sorunların üstesinden gelmek amaçlanmaktadır.

Şekil 1.17.'de ağ yapısı gösterilen DeepLabV3+, temel olarak kodlayıcı-kod çözücü katmanlarından oluşmaktadır. Kodlayıcı katmanı, atrous evrişim ve atrous uzamsal piramit havuzundan(ASPP) oluşmaktadır.




Şekil 1.17. DeepLabV3+ mimarisinin katman yapısı

Standart evrişim, girdi özellik haritası üzerinde gezdirilen bir çekirdek ile her konumda, skaler bir değer elde etmek için kullanılırken atrous evrişim, konvolüsyonun görüş alanını iyileştirmek için kullanılır[60]. Atrous konvolüsyonu, bir atrous oranı kullanılarak daha büyük bir çıktı oluşturur[61]. İki boyutlu görüntüler için atrous evrişim eşitlik (27)'deki gibidir.

$$y[i] = \sum_k x[i + r \cdot k]w[k] \quad (27)$$

Burada x, giriş özellik haritasını; y, her i konumu için çıkışı; w, filtreyi; k, çekirdeği; r, atrous oranını ifade etmektedir. $r = 1$ olduğunda, standart evrişim işlemi gerçekleşir. x girişi, uzamsal boyutlarında iki ardışık filtre arasına r-1 sıfırlar eklenerek üretilen üst örneklemeyle fitrelerle evrilir.



Şekil 1.18. Atrous yapısı

Şekil 1.18.'de sırasıyla standart evrişim işlemi ile atrous evrişim işlemleri gösterilmiştir. Standart evrişim 3x3 çekirdek boyutu ile görüntü üzerinde gezinmektedir. Atrous evrişim işleminde de yine 3x3 çekirdek boyutu kullanılmaktadır, ancak atrous oranı 2 olarak verildiği için filtreler arasına 2-1=1 tane sıfır ekleyerek örnekleme yapılmaktadır.

Atrous uzamsal piramit havuzunu sayesinde, girdi özellik haritalarının üstünde farklı atrous oranlarına sahip 4 paralel atrous evrişim işlemi gerçekleştirilmektedir. Bu sayede, farklı ölçekli bilgiler etkili bir şekilde yakalanır. Bu aşamadan sonra gelen 1x1 boyutlu evrişim ile kodlayıcı yapısının sık özellikleri alınır ve özellik haritası kanal sayısı azaltılır.

Kod çözme katmanında, özellik haritaları kademeli olarak azaltılır ve kodlayıcı aşamasından elde edilen sık bilgiler ile üst örneklenmiş bilgiler birleştirilerek boyutların çıktısını çözünürlüğü artırarak yeniden oluşturur. Böylece semantik özellik bilgisi daha net elde edilir.

1.7. Sınıflandırma

Denetimli öğrenme algoritması olan sınıflandırma, etiketlenmiş verilerin kullanıldığı ve verilerin birbirleriyle olan ilişkilerine bakılarak kategorize edilmeleri durumudur. Sınıflandırma algoritmaları [62], test verisini sınıflandırmak için eğitim aşamasında öğrendiği özelliklerden yararlanarak sınıflandırma işlemini gerçekleştirmektedir. Sınıflandırma algoritmalarının yaygın olarak kullanıldığı alanlar arasında veri analitiği, görüntü tanıma, spam filtreleme, görüntü sınıflandırma, dolandırıcılık ve kayıp tespiti gibi alanlar sayılabilir [62].

1.7.1. k-NN


k-NN [63], 1951 yılında geliştirilen, sınıflandırma ve tahmin için yakınlık metriği kullanan denetimli bir öğrenme algoritmasıdır. Örneklerden elde edilen özelliklerin yakınlık dağılımlarına bakılır ve birbirine yakın olan özelliklere sahip örneklerin aynı sınıfta olduğu sonucu çıkarılır. Sınıflandırma problemi için, yeni bir test örneği verildiğinde örnek ile eğitim örneklerinden çıkarılan özellikler arasındaki mesafe hesaplanır ve var olan örneklerden çıkarılan özellikler arasında mesafe hesaplanır ve seçilen k en yakın komşuluk değeri ile yeni örneğin sınıfı çoğunluk oylaması ile belirlenir. Yani k-NN sınıflandırmanın çıktısı örneğin sınıf üyeliğidir. K-NN regresyonda ise çıktı, örneğin komşularının değerinin ortalamasıdır. k-NN’de kullanılan bazı uzaklık metrikleri sırasıyla eşitlik(28), (29) ve (30)’da verilmiştir.

$$\text{Öklid mesafesi} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (28)$$

$$\text{Manhattan mesafesi} = \sum_{i=1}^k |x_i - y_i| \quad (29)$$

$$\text{Minkowski mesafesi} = (\sum_{i=1}^k (|x_i - y_i|)^q)^{\frac{1}{q}} \quad (30)$$

Burada x_i ve y_i eğitim ve test örneklerinden çıkarılan özellikleri ifade etmektedir.



Şekil 1.19. 2 boyutlu özellik uzayında örneğin k-NN algoritmasıyla sınıflandırılması


Şekil 1.19.'da X ve Y özelliğine göre 2 boyutlu uzayda temsil edilen örnek 2 sınıf yıldız ve dikdörtgen sembolleriyle gösterilmektedir. k değeri 3 olarak verilirse, turuncu daire ile temsil edilen test örneği kendisine en yakın komşusunu herhangi bir uzaklık metriği kullanılarak belirler ve çoğunluk oylamasına göre yeni sınıf etiketi belirlenir.

Sınıflandırma ve regresyon problemleri için, örneğin komşularının katkılarına ağırlık koyarak, yani yakın olan komşuların katkılarının uzak olan komşulardan daha fazla olması sağlanarak, farklı k-NN algoritma türevleri geliştirilmektedir.

1.7.2. Destek Vektör Makineleri

DVM[64], 1995 yılında önerilen örüntü tanıma ve sınıflandırma için kullanılan denetimli bir makine öğrenmesi algoritmasıdır.

Veri setindeki her bir x_i örneği ve $y_i \in \{1, -1\}$ ilgili örneklere ait sınıfları temsil etsin. Burada ilgili örnekleri birbirinden en iyi şekilde ayıracak doğrusal hiper düzlemin bulunması hedeflenmektedir. Hiper düzlem, $w \cdot x + b = 0$ eşitliği ile ifade edilebilir. Eşitlikteki w hiper düzleme dik olan normali(ağırlık vektörü); $\|w\|$, w 'nin Öklid formu; $|b|/\|w\|$ hiper düzlemden merkeze olan dik uzaklık olarak ifade edilebilir.




Şekil 1.20. Doğrusal ayrılabilen iki sınıf aracılığıyla hiper düzlemin gösterimi

Destek vektörleri sınır düzlemleri üzerinde bulunan ve hiper düzleme en yakın olan örneklerdir. DVM'nin amacı, hiper düzlemi iki sınıfın en yakın örneklerinden maksimum uzaklığa yerleştirecek şekilde yönlendirerek en geniş marjlı hiper düzlemi aramaktır. Şekil 1.20.'de sert marj durumu gösterilmiştir. Sınır düzlemlerinin tam ortasından geçen ve -1,+1 sınır düzlemlerine eşit uzaklıkta olan düzlem hiper düzlem olarak ifade edilmektedir.

Doğrusal destek vektör makineleri ile veri kümesinin doğrusal olarak ayrılması için veri kümesindeki tüm örneklerin (31)-(32) eşitsizliklerini sağlaması gerekmektedir.

$$f(x_i) = \langle w \cdot x_i \rangle + b \geq +1, \quad y_i = +1 \quad (31)$$

$$f(x_i) = \langle w \cdot x_i \rangle + b \leq -1, \quad y_i = -1 \quad (32)$$



Şekil 1.21. Doğrusal ayrılamayan iki sınıf aracılığıyla hiper düzlemin gösterimi


Şekil 1.21.'de gösterildiği gibi bazı durumlarda örnekler sınır düzlemlerinin dışına çıkabilir. Bu duruma yumuşak marjin kullanılmalıdır. İki sınıf arasındaki denge c hiper parametresi ile kontrol edilebilir. c hiper parametresi ne kadar büyükse marjin o kadar dardır.

1.7.3. Topluluk Öğrenmesi Yaklaşımları

Sınıflandırma veya segmentasyon için oluşturulan modeller bireysel başarılarından ziyade toplu olarak kullanıldıklarında daha iyi sonuçlar verebilmektedir. Bu başlık altında kolay topluluk sınıflandırıcısı, RUSBoost sınıflandırıcısı, dengelenmiş torbalama sınıflandırıcısı, dengelenmiş rastgele orman sınıflandırıcısı, AdaBoost sınıflandırıcısı, gradyan artırma sınıflandırıcısı ve karar ağaçları anlatılmaktadır.

1.7.3.1. AdaBoost Sınıflandırıcı

AdaBoost sınıflandırıcı[65], 1996 yılında önerilen topluluk sınıflandırıcılardan biridir. Şekil 1.21.'de ana mantığı gösterilen AdaBoost sınıflandırıcı, birden fazla zayıf performanslı sınıflandırıcıyı birleştirilerek güçlü bir sınıflandırıcı elde eder, böylece doğruluk arttırılmış olur. Bu sınıflandırıcıda yapılması gereken ana işlemler, sınıflandırıcıların ağırlıklarının ayarlanması ve her yinelemede verileri olağandışı test örneklerine karşı eğitmektir.



Şekil 1.22. Zayıf öğrenicilerin ağırlıklarının değişim gösterimi

Şekil 1.22.'de gösterildiği gibi AdaBoost algoritması, ilk olarak rastgele eğitim alt kümesi seçer. Eğitim aşamasında seçilen alt kümenin verilerinin doğru tahmin edilmesine bakılarak eğitim örnekleri seçimi tekrar yapılır ve AdaBoost modeli yinelemeli olarak eğitilir. Yanlış sınıflandırılmış verilere daha yüksek ağırlık atanır, böylece sonraki eğitimde yanlış sınıflandırılmış veriler sınıflandırma için daha yüksek olasılık elde eder. Sınıflandırma doğruluğuna göre her eğitim iterasyonunda sınıflandırıcıya da ağırlık atanmaktadır. Böylece sınıflandırma doğruluğu yüksek sınıflandırıcı daha yüksek ağırlık alacaktır. Bu eğitim iterasyonları tüm veriler hatasız bir şekilde sınıflandırılana veya maksimum tahmin edici sayısına ulaşılan kadar devam eder. Son olarak sınıflandırma için oluşturulan tüm algoritmalarda bir oylama yapılır.

1.7.3.2.Gradyan Arttırma Sınıflandırıcısı

Gradyan Arttırma Sınıflandırıcısı[66], sınıflandırma için kullanılan topluluk makine öğrenmesi yöntemidir. Gradyan Arttırma Sınıflandırıcısının amacı, AdaBoost sınıflandırıcısının aksine yanlış sonuçlara daha yüksek bir ağırlık atamak değil, zayıf sınıflandırıcıların kayıplarını en aza indirmektir. Zayıf öğreniciler her seferinde ağa sıralı olarak eklendiğinde eğitim örneğinin gerçek sınıf değeriyle arasındaki fark en aza indirilmeye yani nihai model oluşmaya başlar. Gradyan Arttırma Sınıflandırıcısında sınıflandırma başarısı arttıkça kayıp gradyanı en aza indirilir. Algoritma, bir önceki sınıflandırıcıdan gelen katkıyı ölçmek için öğrenme oranı kullanmaktadır. AdaBoost algoritmasından farklı olarak zayıf sınıflandırıcı olarak kullanılan ağaçların derinliği parametresi kullanılmaktadır. Eşitlik (33) yardımıyla eşitlik (34)'te başlangıç tahmini hesaplanır.

$$L(y_i, F(x)) \quad (33)$$

Burada y gerçek değeri, $F(x)$ tahmin edilen fonksiyon çıktısıdır. L gerçek değer ile tahmin edilen değer arasındaki farkı ölçmektedir.

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^N L(y_i, \gamma) \quad (34)$$

Burada $F_0(x)$ başlangıç tahminini, N veri kümesindeki toplam verileri, γ ise başlangıç tahmini optimize ederek veri kümesinin kayıp fonksiyonunu minimize edecek şekilde seçilir.

$$r_{im} = -\left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)}\right]_{F=F_{m-1}(x_i)} \quad (35)$$

Burada r_{im} i'inci örneğin m'inci tahminden olan artık hatayı, $F(x_i)$ tahmin fonksiyonun çıktısını ifade eder.


$$F_m(x) = F_{m-1}(x) + \alpha h_m(x) \quad (36)$$

Burada $F_m(x)$ güncellenmiş tahmin fonksiyonunu, α ise öğrenme oranını ifade eder. (35)-(36) eşitlikleri M (toplam zayıf öğrenici sayısı) kadar devam eder ve nihai sonuç bulunur.

1.7.3.3. Karar Ağacı Algoritması

Sınıflandırma ve regresyon problemlerinde kullanılan gözetimli öğrenme algoritmalarından olan karar ağacı algoritması[67], çok sayıda kayıt içeren veri kümesini, karar kuralları uygulayarak daha küçük kümelere bölmek için kullanılan bir yapıdır.

Karar ağaçları, düğüm, dal, yaprak ve kök gibi temel kısımlardan oluşmaktadır. Düğümler veri setindeki öznitelikleri(örneklerin özelliklerini) ifade etmektedir. Dal, karar ağaçlarındaki düğümleri birbirine bağlamaktadır. Kök karar ağacının ilk kısmı, yaprak ise son kısmını yani etiketi temsil etmektedir. Ağacın temel mantığı olarak eğitim verilerine ait özniteliklere birtakım sorular sorularak ve elde edilen cevaplarla kök-yaprak arasında cevaba en kısa sürede ulaşılması hedeflenmektedir. Oluşturulan ağaca test verisi verildiğinde, yine soru-cevap ilişkisine bakılarak test verisi oluşturulan ağacın kökünden, alt düğümlerinden, yaprağa doğru ilerleyerek devam eder.



Şekil 1.23. Örnek bir karar ağacı yapısı

Şekil 1.23.'te A, B, C sınıfları için x_1, x_2, x_3, x_4 dört boyutlu öznitelik değerlerinden oluşan karar ağacı gösterilmiştir. Bu ağaç için a, b, c, d ve e dallanma değerlerine göre oluşturulmuştur.

Dallanmada hangi özniteliklerin kullanılacağı ve özniteliklerin dallanmaya karar verecek eşik değerlerinin ne olacağı belirlenerek ağaç yapısı oluşturulur. Karar ağacının hangi özelliğe göre dallanma yapacağı entropi değerine göre hesaplanır. Entropi, sistemdeki düzensizliğin ölçüsüdür.

Veri setini oluşturan $C_1, C_2, \dots, C_n$ ilgili sınıflara ait örnek sayısını ve T toplam örnek sayısını sınıf değerlerini gösterdiği varsayılırsa, bir sınıfa ait olasılık eşitlik (37)'de verilmiştir.

$$P_i = \frac{c_i}{|T|} \quad (37)$$

Sınıflara ait entropi değerleri eşitlik (38)'deki gibi hesaplanmaktadır.

$$Entropi(T) = -\sum_{i=1}^n p_i \log_2(p_i) \quad (38)$$

Burada B özneliğine göre T sınıf değerleri $T_1, T_2, \dots, T_n$ şeklinde ayrılır. B öznelik değerleri kullanılarak T sınıf değerlerinin bölünmesi sonucunda elde edilen kazanç eşitlik (39)'da yer almaktadır.

$$Kazanç(B, T) = Entropi(T) - \sum_{i=1}^n \frac{|T_i|}{|T|} Entropi(T_i) \quad (39)$$

T kümesi için B özneliğinin değerinin belirlenmesinde bölümlleme bilgisi eşitlik (40)'ta ifade edilmektedir.

$$Bölünme Bilgisi(B) = -\sum_{i=1}^k \frac{|T_i|}{|T|} \log_2\left(\frac{|T_i|}{|T|}\right) \quad (40)$$

Bu durumda kazanç oranı eşitlik (41)'deki gibi hesaplanmaktadır. Bu eşitlik, sınıflandırma işleminde kullanılacak ayırma ile elde edilen bilgi oranını vermektedir.


$$\text{Kazanç Oranı} = \frac{\text{Kazanç}(B,T)}{\text{Bölünme Bilgisi}(B)} \quad (41)$$

Kazanç oranı ölçütü, sınıflandırma işleminde kullanılacak ayırma ile ilgili elde edilen bilgi oranını vermektedir. Ağacın her bir düğümünde kazanç oranı maksimum olacak şekilde T kümesi tekrarlı bir şekilde ayrılır. İşleme her bir yaprak düğümü sadece bir sınıfa ait olana kadar devam edilir.

Karar ağaçları oluşturulduktan sonra çok geniş ve karmaşık ağaç yapısını ortadan kaldırmak için, bir alt ağacı atarak onun yerine yaprak yerleştirilebilir, böylece ağaç budanmış olur. Budama işleminde ağacın sınıflandırma doğruluğunu ve katkısı olmayan kısımlar çıkarılır[68].

1.7.3.4. Kolay Topluluk Sınıflandırıcısı

Kolay Topluluk Sınıflandırıcısı [69], Şekil 1.24.'te gösterildiği gibi veri setinde bulunan çoğunluk sınıfı birkaç alt kümeye örnekler ve azınlık sınıf ile çoğunluk sınıfın her bir alt kümesini kullanarak öğrenciyi eğitir. Nihayetinde bu öğrencilerin çıktılarını birleştirir. Böylece dengeli alt sınıflar oluşturularak sınıflandırma başarıları artırılmıştır.



Şekil 1.24. Kolay topluluk sınıflandırıcının çalışma mantığı

P, N ve N' sırasıyla azınlık, çoğunluk veri kümesini, N veri setinden oluşan rastgele alt kümesini temsil etmektedir. N eğitim veri seti olarak verildiğinde alt örnekleme yaklaşımıyla N' kümesinden T adet alt küme oluşmaktadır. H_i sınıflandırıcısı her bir N_i ($1 \leq i \leq T$) alt kümesi için N_i ve P kümesi kullanılarak eğitilmektedir. Bu sınıflandırıcıda H_i sınıflandırıcısı AdaBoost kullanılarak eşitlik (42) ile eğitilmiştir.

$$H_i(x) = \text{sgn}(\sum_{j=1}^{S_i} \alpha_{i,j} h_{i,j}(x) - \theta_i) \quad (42)$$

Burada H_i , s_i adet $h_{i,j}$ zayıf sınıflandırıcısını, $\alpha_{i,j}$ ağırlıklı AdaBoost topluluğunu; θ_i topluluğun eşik değerini göstermektedir.


$$H(x) = \text{sgn}(\sum_{i=1}^T \sum_{j=1}^{S_i} \alpha_{i,j} h_{i,j}(x) - \sum_{i=1}^T \theta_i) \quad (43)$$

Tüm sınıflandırıcılar için oluşturulan karar sonucu eşitlik (43)'teki gibi birleştirilmiştir.

Bu çalışmada temel sınıflandırıcı olarak AdaBoost kullanılmıştır.

1.7.3.5.RUSBoost Sınıflandırıcısı

İkili ve çok sınıflı sınıflandırma problemleri için kullanılan rastgele alt örnekleme arttırma(RUSBoost) [70]sınıflandırıcısı, dengesiz veri setlerini sınıflandırmada etkili olarak kullanılan bir algoritmadır. Yöntem, AdaBoost algoritması ile veri setindeki sınıflarda en az üyeye sahip sınıfın üye sayısını alır. Veri setinde en fazla üyeye sahip sınıflar, en az üyeye sahip sınıfın üye sayısı kadar alt örneklenir.



Şekil 1.25. RUSBoost sınıflandırıcısının çalışma mantığı

Şekil 1.25.'te gösterildiği gibi veri集中的 (x_i, y_i) ikilisi olarak temsil edilen m adet örnek, $1 \leq t \leq T$ (topluluktaki iterasyon sayısı) olmak üzere h_t , t . adımdaki eğitilmiş zayıf hipotezi ve $D_t(i)$, t . iterasyondaki i örneğinin ağırlığını göstermektedir. Öncelikle her örneğin başlangıç ağırlığı $1/m$ olarak ayarlanır. Geçici yeni eğitim veri setinin %N'i azınlık sınıfa ait olana kadar çoğunluk sınıfın örnekleri rastgele bir şekilde kaldırılarak yeni eğitim veri seti oluşturulur. Örneğin oluşturulacak veri setinde sınıflar arasında olması istenen oran 50:50 ise çoğunluk sınıftaki veriler, çoğunluk ve azınlık verileri birbirine eşit olana kadar kaldırılır. Oluşturulan veri kümesi ve ağırlık dağılımları, h_t oluşturması için temel sınıflandırıcıya gönderilir. Temel sınıflandırıcı orijinal eğitim veri setini ve ağırlık dağılımlarını kullanarak hata değerini (ϵ_t) eşitlik (44)'te ve ağırlık güncelleme parametresini eşitlik (45)'teki gibi hesaplar.

$$\epsilon_t = \sum_{(i,y): y_t \neq y} D_t(i) (1 - h_t(x_i, y_i) + h_t(x_i, y)) \quad (44)$$

$$\alpha_t = \frac{\epsilon_t}{\epsilon_t - 1} \quad (45)$$

Sonraki iterasyon için ağırlık dağılımı eşitlik (46)'daki gibi güncellenir ve eşitlik (47)'deki gibi normalize edilir.

$$D_{t+1} = D_t(i) \alpha_t^{\frac{1}{2}(1+h_t(x_i, y_i) - h_t(x_i, y \neq y_i))} \quad (46)$$

$$D_{t+1}(i) = \frac{D_{t+1}(i)}{Z_t} \quad (47)$$

Burada $Z_t = \sum_i D_{t+1}(i)$ olarak gösterilmiştir.

Sonuç hipotezi, T iterasyon devam eden adımlar zayıf hipotezlerin ağırlıklı oyu ile eşitlik (48)'deki gibi elde edilir.

$$H(x) = \operatorname{argmax}_{y \in Y} \sum_{t=1}^T h_t(x, y) \log \frac{1}{\alpha_t} \quad (48)$$

Bu çalışmada temel sınıflandırıcı olarak Gradyan Arttırma Sınıflandırıcı kullanılmıştır.

1.7.3.6. Dengelenmiş Torbalama Sınıflandırıcısı

Breiman tarafından önerilen torbalama sınıflandırıcısı[71], tüm veri setini değiştirerek alt veri setlerine böler. Bölünen veri setleri çoklu temel öğreniciler tarafından sınıflandırılır ve çıktıları toplanır.

K temel sınıflandırıcı sayısını; D veri setini; veri seti temel sınıflandırıcılara eşit olarak bölündüğünde oluşacak yeni alt veri setleri $D^1, D^2, \dots, D^K$; $f^k(x)$, D^k ile eğitilen k'nıncı temel sınıflandırıcıyı; $f^A(x)$ ise $\{f^1(x), f^2(x), \dots, f^K(x)\}$ yani nihai topluluk modelini temsil etmektedir. $f^A(x)$, her temel sınıflandırıcı için tahmin edilen olasılığın $[p^k(y_i|x_i)]$ ortalaması ile eşitlik (49) ile bulunmaktadır.


$$f^A(x_i) = \frac{1}{K} \sum_{k=1}^K p^k(y_i|x_i) \quad (49)$$

Dengelenmiş torbalama sınıflandırıcısında, torbalama sınıflandırıcısına ek olarak oluşan küçük veri setlerinde azınlık ve çoğunluk sınıfın eşit olarak seçilmesi amaçlanır. Sınıflar arası denge korunarak azınlık sınıfın temel sınıflandırıcılar tarafından daha iyi öğrenilmesi sağlanır.

Bu çalışmada temel sınıflandırıcı olarak Gradyan Arttırma Sınıflandırıcı kullanılmıştır.

1.7.3.7. Dengelenmiş Rastgele Orman Sınıflandırıcısı

2001 yılında önerilen rastgele orman sınıflandırıcısı[72], eğitimde birden fazla karar ağacı oluşturarak sınıflandırma gerçekleştirmektedir. Eğitim veri setinden rastgele olarak seçilen veri alt kümeleri her bir karar ağacına girdi olarak verilir. Karar ağaçlarının oluşturdukları tahminler bir araya getirilir ve sonuç üretilir. Şekil 1.26.'da gösterildiği gibi x giriş vektörü, k oluşturulan ağaç sayısını, θ_k k 'nıncı ağaç için üretilen rastgele vektör olarak kabul edildiğinde bir karar ağacının sonucu $h(x, \theta_k)$ olarak bulunur. Oylama yapılırken her bir ağaç x girişi için bir sınıf ataması yapar ve oylama sonucunda en çok oyu alan sınıf x giriş vektörünün sınıfı olarak atanır.



Şekil 1.26. Rastgele orman sınıflandırıcısı çalışma mantığı

Dengesiz verilerin öğrenilmesinde, oluşturulan alt veri setinin azınlık sınıfın çok azını içermesi veya hatta hiç içermemesi, azınlık sınıfın tahmin edilmesinde düşük bir sonuçla karşılaşılmasına neden olmaktadır. Bu sorunun üstesinden gelmek için her sınıftan değişken örnekler kullanılarak katmanlı bir alt veri seti kullanılır. Ancak bu da denge sorununu tam olarak çözmeyeceği için, yapay olarak sınıf veri sayısının çok olduğu sınıftan aşağı örnekleme yaparak ya da verilerin az olduğu sınıftan daha fazla örnekleme yaparak veri setinde bulunan sınıfları eşitlemek, daha iyi bir performans sonucu vermektedir. Ancak çoğunluk olan sınıf alt örneklenirken veri kaybına dolayısıyla bilgi kaybına neden olabilir.

Bu durumun üstesinden gelmek için dengeli aşağı örneklenmiş verilerden elde edilen ağaçlar bir araya getirilerek dengeli rastgele orman algoritması elde edilmiştir[73,74].


Dengelenmiş rastgele orman algoritması, veri setinden rastgele seçilen alt veri setleriyle eğitilen birden çok karar ağacı kullanmaktadır. Karar ağaçlarının eğitilmesi aşamasında, sınıflar arası dengesizliği ortadan kaldırmak için azınlık sınıfa ait olan örneklerin seçilmesi olasılığı artırılarak ve çoğunluk sınıfa ait olan örneklerin seçilme olasılığı azaltılarak örneklerin ağırlıkları ayarlanır. Karar ağaçları, veri setindeki özelliklerin değerlerine göre düğümlerde kararlar alarak her bir örneğe sınıf ataması yaparlar. Tüm karar ağaçları için bu aşama geçildikten sonra tüm örneklerin nihai ataması karar ağaçlarından çıkan sonuçların çoğunluk oylaması ile belirlenir.

1.7.4. Evrişimli Sinir Ağları

Evrişimsel sinir ağları, bilgisayarlı görü alanında kullanılan ve sınıflandırma yapan derin öğrenme modelleridir.

1.7.4.1. Evrişimsel Sinir Ağları Katmanları

Genel olarak bir evrişimli sinir ağı, evrişim, havuzlama, düzleştirme, tamamen bağlı ve Softmax katmanlarından oluşmaktadır.




Şekil 1.27. Evrişimsel sinir ağlarının katman yapısı

Şekil 1.27.'de genel bir CNN yapısı gösterilmiştir. Evrişim ve havuzlama katmanlarında giriş görüntüsünden özellik haritaları elde edilmektedir. Daha sonra düzleştirme, tamamen bağlı ve Softmax katmanlarında sınıflandırma işlemi

gerçekleşmektedir. Evrişim katmanı, aktivasyon katmanı ve havuzlama katmanı 1.6.3.1.1., 1.6.3.1.2. ve 1.6.3.1.3.'te açıklanmıştır.

1.7.4.1.1. Düzleştirme Katmanı

Şekil 1.28.'de gösterildiği gibi evrişim ve havuzlama katmanlarından sonra oluşan özellik haritalarını düzleştirerek tamamen bağlı katmana girdi olarak verilmeye hazırlayan tek boyutlu vektör haline getiren katmandır.



Şekil 1.28. Düzleştirme katmanı ve tamamen bağlı katman yapısı

1.7.4.1.2. Tamamen Bağlı Katman

Tamamen bağlı katman, her bir nöronun önceki katmanlarla bağlı olduğu Şekil 1.26'da verilen bir yapay sinir ağı mimarisidir. Genellikle sınıflandırma ve regresyon problemlerinde kullanılmaktadır. Giriş nöronu, bir ağırlıkla çarpılarak ve aktivasyon fonksiyonundan geçirilerek çıktıyı üretir. Çıktı burada sınıf etiketleridir.

1.7.4.1.3. Softmax Katmanı

Softmax fonksiyonu sayesinde girdi, olasılık vektörüne dönüştürülür. Her sınıf olasılık değeri 0 ile 1 arasındadır ve bütün olasılıkların toplamı 1'e eşittir. Sınıflandırma için de olasılık değeri en yüksek olan sınıf seçilir. Eşitlik (50)'de Softmax fonksiyonu yer almaktadır.


$$f_i(x) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (50)$$

Burada x değerleri [0,1] arasına sıkıştırılır. Bu fonksiyon ikili sınıflandırma problemlerinde kullanılmaktadır. Fonksiyon her bir giriş için üstel fonksiyonu hesaplar ve hesapladığı değerleri paydaya böler. Böylece, her bir giriş değerinin olasılığı hesaplanmış olur.

1.7.4.2.Evrişimli Sinir Ağı Modelleri

1.7.4.2.1.ResNet-200

Evrişimli sinir ağlarında katman sayısı artırıldıkça hata oranı azalmaktadır ancak katman sayısı çok arttığında eğitim ve test hata oranı da artmaktadır. Bu sorunun üstesinden gelmek için artık ağlar önerilmiştir. Bu ağ ile aradaki bazı katmanlar atlanarak bir katmanın aktivasyonları diğer katmanlara bağlanır. Bu sayede herhangi bir katmanın ağ performansını olumsuz etkilemesi durumunda o katman atlanır. ResNet(Residual Network) ağı ise bu mantıkla oluşturulmuş VGG-19 ağından türetilmiş ancak daha az kompleks bir mimaridir.



Şekil 1.29. ResNet-200 ağının katman yapısı

ResNet-200 ağı[75], Şekil 1.29.'da gösterildiği gibi 200 katmandan oluşmaktadır. Girişte uygulanan bir konvolüsyon ve havuzlama katmanının ardından sırasıyla 64, 64 ve 256 konvolüsyon katmanından oluşan blok 3 kere tekrar eder. İkinci blokta 128, 128 ve 512

konvolüsyon katmanı 24 kere tekrar eder. Üçüncü blokta 256, 256, 1024 konvolüsyon katmanı 36 kere tekrar eder. Dördüncü blokta ise 512, 512 ve 2048 konvolüsyon katmanı 3 kere tekrar eder.

1.7.4.2.2.EfficientNet

EfficientNet[76], ağların tek yönlü olarak değil, derinlik, genişlik ve çözünürlüklerinin birlikte ölçeklendirilmesini ve daha iyi sınıflandırma sonuçları elde edilmesini sağlamaktadır. Genişlik, evrişimli katmanda kullanılan kanal sayısıdır. Kanal sayısını arttırmak, modeli daha karmaşık bir hale getirir ancak girdiyi daha ayrıntılı öğrenmesini sağlar. Derinlik ölçeklendirme, katman sayısı ile ilgilidir. Derin bir model, daha karmaşıktır ve daha yüksek temsili özellikler öğrenilmesini amaçlar. Giriş görüntülerindeki daha iyi çözünürlük değeri, daha fazla ayrıntı yakalanmasını sağlamaktadır. Ağlar oluşturulurken yüksek derinlik, genişlik ve çözünürlüğe sahip ağlardan yüksek doğruluk elde edilmektedir, ancak doğruluk bu ölçekler için bir süre sonra stabil kalmaktadır ve bu durum da tek boyutlu ölçeklendirmeye gidilmektedir. EfficientNet ile sunulan bileşik ölçeklendirme tekniği ile EfficientNet-B0'dan EfficientNet-B7'ye kadar farklı ağlar oluşmaktadır. Şekil 1.30.'da EfficientNet-B0 mimarisi gösterilmiştir.



Şekil 1.30. EfficientNet-B0 ağının katman yapısı

$$d = \alpha^\phi \quad (51)$$


$$w = \beta^\phi \quad (52)$$

$$r = \gamma^\phi \quad (53)$$

Eşitlik(51), (52) ve (53) sırasıyla derinlik, genişlik ve çözünürlük bileşenlerini temsil etmektedir. α, β ve γ değerlerini bulmak için ızgara arama yapılır. ϕ kullanıcı tarafından belirlenen birleşik katsayıyı temsil etmektedir.

EfficientNet-B0 ağı için birleşik ölçeklendirme uygulandığında kullanıcı tarafından $\phi = 1$ olarak seçilir. $\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2$ kısıtı ile α, β ve γ değerlerini bulmak için ızgara arama

yapılır. [76] çalışmasında en iyi değerler $\alpha = 1.2$, $\beta = 1.1$ ve $\gamma = 1.15$ olarak önerilmiştir. EfficientNet-B1 - EfficientNet-B7 arasındaki ağlar için α , β ve γ değerleri sabitlenir, ϕ değeri ise farklılık gösterir. α , β ve γ değerlerinin sabitlenme nedeni arama maliyetinin ağ büyüdükçe artmasıdır.




Şekil 1.31. MBConv bloğunun katman yapısı

MBConv bloklarının[77] mimarisi Şekil 1.31.'de gösterilmiştir. 2 evrişim katmanından(k1x1), bir derinlemesine evrişim katmanından, bir Squeeze and Excitation bloğundan ve bir dropout katmanından oluşmaktadır. İlk evrişimli katman, kanalları genişletmek için kullanılırken, ikinci evrişim katmanı kanalları sıkıştırmak için kullanılır. 1x1 evrişim filtresi ile verinin boyutu artırılır ve giriş özellik haritalarının derinliği artırılır bu sayede daha fazla özellik çıkarılır. Derinlemesine evrişim ile her bir giriş kanalına küçük filtreler uygulanarak parametre sayısını azaltılır. Ayrıca özelliklerin öğrenilmesini sağlar. SE bloğu[78], kanallar arasındaki ilişkiye odaklanır ve kanalların hepsini eşit olarak hesaplamak yerine her kanala farklı ağırlık verir. 1x1 son evrişim katmanı ise özellik haritasının boyutunu küçültür.

Eşitlik(54)'te MBConv bloğunda kullanılan Swish toplu normalleştirme yer almaktadır.

$$f_{swish} = \frac{1}{1+e^{-\beta x}} \quad (54)$$

Burada β , CNN'nin eğitimi sırasında öğrenilebilen bir parametredir.



Şekil 1.32. Squeeze and Excitation Bloğu


Şekil 1.32.'de gösterilen SE Bloğunda ilk olarak özellik haritası ve kanal sayısı girdi olarak alınır. Sıkıştırma modülünde öznitelik haritasının her bir kanalı ortalama havuzlama kullanılarak tek bir sayısal değere sıkıştırılır. Böylece her bir kanal için özet oluşturulur. Uyarılma modülünde sıkıştırılmış öznitelikler, 2 tamamen bağlı katmandan geçirilir. İlk tamamen bağlı katmanda, özniteliklerin boyutu azaltılır ve ReLU aktivasyon fonksiyonu uygulanır. Bu sayede gerekli olan doğrusal olmama durumunu eklenir. İkinci tamamen bağlı katmanda özniteliklerin boyutları eski haline getirilir ve sigmoid fonksiyonundan geçirilir. Çıktı olarak, her bir kanalın önemini temsil eden vektör elde edilir. Elde edilen önem vektörü, öznitelik haritasındaki her bir kanalın çıktı değeri ile çarpılır. Ardından kanal bazlı bir ölçekleme yapılarak daha önemli kanalların vurgusu artırılır. Ekleme katmanında ise özellik haritası ile ölçeklenmiş çıktının toplanması işlemidir.

1.7.4.3. Evrişim ve Dikkat Ağlarının Birleşimi

Evrişim katmanları görüntüden filtre boyutu kadar yerel bilgi almaktadır, bu sayede görüntünün yerel özellikleri çıkarılmaktadır. İlk olarak doğal dil işleme alanında kullanılmaya başlanan öz-dikkat, görüntüdeki piksellerin birbirleriyle olan ilişkisini(pikseller arasındaki benzerlik ve uzaklık) hesaplamak için kullanılmaktadır. Bu sayede görüntünün tamamından bilgi aldığı için görüntünün bağlamsal özelliklerini ortaya çıkarmaktadır. Öz- dikkat mekanizması nesne tanıma, görüntü sınıflandırma ve segmentasyon alanlarında kullanılmaktadır.

1.7.4.3.1. CoAtNet

Evrişim ve öz-dikkat katmanlarının birleştirilmesiyle oluşan CoAtNet[79] ile görüntülerdeki yerel ve global özellikler çıkarılıp genelleme yeteneği artırıldığı için sınıflandırma performansı da artmaktadır.



Şekil 1.33. CoAtNet mimarisinin katman yapısı

S0,S1,S2,S3 ve S4 aşamalarından oluşan CoAtNet Şekil 1.33.'te gösterilmektedir. Bu mimaride, evrişim katmanları koşul olarak görü dönüştürücü katmanlarından önce gelir. Çünkü uzamsal boyut dikkat mekanizması için büyüktür. S0 aşaması 2 evrişim katmanından oluşmaktadır. S0 aşaması sayesinde görüntülerden özellik haritaları oluşturulur. S1 ve S2 aşamaları, MBConv modülü kullanarak hem sonraki aşamalar için büyük olan uzamsal boyutu küçültmektedir hem de daha etkili özellikler çıkarılmaktadır. S3 ve S4 aşamalarında görü dönüştürücü blokları bulunmaktadır. Bu bloklardaki göreceli dikkat, giriş dizilerinin konum bilgisini tutar. Öz dikkat mekanizması, özellik vektörlerini birbirleri ile karşılaştırır ve bu karşılaştırmalar sonucunda ağırlıkları belirler. Oluşan bu ağırlıklar ilgili vektörlere ne kadar dikkat edilmesi gerektiğiyle ilgilidir. Göreceli dikkat ise öz dikkat mekanizmasının özelleştirilmiş halidir. Burada özellik vektörlerinin birbirleri ile ilişkilerini belirlemek için konumsal bilgiyi de tutmaktadır. Daha sonra bu konumlar kullanılarak dikkat ağırlıkları belirlenmektedir. FFN(İleri Beslemeli ağ), çıkışın bir sonraki görü dönüştürücü bloğunda kullanılabilmesi için dikkat vektörlerine uygulanan bir katmandır. Bu ağ sayesinde veri girişten sadece ileriye doğru işlenir ve çıktı üretilir. Ağın genel yapısında giriş verisi katmanlardan geçerken her katmanda bulunan yapay sinir hücreleri giriş verileri ile çarpılır ve bir aktivasyon fonksiyonundan geçirilir. Aktivasyon katmanından geçirilen çıktı bir sonraki katmana iletilir. Global havuzlama katmanı[53], özellik haritalarının boyutlarını global ortalama havuz veya global maksimum havuz kullanarak her bir kanal için 1x1 boyutlarına getirerek tek bir vektör haline getirir. Böylece bütün özellikler tek bir vektör altına toplanmış olur. Tamamen bağlı katmanda ise önceki katmandaki her bir özelliği alır ve ağırlıklarla çarparak aktivasyondan geçirerek nihai sonucu üretir. Bu katmanda sınıflandırma için sınıf sayısı kadar nöron bulunmaktadır. Bu nöronlar çıkış değerlerini tutmaktadırlar. En yüksek değere sahip olan nöronun olduğu sınıf sınıflandırma sonucu olarak atanır.

CoAtNet modeli için 224x224 boyutunda verilen bir giriş görüntüsü, S0 modülünün sonunda 112x112, S1 modülünün sonunda 56x56, S2 modülünün sonunda 28x28, S3 modülünün sonunda 14x14, S4 modülünün sonunda 7x7 boyutlarına sahiptir.

Derinlemesine evrişim işlemi, Eşitlik (55)'teki gibi yerel bir alıcı alandan bilgi elde etmek için sabit bir çekirdeğe dayanır.

$$y_i = \sum_{j \in \mathcal{L}(i)} w_{i-j} \odot x_j \quad (55)$$

Burada x girdi, y çıktı, w ağırlık, $\mathcal{L}$ ise i 'nin yerel komşuluğudur.

Öz-dikkat ise alıcı alanın tüm uzamsal konumlar olmasına izin verir ve ağırlıkları (x_j , x_j) çifti arasındaki yeniden normalleştirilmiş ikili benzerliğe dayalı olarak eşitlik (56)'daki gibi hesaplar.

$$y_i = \sum_{j \in G} \underbrace{\frac{\exp(x_i^T x_j)}{\sum_{k \in G} \exp(x_i^T x_k)}}_{A_{i,j}} x_j \quad (56)$$

Burada G global uzamsal alanı, $A_{i,j}$ dikkat ağırlığı, $x_i^T x_k$ dikkat matrisini ifade etmektedir.

Evrişim ve öz-dikkat ağırlarının birleştirilmesi ile model daha iyi performans gösterecektir. Softmax katmanından önceki birleşim temsiliyeti eşitlik (57)'deki gibi gösterilmektedir.

$$y_i^{pre} = \sum_{j \in G} \left(\frac{\exp(x_i^T x_j + w_{i-j})}{\sum_{k \in G} \exp(x_i^T x_k + w_{i-k})} + x_j \right) \quad (57)$$

Burada w_{i-k} evrişim filtresini temsil etmektedir.

1.8. Derin öğrenme Hiper Parametreleri

Derin öğrenme hiper parametreleri, eğitim aşamasında hem zamanı iyi yönetmek hem de model başarısını arttırmak için deneme yanılma yoluyla bulunması gereken değerlerdir.

1.8.1.Devir Sayısı, Yığın Boyutu, Öğrenme Oranı ve Ağırlık Azalması

Devir sayısı, eğitim aşamasında model eğitiminin kaç iterasyon süreceğini gösteren değerdir. Devir sayısının az olması eğitimin tam olarak tamamlanmamasına ve düşük test

sonucuna neden olmaktadır. Devir sayısının fazla olması ise ağırlık verileri fazla öğrenmesine dolayısıyla verileri özelleştirip test sonucunun düşmesine neden olmaktadır.

Yığın boyutu, tek seferde veri setinde ne kadar verinin girdi olarak kullanacağını ölçütüdür. Birlikte kullanılan örnekler sayesinde hata fonksiyonunu minimize etmek için yapılan ağırlık güncellemesinde veriler birlikte değerlendirilip ortalamaları hesaplanarak ağırlık parametrelerini güncellenir. Yığın boyutunun küçük seçilmesi, işlemci kısıtı yüzünden eğitimi yavaşlatabilir. İşlemci kısıtı olmadığında daha fazla güncelleme yapılmasını sağlar ve eğitimi hızlandırır. Yığın boyutunun büyük olması durumunda daha az güncelleme yapılır ve eğitim daha yavaş sürer.

Öğrenme oranı, eğitim aşamasında ağırlık parametreleri güncellenirken adım büyüklüğünü kontrol etmek için kullanılır. Öğrenme oranı çok büyük seçilirse güncelleme adımları çok büyük olur. Bu sayede hızlı bir şekilde minimuma indirgenebilir ancak adımlar büyük olacağı için ağırlıklar minimum noktayı atlayabilirler. Öğrenme oranı çok küçük seçilirse güncelleme adımları çok küçük olacağı için öğrenme süreci çok yavaş ilerler. Minimum değere yakınsama durumu yavaşlayabilir, bu yüzden daha fazla devir sayısı gerekmektedir. Optimal öğrenme oranı, her modelin yapısına uygun olarak değişebilir.

Modelin aşırı öğrenmesini engellenmek için kullanılan düzenleme parametrelerinden biri olan ağırlık azalması, modelin ağırlıklarını azaltmaya yardımcı olarak ağırlık basitleştirir ve aşırı öğrenmeyi engeller. Bu değer genellikle ağırlık azaltma katsayısı olarak (λ) temsil edilir. Yüksek bir lambda değeri, ağırlıkların daha fazla azaltılmasına ve daha basit bir model oluşmasına yol açar. Çok daha yüksek bir lambda değeri ağırlıkların çok fazla azaltılmasına dolayısıyla çok daha basit bir model oluşmasına neden olur. Düşük bir lambda değerinde ise aşırı uyum durumu oluşabilir.

1.8.2. Optimizasyon Algoritması

1.8.2.1. Adaptive Moment Estimation(ADAM) Algoritması

Adaptive Moment Estimation(ADAM) Algoritması[80], eğitim aşamasında kullanılan gradyan bazlı bir optimizasyon algoritmasıdır. İlk olarak modelin parametreleri rastgele olarak başlatılır. İlk moment eşitlik (58)'teki gibi hesaplanır.

$$v_t = \beta_1 * v_{t-1} - (1 - \beta_1) * g_t \quad (58)$$

Burada v_t , t anındaki tahmini moment; β_1 momentin geçmiş gradyanlara etkisi; g_t t anındaki gradyan vektörünü temsil etmektedir.

İkinci moment eşitlik (59)'taki gibi hesaplanır.

$$s_t = \beta_2 * v_{t-1} - (1 - \beta_2) * g_t^2 \quad (59)$$

Burada s_t , t anında gradyan karelerin toplamı; β_2 momentin geçmiş gradyanlara etkisi olarak temsil edilmektedir.

Eşitlik (60)'taki gibi ağırlıkların güncellemesinin ne kadar olacağı hesaplanır.

$$\Delta\omega_t = -\eta \frac{v_t}{\sqrt{s_t + \epsilon}} * g_t \quad (60)$$

Burada $\Delta\omega_t$, t anında ağırlıkların güncellenmesini; η , öğrenme hızını; ϵ , sıfıra bölme hatasının olması durumu göz önüne alınarak eklenen küçük sayıyı ifade etmektedir.

Eşitlik (60)'taki gibi ağırlıklar güncellenir.

$$\omega_{t+1} = \omega_t + \Delta\omega_t \quad (61)$$

ω_t , t anındaki ağırlıkları; ω_{t+1} , t+1 anındaki ağırlıkları temsil etmektedir.

Bu işlemler iterasyon sayısı kadar devam etmektedir.

1.8.2.2. Çapraz-Entropi Kayıp Fonksiyonu

Çapraz-Entropi Kayıp Fonksiyonu, sınıflandırma problemlerinde kullanılan kayıp fonksiyonudur. Bu fonksiyon eşitlik (62)'de gösterildiği gibi, modelin tahmin ettiği etiket ile gerçek sınıf etiketi arasındaki farkı ölçer. Amacı doğru tahmini sağlamak olduğu için modeli optimize eder.

$$K_{CE} = -\sum_{i=1}^n t_i \log p_i \quad (62)$$


Burada n sınıf sayısını; t_i , i 'inci sınıf için doğru etiketi; p_i i 'inci sınıf için Softmax katmanından çıkan olasılığı ifade etmektedir.

1.9. Transfer Öğrenme

Transfer öğrenme, önceden büyük bir veri seti ile eğitilmiş bir modelin ağırlıkları, özellikleri gibi bilgilerinin kullanılmasıdır. Transfer öğrenme, modele daha az veri gereksinimi, eğitim için daha az süre ve daha iyi genelleme yeteneği kazandırmaktadır. Böylece modellerin performansları ve başarıları artmaktadır.

1.10. k-kat Çapraz Doğrulama

Oluşturulan modelin performansını daha iyi bir şekilde değerlendirmek için kullanılan bir yöntem olan k- kat çapraz doğrulama, her bir kat için hem eğitim hem de test veri seti olarak veri setinin tamamını kullanır. Bu sayede modelin genelleme yeteneği de artırılmış olur.



Şekil 1.34. k-kat çapraz doğrulama aşamaları

Şekil 1.34.'te gösterilen k-kat çapraz doğrulamada ilk olarak veri seti k parçaya ayrılır. Ayrılan parçalardan ilk parça test için geriye kalan parçalar eğitim için kullanılır. Model eğitilir. Model ayrılmış olan test parçası ile test edilir ve test doğruluğu ölçülür. Ayrılan her

bir parça eğitim-test işlemleri gerçekleştirilir. Test doğrulukları ortalaması alınarak nihai test doğruluğu elde edilir.

1.11. Performans Ölçüm Metrikleri

Sınıflandırma ve bölütleme için oluşturulan modellerin performanslarını ölçmek için çeşitli metrikler kullanılmaktadır. Kullanılan bu metrikler baz alındığında gerçek pozitif (DP), pozitif sınıfta yer alan ve modelin pozitif olarak sınıflandırdığı örnek sayısı; yanlış pozitif (YP), negatif sınıfta yer alan ve modelin pozitif olarak sınıflandırdığı örnek sayısı; gerçek negatif (DN), negatif sınıfta yer alan ve modelin negatif olarak sınıflandırdığı örnek sayısı; yanlış negatif (YN), pozitif sınıfta yer alan ve modelin negatif olarak sınıflandırdığı örnek sayısını temsil etmektedir.

	Tahmin	
	DP	YP
Gerçek	YN	DN

Şekil 1.35. Doğruluk matrisi

Şekil 1.35.'te DP,YP,YN ve DN terimleri kullanılarak verilen bir karmaşıklık matrisi yer almaktadır.

1.11.1.Segmentasyon Performans Ölçüm Metrikleri

Görüntülerin lezyon ve arka plan piksellerinin sınıflandırılması için kullanılan modellerde Jaccard indeksi, Dice katsayısı, duyarlılık, özgüllük ve doğruluk metrikleri modellerin performansı ölçmek amacıyla kullanılmaktadır. Bu metrikler sırasıyla eşitlik (58)- (62)'de gösterilmiştir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (58)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (59)$$

$$Doğruluk = \frac{DP+DN}{DP+YP+YN+DN} \quad (60)$$

$$Jaccard \text{ İndeksi} = \frac{TP}{TP+YN+YP} \quad (61)$$

$$Dice \text{ Katsayısı} = \frac{2TP}{2TP+YP+YN} \quad (62)$$

1.11.2.Sınıflandırma Performans Ölçüm Metrikleri

Görüntülerinin sınıflandırılması için duyarlılık, özgüllük, doğruluk ve dengeli doğruluk metrikleri oluşturulan modellerin performansını ölçmektedir. Dengeli doğruluk metriği eşitlik (63)'te gösterilmiştir.


$$Dengeli \text{ Doğruluk} = \frac{(Duyarlılık+Özgüllük)}{2} \quad (63)$$

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

2.1.Giriş

Bu tez çalışmasında, dermoskopi görüntülerinin segmentasyonu ve sınıflandırılmasına dayalı yöntemler geliştirilmiştir.

Şekil 2.1.'de verildiği üzere tez çalışması 3 kapsamda incelenmektedir. Geleneksel makine öğrenmesi ile sınıflandırma kapsamında görüntülerin yeniden boyutlandırılması ve görüntülerdeki artefaktların kaldırılması ön işlemlerinden sonra, ilk olarak aktif kontur modeli uygulanmış ve bölütleme adımı tamamlanmıştır. Renk bileşenlerinin ortalama ve standart sapma değerleri; asimetri, sınır ve çap değerleri; zıtlık, enerji, homojenlik ve korelasyon değerleri gibi toplamda 13 tane özellik çıkarılmıştır. Bölütleme aşamasından sonra elde edilen özellikler k-NN sınıflandırıcı ile sınıflandırılmıştır. Yapılan başka bir çalışmada dermoskopi görüntüleri yeniden boyutlandırma ve görüntülerdeki artefaktların kaldırılması ön işlemlerinden sonra renk bileşenlerinin ortalama ve standart sapma değerleri; asimetri, sınır ve çap değerleri; zıtlık, enerji, homojenlik ve korelasyon değerleri gibi toplamda 13 tane özellik çıkarılmıştır. Çıkarılan özellikler, k-NN, destek vektör makineleri, kolay topluluk sınıflandırıcı, RUSBoost sınıflandırıcı, dengelenmiş torbalama sınıflandırıcı, dengelenmiş rastgele orman sınıflandırıcı ile sınıflandırılmış ve sonuçlar karşılaştırılmıştır. Derin öğrenme ile sınıflandırma kapsamında dermoskopi görüntüleri popüler modeller olan ResNet-200, EfficientNet ve CoAtNet ağları ile sınıflandırılmış ve başarıları karşılaştırılmıştır. Derin öğrenme ile segmentasyon kapsamında görüntüler U-Net, SegNet ve DeepLabV3+ ile segmente edilmiş, ardından ağırlıklı çoğunluk oylaması ile nihai sonuç elde edilmiştir ve ağların segmentasyon başarıları karşılaştırılmıştır.



Şekil.2.1. Tez kapsamı

2.2. Deri Kanserinin Otomatik Tanınması

2.2.1. Veri Setleri

Bu çalışmada International Skin Imaging Collaboration (ISIC) 2017 ve ISIC 2019 yarışmalarının veri setleri kullanılmıştır.

2.2.1.1. ISIC 2017

ISIC 2017[81] veri seti 2000 eğitim, 600 test verisinden ve 3 sınıftan oluşmaktadır. Bu sınıflar örnek sayıları ile 374 melanoma, 254 seborrheic keratosis ve 1372 benign nevusden oluşmaktadır.

ISIC 2017 yarışması sınıflandırma problemi, dermoskopi görüntülerinin 3 farklı sınıf (melanom, nevus ve seboeik keratoz) içeren 2 farklı ikili sınıflandırılması probleminden oluşmaktadır. İlk sınıflandırma probleminde melanom sınıfının, nevus ve seboeik keratoz sınıfından ayrılması istenirken ikinci sınıflandırma probleminde melanom ve seboeik keratoz sınıfının ile nevus sınıfının ayrılması istenmektedir.



Şekil.2.2. ISIC 2017 veri setinin birinci sınıflandırma probleminde yer alan eğitim görüntüleri örnekleri: üst satır: melanom; alt satır: nevus ve seboeik keratoz

Şekil 2.2.'de sırasıyla ISIC2017 veri setinde yer alan her bir sınıfa ait görseller gösterilmiştir.

2.2.1.2. ISIC 2019

ISIC 2019[21] veri seti 4522 melanoma, 12875 melanocytic nevus, 3323 basal cell carcinoma, 867 actinic keratosis, 2624 benign keratosis, 239 dermatofibroma, 253 vascular lesion, 628 squamous cell carcinoma olmak üzere 25331 dermoskopi görüntüsünden ve 8 sınıftan oluşmaktadır. Şekil 2.3.'te sırasıyla ISIC2019 veri setinde yer alan her bir sınıfa ait görseller gösterilmiştir.




Şekil 2.3.ISIC 2019 veri kümesindeki her sınıfa ait örnek görüntüler. Sol üstten sağa: Aktinik keratoz, bazal hücreli karsinom, iyi huylu keratoz, dermatofibroma, melanom, melanosit nevus, skuamöz hücreli karsinom ve vasküler lezyon

2.2.2.Dermoskopi Görüntülerinin Makine Öğrenmesi ile Sınıflandırılması

2.2.2.1.Ön İşlemler


Dermoskopi görüntüleri segmentasyon ve sınıflandırma başarısını arttırmak için özelliklerin çıkarımı adımından önce çeşitli ön işlemlere tabi olurlar. Bu sayede hem ağa giriş görüntüsü görüntüdeki veri kaybı en aza indirilerek uygun hale gelmiş olur hem de görüntüde başarıyı olumsuz etkileyecek kıl, cetvel ve mürekkep izi gibi çeşitli artefaktlar kaldırılmış olur.

Görüntülerdeki hesaplama karmaşıklığını düşürmek adına piksel alan ilişkisi kullanılarak görüntüler farklı boyutlardan yeniden örnekleme yardımıyla yeniden boyutlandırılır. Yapılan bütün çalışmalarda Şekil 2.4.'te gösterildiği gibi görüntüler 224x224 boyutlarına yeniden ölçeklendirilmiştir.



Şekil 2.4.(a) Örnek dermoskopi görüntüsü, (b) Örnek dermoskopi görüntüsünün 224x224 boyutlarına ölçeklendirilmesi

DullRazor algoritması sayesinde dermoskopi görüntülerinde segmentasyon ve sınıflandırma başarısını düşüren kıl artefaktı kaldırılmıştır.



Şekil 2.5. (a) Önişlem uygulanmamış görüntü,(b) DullRazor algoritması uygulanmış görüntü

Şekil 2.5.(a)'da bir dermoskopi görüntüsü, Şekil 2.5.(b)'de DullRazor algoritması uygulanmış bir görüntü verilmiştir.

2.2.2.2. Dermoskopi Görüntülerinin Bölütlenmesi

Lezyon segmentasyonu, lezyonun görüntüdeki yerinin belirlenmesinde; sınır, çap gibi özelliklerinin doğru belirlenmesinde ve sınıflandırmadaki doğruluğun artırılmasında en önemli adımdır.

2.2.2.2.1.Otsu Metodu

Görüntüler RGB renk uzayından HSV renk uzayına dönüştürülür. Bu dönüşüm için dermoskopi görüntüsünün her bir pikselinde bulunan R,G,B değerleri $[0,1]$ arasına normalize edilir, yeni oluşan değerler R',G',B' olarak adlandırılır. Normalize edilen değerler arasındaki maksimum değer C_{max} , minimum değer C_{min} olarak atanır. Maksimum değer ile minimum değer arasındaki fark ise Δ değerini temsil eder. Bu değerler yardımıyla H,S,V değerleri sırasıyla eşitlik (64),(65),(66) ile bulunur. Ardından gauss bulanıklaştırma uygulanan görüntü ile HSV uzayındaki görüntünün ağırlıklı toplamları hesaplanarak yeni bir görüntü elde edilir. Elde edilen yeni görüntü eşikleme uygulanması için gri seviyeye dönüştürülür.


$$H = \begin{cases} 0^{\circ}, & \Delta = 0 \\ 60^{\circ} \times \left(\frac{G' - B'}{\Delta} \bmod 6 \right), & C_{max} = R' \\ 60^{\circ} \times \left(\frac{G' - B'}{\Delta} + 2 \right), & C_{max} = G' \\ 60^{\circ} \times \left(\frac{R' - G'}{\Delta} + 4 \right), & C_{max} = B' \end{cases} \quad (64)$$

$$S = \begin{cases} 0, & C_{max} = 0 \\ \frac{\Delta}{C_{max}}, & C_{max} \neq 0 \end{cases} \quad (65)$$

$$V = C_{max} \quad (66)$$

Dönüştürülen görüntüye Otsu eşikleme uygulanmıştır. Otsu eşiklemede, gri seviyeye dönüştürülen görüntünün histogramı, tek eşik değeri için oluşan ön ve arka piksellerin ağırlığı ($w_{\bar{o}}$, w_a), ortalaması ve varyansları ($V_{\bar{o}}$, V_a) hesaplanır. Son olarak sınıf içi varyans eşitlik (67) ile hesaplanır.

$$\text{Sınıf içi varyans} = w_{\bar{o}} \times V_{\bar{o}} + w_a \times V_a \quad (67)$$



Şekil 2.6.(a) Örnek dermoskopi görüntüsü, (b) maske görüntüsü, (c) Otsu eşikleme ile oluşturulan segmentasyon görüntüsü


Şekil 2.6.'da gösterildiği gibi örnek dermoskopi görüntüsüne ön işlemler uygulandıktan sonra Otsu eşikleme uygulanmış ve 2.6.(c)'deki segmentasyon görüntüsü elde edilmiştir.

2.2.2.2.2. Aktif Kontur Modeli

Aktif kontur modeli ile segmentasyon aşağıdaki adımlar ile gerçekleşmektedir:

- Giriş görüntüsü ilk olarak sigma değeri 3 olan çok boyutlu bir Gauss filtresi ile yumuşatılır.
- Görüntüye aktif kontur modeli uygulanır ve sınır çizgisi elde edilir.
- Elde edilen sınırın koordinatları yardımıyla yeni bir görüntü oluşturularak sınır çizgileri içindeki lezyon alanı beyaz, arka plan siyahla doldurularak maske görüntüsü oluşturulur. Bu görüntü, şekil özelliklerini elde etmek için kullanılır.
- Maske görüntüsü ve giriş görüntüsü üzerinde koordinat eşlemesi yapılarak sadece lezyon alanı ve siyah arka planlı bir görüntü elde edilir. Bu görüntü, doku ve renk niteliklerini oluşturmak için kullanılır.

Yeniden boyutlandırılan görüntüler üzerinde lezyon bölgesinin kenarlarına kapalı bir eğri uydurularak lezyon bölgesinin arka plandan ayrılması sağlanmıştır. Lezyon bölgesinin belirlenmesi için el ile bir başlangıç noktası aktif kontur modeline girdi olarak verilir. ISIC 2017 ve ISIC 2019 veri kümelerinde lezyonlar genellikle dermoskopi görüntüsünün merkezinde yer aldığı için görüntü merkezinden bir daire başlatılarak sınırın bu kapalı eğri içerisine sığdırılması sağlanmıştır. Aktif kontur modelinin uzunluk biçim(α) parametresi 0.015, yumuşatma biçim(β) parametresi 10 ve adım parametresi(γ) 0.001 seçilmiştir. Ardından, elde edilen sınır bilgisinden yararlanılarak lezyon görüntüsünün maske görüntüsü elde edilmiştir.



Şekil.2.7. (a)Örnek görüntü, (b) aktif kontur yöntemi ile bölütlenmiş görüntü, (c) maske görüntüsü, (d) doku görüntüsü

Şekil 2.7.'de sırasıyla veri setinde bulunan bir görüntü, aktif kontur yöntemi ile bölütlenmiş görüntü, varsayılan maske görüntüsü ve çıkarılan doku görüntüsü yer almaktadır.

2.2.2.3. Dermoskopi Görüntülerinden Özellik Çıkarımı

Bölütlenen dermoskopi görüntülerinden renk(İlgili lezyon alanının), şekil ve doku özellikleri olmak üzere toplamda 13 özellik çıkarılmıştır. RGB renk kanallarının her biri için ortalama ve standart sapma olmak üzere 6; asimetri, sınır ve çap için 3; zıtlık, enerji, homojenlik ve korelasyon için 4 özellik çıkarılmıştır.

2.2.2.4.Dermoskopi Görüntülerinin Sınıflandırılması

2.2.2.4.1.k-NN Yöntemi ile Sınıflandırma

Önişlemleri tamamlanan eğitim görüntülerine uygulanan aktif kontur modeli ile lezyon sınırları belirlendikten sonra lezyon alanlarından renk, şekil ve doku özellikleri çıkarılmış ve 13 elemanlı bir özellik vektörü elde edilmiştir. Test görüntülerine ön işleme, bölütleme ve özellik çıkarma adımları da uygulanmış ve her görüntü için özellik vektörleri elde edilmiştir. Sınıflandırma adımında kullanılan veri setine en uygun k değerini belirlemek için farklı k değerleri için algoritma çalıştırılmıştır.


Tablo 2.1.k-NN Sınıflandırma Sonuçları

k	Duyarlılık	Özgüllük	Doğruluk
1	%80	%20	%68
2	%80	%20	%68
3	%80	%11	%73
4	%90	%12	%75
5	%94	%8	%77


Önerilen yöntemin performans sonuçları Tablo 2.1.'de verilmiştir. k değerinin 1 ile 5 arasında değişmesi durumunda duyarlılık değerinin arttığı, özgüllük değerinin ise azaldığı görülmektedir. En iyi sonucun %80 duyarlılık, %20 özgüllük ve %68 doğruluk değerleri ile k=2 için elde edildiği görülmektedir. Özgüllük değerinin düşük olmasının başlıca sebepleri, çıkarılan özelliklerin nevus ve seboreik keratoz sınıfını ayırt etmede yeterli olmaması ve sınıflandırıcının zayıf olmasıdır.

Diğer bir çalışmada ön işlemleri tamamlanan eğitim görüntülerine uygulanan otsu metodundan sonra bölütlenen görüntüden çıkarılan 13 özellik k-NN modeli ile sınıflandırılmıştır. k değeri [1,20] arasında, uzaklık metriği olarak Öklid, ağırlık olarak ise tüm komşuların ağırlıklarının eşit veya yakın komşuların uzak komşulara göre ağırlığının daha fazla olacağı anlamına gelmektedir.

Şekil 2.8.'de doğruluk ve özgüllük değerinin sürekli arttığı, hassasiyet değerinin düştüğü ve buna bağlı olarak dengeli doğruluk değerinin de azaldığı gözlemlenmiştir. Şekil 2.9.'da da doğruluk ve özgüllük değerinin sürekli arttığı, hassasiyet değerinin düştüğü ve buna bağlı olarak dengeli doğruluk değerinin de azaldığı gözlemlenmiştir. Veri setindeki sınıflarda bulunan veri sayılarının dengesiz olarak dağıldığı göz önünde bulundurulursa doğruluk metriğinin yüksek olduğu k değerini en iyi sonuç olarak seçmek doğru olmayacağı için diğer metriklerin de yüksek olduğu bir k değeri seçilmiştir. Şekil 2.8. ve Şekil 2.9.'a göre en iyi sonuçlar k=2 ve ağırlık değerinin komşulara herhangi bir ağırlık vermeden oluşan sınıflandırma olduğu gözlemlenmiştir.




Şekil 2.8. Yakın komşuların ağırlıklarının arttırılmasıyla oluşan k-NN sonuçları



Şekil 2.9. Komşulara herhangi bir ağırlık vermeden oluşan k-NN sonuçları


2.2.2.4.2. Destek Vektör Makineleri Yöntemi ile Sınıflandırma

Önişlemleri tamamlanan eğitim görüntülerine uygulanan otsu metodundan sonra bölütlenen görüntüden çıkarılan 13 özellik destek vektör makineleri ile sınıflandırılmıştır. c değeri $[0.1,1]$ arasında seçilmiştir. İki sınıf için her bir sınıfın ağırlığı hesaplandıktan sonra ters sınıf frekansı ağırlıklandırma yapılarak sınıf ağırlıkları dengeli hale getirilmiştir. Sınıflandırma işlemi, veri setinin hem dengelenmiş hali ile hem de dengeleme durumu olmadan denenmiştir. Şekilde doğruluk, özgüllük, hassasiyet ve dengeli doğruluk değerleri yer almaktadır.



Şekil 2.10. Veri setindeki verilerin dağılımları dengeli olduğunda SVM sonuçları

Şekil 2.10.'da ISIC 2017 veri setindeki verilerin dağılımlarının ters sınıf frekansı ağırlıklandırma yaklaşımı dengelendiğinde oluşan sonucun c parametresine göre değişimi gösterilmektedir. c parametresi arttıkça hassasiyet metriği düşmektedir. Dengeli doğruluk metriği değişmezken, özgüllük ve doğruluk metrikleri $c=0.6$ 'ya kadar arttıktan sonra sabit kalmaktadır.



Şekil 2.11. Veri setindeki verilerin dağılımları dengesiz olduğunda SVM sonuçları

Şekil 2.11.'de ISIC 2017 veri setindeki verilerin dağılımlarının dengesiz olması durumunda sonucun c parametresine herhangi bir değişimin olmadığı gözlemlenmiştir.

Bazı veri setlerindeki özelliklerin SVM yöntemi ile sınıflandırılması aşamasında c parametresine bağımlılıkları düşük olabilmektedir. Ancak Şekil 2.11.'de yine aynı özelliklerin SVM yöntemi ile sınıflandırılmasında c parametresinin sınıflandırma sonuçlarını değiştirdiği gözlemlenmiştir. İkinci bir neden olarak veri setinin karmaşıklığı göz önünde bulundurulduğunda veriler kolay ayrılabilir ise düşük bir c değeri seçmek gerekir. Veriler kolay ayrılmıyor ise c değeri belirli bir aralıkta yüksek başarı verebilmektedir.

Şekil 2.10. ve Şekil 2.11.'e göre en iyi sonuç veri setinin dengeli ve $c=0.8$ olarak seçildiği durumdur.

2.2.2.4.3. Kolay Topluluk Sınıflandırıcısı Yöntemi ile Sınıflandırma

Yeniden boyutlandırma, otsu eşikleme yöntemi ve 13 özellik çıkarımı yöntemiyle sonra oluşan özellikler kolay topluluk sınıflandırıcısı ile sınıflandırılmıştır. Temel sınıflandırıcı olarak AdaBoost sınıflandırıcı kullanılmıştır. AdaBoost sınıflandırıcısının öğrenme katsayısı 0.1 olarak seçilmiştir. Burada öğrenme katsayısı her yinelemede sınıflandırıcılara uygulanan ağırlığı ifade etmektedir. Kolay topluluk ve AdaBoost

sınıflandırıcısının iterasyon sayısı 50,100,150,200 ve 250 denenmiştir. Tablo 2.2.’deki sütunlar AdaBoost sınıflandırıcısının iterasyon sayısını, satırlar ise Kolay topluluk sınıflandırıcısının iterasyon sayısını temsil etmektedir. Sonuçlar sırasıyla doğruluk, özgüllük, hassasiyet ve dengeli doğruluk değerlerini göstermektedir.

Tablo 2.2. Kolay topluluk ve AdaBoost sınıflandırıcısı ile elde edilen sınıflandırma sonuçları

	50	100	150	200	250
50	%60.16 %57.55 %70.94 %64.24	%61.16 %58.38 %72.64 %65.51	%61.66 %58.79 %73.50 %66.15	%61.50 %58.59 %73.50 %66.04	%62.16 %59.00 %75.21 %67.10
100	%61.16 %58.79 %70.94 %64.86	%61.50 %58.38 %74.35 %66.37	%61.66 %58.38 %75.21 %66.79	%61.33 %58.38 %73.50 %65.94	%61.66 %58.79 %73.50 %66.15
150	%61.50 %58.79 %72.64 %65.72	%61.16 %57.97 %74.35 %66.16	%62.16 %59.00 %75.21 %67.10	%61.83 %59.00 %73.50 %66.25	%61.50 %58.59 %73.50 %66.04
200	%61.66 %59.21 %71.79 %65.50	%62.00 %59.00 %74.35 %66.68	%62.16 %59.00 %75.21 %67.10	%61.50 %58.59 %73.50 %66.04	%61.33 %58.38 %73.50 %65.94
250	%62.00 %59.62 %71.79 %65.71	%62.33 %59.42 %74.35 %66.88	%62.66 %59.62 %75.21 %67.42	%62.00 %59.21 %73.50 %66.35	%61.83 %58.79 %74.35 %66.57

Tablo 2.2.’ye göre kolay topluluk sınıflandırıcısının sınıflandırıcı sayısı arttıkça genel olarak doğruluk, özgüllük, hassasiyet ve dengeli doğruluk değerleri artmaktadır. Kolay topluluk ve AdaBoost sınıflandırıcısı ile elde edilen sınıflandırma sonuçlarına göre en iyi doğruluk değeri %62.66, özgüllük değeri %59.62, hassasiyet değeri %75.21 ve dengeli doğruluk değeri %67.42 olarak bulunmuştur. Bu değerlere göre en iyi sonuçlar kolay topluluk sınıflandırıcısının iterasyon sayısının 250 ve AdaBoost sınıflandırıcısının iterasyon sayısının 150 olduğu sonuçlar olarak gözlemlenmiştir.

2.2.2.4.4. RUSBoost Sınıflandırıcı Yöntemi ile Sınıflandırma

Yeniden boyutlandırma, otsu eşikleme yöntemi ve 13 özellik çıkarımı yöntemiyle sonra oluşan özellikler kolay topluluk sınıflandırıcısı ile sınıflandırılmıştır. Temel sınıflandırıcı olarak Gradyan Arttırma sınıflandırıcı kullanılmıştır. Gradyan Arttırma sınıflandırıcısının öğrenme katsayısı 0.1, RUSBoost sınıflandırıcısının öğrenme katsayısı 0.2 olarak seçilmiştir. RUSBoost sınıflandırıcısının ve Gradyan Arttırma sınıflandırıcısının iterasyon sayısı 50,100,150,200 ve 250 denenmiştir. Her bir tablodaki sütunlar Gradyan Arttırma sınıflandırıcısının iterasyon sayısını, satırlar ise Gradyan Arttırma sınıflandırıcısının maksimum derinliğini temsil etmektedir. Maksimum derinlik, ağaçtaki düğüm sayısını temsil etmektedir. Sonuçlar sırasıyla doğruluk, özgüllük, hassasiyet ve dengeli doğruluk değerlerini göstermektedir.

Tablo 2.3.RUSBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 50 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%80.50	%84.83	%86.83	%89.00	%90.16
	%79.08	%82.19	%84.26	%86.74	%87.99
	%86.32	%95.72	%97.43	%98.29	%99.14
	%82.70	%88.96	%90.85	%92.52	%93.56
2	%95.50	%97.50	%97.33	%95.66	%84.00
	%94.40	%96.27	%96.68	%94.61	%82.60
	%100.00	%100.00	%100.00	%100.00	%89.74
	%97.20	%98.13	%98.34	%97.30	%86.17
3	%93.16	%86.50	%84.50	%79.66	%86.50
	%91.77	%83.43	%82.81	%77.22	%85.30
	%100.00	%99.14	%91.45	%89.74	%91.45
	%98.86	%91.29	%87.13	%83.48	%88.37

Tablo 2.3.'e göre maksimum derinlik=1 olduğunda gradyan arttırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk ve dengeli doğruluk değerleri artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=100'e kadar doğruluk değeri artmış, daha sonra azalmaya başlamıştır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=150'ye kadar artmış, daha sonra azalmaya başlamıştır. Maksimum derinlik=3 olduğunda sınıflandırıcı sayısı=200'e kadar doğruluk ve dengeli doğruluk değerleri azalmaktadır, ardından artmaya başlamaktadır.

Tablo 2.4.RUSBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 100 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%85.66 %83.85 %93.16 %88.50	%91.16 %89.23 %99.14 %94.18	%93.16 %91.71 %99.14 %95.43	%94.66 %93.37 %100.00 %96.68	%95.73 %94.82 %100.00 %97.41
2	%98.83 %98.55 %100.00 %99.27	%99.16 %98.69 %100.00 %99.48	%93.16 %91.51 %100.00 %95.75	%64.33 %56.72 %95.72 %76.22	%93.33 %94.20 %89.74 %91.97
3	%99.83 %99.79 %100.00 %99.89	%86.16 %83.43 %97.43 %90.43	%82.00 %83.22 %76.92 %80.07	%83.16 %79.08 %100.00 %89.54	%88.00 %85.09 %100.00 %92.54

Tablo 2.4.'e göre maksimum derinlik=1 olduğunda gradyan artırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk ve dengeli doğruluk değerleri artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=100'e kadar doğruluk değeri artmış, daha sonra azalıp artmaya başlamıştır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=200'e kadar azalmış, daha sonra artmaya başlamıştır. Maksimum derinlik=3 olduğunda sınıflandırıcı sayısı=200'e kadar doğruluk değeri azalmaya, ardından artmaya başlamıştır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=150'ye kadar azalmaktadır, ardından artmaya başlamaktadır.

Tablo 2.5.RUSBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 150 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%88.66 %86.33 %98.29 %92.31	%93.66 %92.33 %99.14 %95.74	%95.66 %94.61 %100.00 %97.30	%96.83 %96.06 %100.00 %98.03	%97.33 %96.68 %100.00 %98.34
2	%99.33 %99.17 %100.00 %99.58	%99.33 %99.17 %100.00 %99.58	%91.50 %90.26 %96.58 %93.42	%88.83 %92.75 %72.64 %82.70	%93.66 %92.13 %100.00 %96.06
3	%100.00 %100.00 %100.00 %100.00	%90.0 %89.23 %93.16 %91.19	%88.16 %87.78 %89.74 %88.74	%92.83 %95.23 %88.03 %91.63	%89.00 %86.33 %100.00 %93.16

Tablo 2.5.'e göre maksimum derinlik=1 olduğunda gradyan artırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk ve dengeli doğruluk değerleri artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=100'e kadar doğruluk değeri sabit kalmış, daha sonra azalıp artmaya başlamıştır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=100'e kadar sabit kalmış, daha sonra azalıp artmaya başlamıştır. Maksimum derinlik=3 olduğunda en iyi sonuçları sınıflandırıcı sayısı=50'de vermiştir. Ardından doğruluk değeri sürekli artıp azalmış, dengeli değeri ise azalıp artmıştır.

Tablo 2.6. RUSBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 200 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%92.50 %90.89 %99.14 %95.01	%96.83 %96.06 %100.00 %98.03	%98.16 %97.72 %100.00 %98.86	%98.83 %98.55 %100.00 %99.27	%99.00 %98.75 %100.00 %99.37
2	%99.83 %99.79 %100.00 %99.89	%99.50 %99.37 %100.00 %99.68	%84.00 %82.81 %88.88 %85.85	%86.50 %87.37 %82.90 %85.13	%99.33 %99.17 %100.00 %99.58
3	%91.16 %89.02 %100.00 %94.51	%92.00 %90.06 %100.00 %95.03	%96.00 %96.06 %95.72 %95.89	%96.00 %95.23 %99.14 %97.19	%96.83 %96.06 %100.00 %98.03

Tablo 2.6.'ya göre maksimum derinlik=1 olduğunda gradyan arttırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk ve dengeli doğruluk değerleri artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=100'e kadar doğruluk değeri artmış, daha sonra azalıp artmaya başlamıştır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=200'e kadar azalmış, daha artmaya başlamıştır. Maksimum derinlik=3 olduğunda doğruluk ve dengeli doğruluk değerleri sürekli artmıştır.

Tablo 2.7. RUSBoost sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 250 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%93.83 %92.54 %99.14 %95.84	%97.33 %96.68 %100.00 %98.34	%98.33 %97.92 %100.00 %98.96	%98.83 %98.55 %100.00 %99.27	%99.16 %98.96 %100.00 %99.48
2	%99.83 %99.79 %100.00 %99.89	%99.33 %99.17 %100.00 %99.58	%88.00 %85.71 %97.43 %91.57	%90.50 %90.47 %90.59 %90.53	%91.16 %89.02 %100.00 %94.51
3	%92.16 %90.26 %100.00 %95.13	%96.50 %96.27 %97.43 %96.85	%96.83 %96.06 %100.00 %98.03	%95.50 %94.40 %100.00 %97.20	%98.83 %98.55 %100.00 %99.27

Tablo 2.7.'ye göre maksimum derinlik=1 olduğunda gradyan arttırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk ve dengeli doğruluk değerleri artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=150'ye kadar doğruluk değeri azalmış, daha sonra artmaya başlamıştır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=200'e kadar azalmış, daha sonra artmaya başlamıştır. Maksimum derinlik=3 olduğunda doğruluk sınıflandırıcı sayısı=150'ye kadar artmış daha sonra azalıp artmıştır. Dengeli doğruluk ise sınıflandırıcı sayısı=150'ye kadar artmış daha sonra azalıp artmıştır.

RUSBoost Sınıflandırıcısı ve Gradyan Arttırma Sınıflandırıcısının kullanıldığı sınıflandırma işleminde Tablo 2.3., Tablo 2.4., Tablo 2.5., Tablo 2.6. ve Tablo 2.7.'ye göre en iyi sonuçlar Tablo 2.5.'te Gradyan Arttırma sınıflandırıcısının iterasyon sayısının 50 ve Gradyan Arttırma sınıflandırıcısının maksimum derinliğinin 3 olduğu durumda elde

edilmektedir. Sırasıyla doğruluk %100, özgüllük %100, hassasiyet %100 ve dengeli doğruluk %100 olarak elde edilmiştir.

2.2.2.4.5. Dengelenmiş Torbalama Sınıflandırıcısı Yöntemi ile Sınıflandırma

Yeniden boyutlandırma, otsu eşikleme yöntemi ve 13 özellik çıkarımı yöntemiyle sonra oluşan özellikler kolay topluluk sınıflandırıcısı ile sınıflandırılmıştır. Temel sınıflandırıcı olarak Gradyan Arttırma Sınıflandırıcısı kullanılmıştır. Gradyan Arttırma Sınıflandırıcısının öğrenme katsayısı 0.1 olarak seçilmiştir. Dengelenmiş torbalama sınıflandırıcısının ve Gradyan Arttırma Sınıflandırıcısının iterasyon sayısı 50,100,150,200 ve 250 denenmiştir. Her bir tablodaki sütunlar Gradyan Arttırma Sınıflandırıcısının iterasyon sayısını, satırlar ise Gradyan Arttırma Sınıflandırıcısının maksimum derinliğini temsil etmektedir. Tabloda doğruluk, özgüllük, hassasiyet ve dengeli doğruluk değerleri sırasıyla yer almaktadır.

Tablo 2.8. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 50 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%62.50	%64.50	%65.33	%65.50	%65.83
	%60.66	%62.93	%63.98	%64.39	%65.01
	%70.08	%70.94	%70.94	%70.09	%69.23
	%63.57	%66.94	%67.46	%67.24	%67.12
2	%63.33	%63.33	%64.33	%64.50	%65.00
	%61.90	%62.52	%63.98	%64.39	%65.42
	%69.23	%66.67	%65.81	%64.96	%63.25
	%65.57	%64.60	%64.89	%64.67	%64.34
3	%65.33	%67.50	%67.67	%68.17	%67.50
	%65.22	%68.94	%69.15	%70.19	%69.77
	%65.81	%61.54	%61.54	%59.83	%58.12
	%65.55	%65.24	%65.34	%65.08	%63.95

Tablo 2.8.'e göre maksimum derinlik=1 olduğunda gradyan arttırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk değeri artmaktadır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=150'ye kadar arttıktan sonra azalmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=150'ye kadar doğruluk değeri sürekli artmaktadır. Dengeli doğruluk değeri ise sürekli artıp azalmaktadır. Maksimum derinlik=3 olduğunda doğruluk

sınıflandırıcı sayısı=200'e kadar artmış daha sonra azalmaya başlamıştır. Dengeli doğruluk ise sürekli artıp azalmaktadır.

Tablo 2.9. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 100 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%62.83	%64.33	%65.17	%65.67	%66.50
	%61.49	%63.35	%64.80	%65.22	%66.25
	%68.38	%68.37	%66.67	%67.52	%67.52
	%64.93	%65.87	%65.73	%66.37	%66.89
2	%63.17	%63.00	%63.83	%64.50	%64.67
	%62.31	%62.53	%64.39	%65.22	%65.42
	%66.67	%64.96	%61.54	%61.54	%61.54
	%64.49	%63.74	%62.96	%63.38	%63.48
3	%65.83	%66.83	%67.33	%67.83	%68.33
	%66.25	%68.32	%70.19	%70.81	%71.42
	%64.10	%60.68	%55.56	%55.56	%55.56
	%65.18	%64.50	%62.87	%63.18	%63.49

Tablo 2.9.'a göre maksimum derinlik=1 olduğunda gradyan arttırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk değeri 200'e kadar artmaktadır, sonra azalmaktadır. Dengeli doğruluk değeri ise sürekli artıp artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=100'e kadar doğruluk değeri azalmaktadır, ardından sürekli artmaktadır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=200'e kadar azalmaktadır, sonra artmaktadır. Maksimum derinlik=3 olduğunda doğruluk sınıflandırıcı arttıkça artmaktadır daha sonra azalmaya başlamıştır. Dengeli doğruluk ise sınıflandırıcı sayısı=150 olana kadar azalmaktadır, sonra artmaktadır.

Tablo 2.10. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 150 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%63.50	%64.83	%65.67	%66.33	%67.00
	%62.73	%64.18	%65.42	%66.04	%67.08
	%66.67	%67.52	%66.67	%67.52	%66.67
	%64.70	%65.85	%66.05	%66.78	%66.87
2	%64.67	%63.83	%64.67	%65.00	%65.17
	%64.60	%63.56	%65.21	%65.83	%66.05
	%64.96	%64.96	%62.39	%61.53	%61.53
	%64.78	%64.26	%63.81	%63.68	%63.79
3	%65.83	%68.17	%68.17	%68.50	%68.67
	%66.25	%69.56	%70.39	%71.01	%71.22
	%64.10	%62.39	%58.97	%58.12	%58.12
	%65.18	%65.98	%64.68	%64.57	%64.67

Tablo 2.10.'a göre maksimum derinlik=1 olduğunda gradyan artırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk ve dengeli doğruluk değerleri artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=100'e kadar doğruluk değeri düşmektedir, sonra artmaktadır. Dengeli doğruluk değeri ise sınıflandırıcı sayısı=200'e kadar düşüp sonra artmaktadır. Maksimum derinlik=3 olduğunda doğruluk sınıflandırıcı sayısı=150'ye kadar azalmış daha sonra artmaya başlamıştır. Dengeli doğruluk ise sürekli artıp azalmaktadır.

Tablo 2.11. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 200 olduğu sınıflandırma sonucu

	50	100	150	200	250
1	%63.00	%65.33	%65.67	%66.33	%66.50
	%61.90	%64.60	%65.22	%65.83	%66.05
	%67.52	%68.38	%67.52	%68.37	%68.38
	%64.71	%66.49	%66.37	%67.10	%67.22
2	%63.17	%63.17	%64.50	%63.33	%64.83
	%62.73	%62.73	%64.80	%65.01	%65.42
	%64.96	%64.96	%63.25	%61.54	%63.39
	%63.85	%63.85	%65.03	%63.27	%63.91
3	%65.67	%68.17	%68.00	%67.50	%68.17
	%66.04	%69.56	%70.40	%70.19	%70.80
	%64.10	%62.39	%58.20	%56.41	%57.26
	%65.07	%65.98	%64.26	%63.30	%64.03

Tablo 2.11.'e göre maksimum derinlik=1 olduğunda gradyan arttırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk ve dengeli doğruluk değerleri azalıp artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=150'ye kadar doğruluk değeri sürekli artmaktadır. Dengeli doğruluk değeri ise sürekli artıp azalmaktadır. Maksimum derinlik=3 olduğunda doğruluk sınıflandırıcı sayısı=100'e kadar artmış daha sonra azalmaya başlamıştır. Dengeli doğruluk ise sürekli artıp azalmaktadır.

Tablo 2.12. Dengelenmiş torbalama sınıflandırıcısında yükseltmenin sonlandırıldığı maksimum tahmin edici sayısının 250 olduğu sınıflandırma sonucu


	50	100	150	200	250
1	%63.50 %62.30 %68.38 %65.35	%65.00 %63.97 %69.23 %66.60	%63.17 %64.60 %67.52 %66.05	%65.67 %65.01 %68.38 %66.70	%66.33 %65.84 %68.38 %67.11
2	%63.50 %62.94 %65.81 %64.38	%63.83 %63.77 %64.10 %63.94	%64.33 %64.80 %62.39 %63.60	%64.33 %65.01 %61.54 %63.27	%64.33 %65.01 %61.54 %63.27
3	%66.50 %67.08 %64.10 %65.59	%67.67 %69.36 %60.68 %65.02	%67.83 %70.19 %58.12 %64.15	%68.00 %70.60 %57.26 %63.93	%68.33 %71.01 %57.26 %61.14

Tablo 2.12.'ye göre maksimum derinlik=1 olduğunda gradyan arttırma sınıflandırıcısının sınıflandırıcı sayısı arttıkça doğruluk ve dengeli doğruluk değerleri azalıp artmaktadır. Maksimum derinlik=2 olduğunda sınıflandırıcı sayısı=150'ye kadar doğruluk değeri sürekli artmaktadır, daha sonra sabit kalmaya devam etmiştir. Dengeli doğruluk değeri ise sürekli azalıp sabit kalmıştır. Maksimum derinlik=3 olduğunda doğruluk değeri sürekli artmıştır. Dengeli doğruluk ise sürekli azalmaktadır.


Dengelenmiş torbalama sınıflandırıcısının ve Gradyan Arttırma Sınıflandırıcısının kullanıldığı sınıflandırma işleminde Tablo 2.8. - Tablo 2.12.'ye göre doğruluk, özgüllük, hassasiyet ve dengeli doğruluk değerleri birbirine yakın değerler olarak belirlenmiştir. Ancak Tablo 2.10.'da Gradyan Arttırma Sınıflandırıcısının iterasyon sayısının=250 ve , Gradyan Arttırma Sınıflandırıcısının maksimum derinliğinin 1 olduğu durumda sırasıyla doğruluk, özgüllük, hassasiyet ve dengeli doğruluk %67.00, %67.08,%66.67 ve %66.87 olarak diğer sonuçlara nazaran daha yüksek bir sonuç belirlenmiştir. Ayrıca her tabloda maksimum derinlik arttıkça özgüllük değerinin azaldığı gözlemlenmiştir.

2.2.2.4.6. Dengelenmiş Rastgele Orman Sınıflandırıcı Yöntemi ile Sınıflandırma

Dengelenmiş Rastgele Orman Sınıflandırıcısı için ormandaki ağaç sayısı [50,800] arasında belirli aralıklarla denenmiştir. Veri setinde bulunan sınıflardaki örneklerin sayılarındaki dengesizlik sebebiyle sınıf ağırlığı dengeli ve dengesiz olarak denenmiştir.



Şekil 2.12. Veri setindeki verilerin dağılımları dengesiz olduğunda dengelenmiş rastgele orman sınıflandırıcı sonuçları




Şekil 2.13. Veri setindeki verilerin dağılımları dengeli olduğunda dengelenmiş rastgele orman sınıflandırıcı sonuçları

Şekil 2.12. ve Şekil 2.13.'e göre veri dağılımlarının dengeli olduğu ve ağaç sayısının 705 olduğu durumda sırasıyla doğruluk, özgüllük, hassasiyet ve dengeli doğruluk değerleri %65.1, %65.4, %64.1, %70,09 olarak bulunmuştur.

2.2.3. Dermoskopi Görüntülerinin Tamamen Evrişimli Sinir Ağları ile Bölütlenmesi

2.2.3.1. Verinin Arttırılması

Derin öğrenme yöntemiyle segmentasyon için ISIC 2017 veri setinin sayısı arttırılmıştır. Önce görüntüler 90° , 180° ve 270° derece döndürülmüştür, daha sonra oluşan görüntüler yatay olarak çevrilmiştir. Bu sayede eğitim görüntü sayısı 2000'den 16000'e çıkmıştır.



Şekil 2.14. Melanom sınıfının veri artırma yöntemi ile artırılmış görüntüleri. Üst satır: soldan sağa sırasıyla orijinal, 90° , 180° ve 270° döndürme ile oluşan görüntüler. Alt satır: üst satırdaki görüntülerin yatay olarak çevrilmiş görüntüleri


Melanom sınıfından bir örnek için oluşturulmuş yeni görseller Şekil 2.14.'te gösterilmiştir.

2.2.3.2. Tamamen Evrişimli Sinir Ağları ile Bölütleme

İlk olarak, hesaplama karmaşıklığını azaltmak için ISIC veri setindeki eğitim görüntülerinin boyutları 224×224 olarak yeniden ölçeklendirilmiştir. Eğitim sürecinde kullanılan görüntü sayısını artırmak ve aşırı uyum problemini önlemek için her bir görüntü 90° , 180° ve 270° döndürülerek ve ardından yatay olarak çevrilerek veri artırımı gerçekleştirilmiştir.

Şekil 2.15.'te verildiği gibi çalışmada önerilen topluluk modelinde, ilk olarak FCN, SegNet, U-Net ve DeepLabV3+ modelleri ile segmentasyon gerçekleştirilmiştir. Daha sonra modellerin performansı baz alınarak FCN, SegNet ve U-Net'in oyları aynı ağırlıkta kalmıştır, DeepLabv3+'nın oyu ise iki katına çıkarılmıştır. Dermoskopi görüntülerindeki ön ve arka plan piksellerinin sınıf dengesizliği sorununun üstesinden gelmek için, ters sınıf frekansı ağırlıklandırma yaklaşımı kullanılmıştır. Ters sınıf frekansı ağırlıklandırma yaklaşımı, veri setindeki toplam örnek sayısının sınıf sayısı ile ilgili sınıfın örnek sayısının çarpımına orandır. Bu nedenle, FCNN ağlarının her biri, piksel sınıflandırma katmanının sınıf ağırlıklı bir piksel sınıflandırma katmanı ile değiştirilmesiyle ince ayara tabi tutulur. Ardından, FCN, U-Net, SegNet ve DeepLabv3+ ağlarından elde edilen semantik bölütleme haritaları çoğunluk oylamalı topluluk modelini besler ve nihai karar oylama yapılarak belirlenir.

Çoğunluk oylamasına örnek olarak, FCN modeli bir pikseli arka plan olarak sınıflandırırken DeepLabv3+, U-Net ve SegNet modelleri pikseli lezyon olarak sınıflandırır, pikselin lezyon olmasına karar verilir.




Şekil.2.15. Segmentasyon için ağırlıklı oylama

Modellerin optimizasyonu için momentum ve ağırlık azalması parametreleri sırasıyla 0,9 ve 0,0001 olarak ayarlanmış momentumlu ile stokastik gradyan iniş kullanılmıştır. Öğrenme oranı U-Net, SegNet ve DeepLabV3+ mimarileri için 0,001 ve FCN mimarisi için 0,00001 olarak ayarlanmıştır. Yığın boyutu U-Net, DeepLabV3+ ve SegNet mimarileri için 16, FCN mimarisi için 8 olarak ayarlanmış ve öğrenme 20 devirden sonra durdurulmuştur.

Tablo 2.13. Tamamen evrişimli sinir ağlarının segmentasyon metrik sonuçları

Modeller	Jaccard İndeksi	Dice Katsayısı	Doğruluk	Hassasiyet	Özgüllük
FCN	%91.45	%95.53	%92.88	%98.15	%74.67
SegNet	%85.66	%90.45	%85.66	%87.49	%79.35
U-Net	%88.90	%94.18	%91.15	%92.33	%87.05
DeepLabV3+	%92.66	%96.19	%93.96	%98.37	%78.75
Çoğunluk Oylaması	%92.68	%96.20	%93.99	%98.08	%79.86

FCN, SegNet, U-Net, DeepLabv3+ ve çoğunluk oylama yaklaşımının segmentasyon metrik sonuçları Tablo 2.13.'te verilmiştir. Elde edilen sonuçlar, DeepLabv3+'nın %92.66 Jaccard İndeksi, %96,19 Dice katsayısı, %93,96 doğruluk ve %98,37 hassasiyet ile FCN, SegNet ve U-Net mimarilerinden daha iyi performans sağladığı göstermektedir. Buna karşın en yüksek özgüllük değeri %87,05 ile U-Net modelinde elde edilmiştir. Segmentasyon sonuçları Jaccard indeksi, Dice, doğruluk ve özgüllük metrikleri açısından çoğunluk oylama şemasının performansının DeepLabV3+ modelinin performansından daha iyi olduğunu göstermektedir.



Şekil 2.16. Segmentasyon modellerinin görsel sonuçları, (a) gerçek segmentasyon, (b) tamamen evrişimli ağ, (c) U-Net, (d) SegNet, (e) DeepLabV3+ ve (f) önerilen topluluk modeli

Şekil 2.16.'da örnek bir test görüntüsü, test görüntüsünün maskesi, FCNN ağlarının her biri ve önerilen topluluk modeli kullanılarak elde edilen segmentasyon sonuç görüntüleri gösterilmektedir. Önerilen model kullanılarak elde edilen maske görüntüsünün görsel olarak gerçek segmentasyon görüntüsüne çok benzediği görülmektedir.

2.2.4. Dermoskopi Görüntülerinin Derin Öğrenme ile Sınıflandırılması

ISIC 2019 veri setindeki görüntüler eğitim, doğrulama ve test olmak üzere üç alt veri setine ayrılmıştır. Ayrılan görüntüler hesaplama karmaşıklığını azaltmak için 224×224 boyutlarına yeniden ölçeklendirilmiştir. Eğitim ve doğrulama verilerini arttırmak için görüntüler yatay olarak çevrilmiştir. Oluşturulan modellerin optimizasyonu için ağırlık

azalma değeri 0.00000001 olan Adam algoritması kullanılmıştır ve öğrenme oranı 0.00001 olarak kabul edilmiştir. Girdi ile hedef arasındaki fark çapraz entropi kaybı hesaplanarak bulunmuştur ve veriler arasındaki dengesizliği ortadan kaldırmak için ters sınıf ağırlıklandırma işlemi yapılmıştır. EfficientNet-B7'nin yığın boyutu 8; CoAtNet-0, CoAtNet-1 ve ResNet-200'ün yığın boyutu ise 16 olarak seçilmiştir. Tüm modeller için devir sayısı 60 olarak belirlenmiştir. Çalışmada 5 katlı çapraz doğrulama kullanılmıştır, bu yüzden her bir model için 5 kere eğitim ve test işlemleri gerçekleşmiş ve nihai sonuç için ortalamaları alınmıştır.

Tablo 2.14. ResNet-200, EfficientNet-B7, CoAtNet-0 ve CoAtNet-1 sınıflandırma metrikleri sonuçları

Modeller	Doğruluk	Duyarlılık	Özgüllük	Dengeli Doğruluk
ResNet-200	%95.7	%77.3	%97.0	%87.2
EfficientNet-B7	%96.0	%79.0	%97.0	%88.0
CoAtNet-0	%96.6	%82.5	%97.8	%90.2
CoAtNet-1	%97.1	%83.3	%97.9	%90.6

ResNet-200, EfficientNet-B7, CoatNet-0 ve CoatNet-1 ağları için sınıflandırma sonuçları Tablo 14'te gösterilmiştir. Elde edilen sonuçlara göre, CoAtNet ağları deri lezyonu sınıflandırmasında diğer ağlarda yüksek sonuçlar veren CNN tabanlı ağlara göre daha yüksek başarı elde etmiştir. CoatNet-1'in doğruluk, duyarlılık, özgüllük ve dengeli doğruluk değerleri sırasıyla %97.1, %83.3, %97.9 ve %90.6 olarak hesaplanmıştır.

3.SONUÇLAR

Bu çalışmada ilk olarak, deri lezyonlarının k-NN tabanlı sınıflandırılması için şekil, renk ve doku özelliklerini öğrenen bir makine öğrenmesi yaklaşımı geliştirilmiştir. Elde edilen sonuçlara göre yöntemin melanom tanımda etkili olduğunu ancak nevus ve seboreik keratoz sınıfını tanımda başarılı olmadığını gözlemlenmiştir. Veri setinde bulunan sınıflar arasındaki dengesiz dağılım sebebiyle (483 melanom vs. 117 nevus ve seboreik keratoz), sınıflandırıcının sınıf ayrımı yapmada zayıf kaldığı düşünülmektedir. Ayrıca dermoskopi görüntülerindeki lezyon bölgesinin renk benzerliği sebebiyle arka plandan ayıramaması ve artefaktların olması gibi durumlarda aktif kontur modelinin başarısının düştüğü gözlemlenmiştir.

İkinci olarak, deri lezyon görüntülerinden şekil, renk ve doku özellikleri çıkartılarak görüntüler melanom ya da nevus ve seboreik keratoz olarak sınıflandırılmıştır. Sınıflandırma işlemleri k-en yakın komşuluk, destek vektör makineleri ve topluluk öğrenme yöntemlerinden dengelenmiş rastgele orman sınıflandırıcıları, kolay topluluk, RUSBoost ve dengelenmiş torbalama ile yapılmıştır. Elde edilen sonuçlara göre RUSBoost sınıflandırıcısı ile en yüksek %100 duyarlılık, %100 özgüllük, %100 doğruluk ve %100 dengeli doğruluk elde edilmiştir. Geleneksel makine öğrenmesi yaklaşımlarından olan k-NN ve destek vektör makinesi yöntemlerinin performansının %25 ile %52 değerleri arasında değiştiği gözlemlenmiştir. Buna karşın, topluluk öğrenmesi tabanlı yöntemlerini performansı %58-%100 arasında hesaplanmıştır. Bu sonuçlara göre topluluk öğrenmesi yöntemlerinin sınıflandırma performansı, geleneksel makine öğrenmesi yöntemlerinin performanslarına göre daha iyidir.

Üçüncü olarak, evrişimli sinir ağlarından ResNet-200 ve EfficientNet-B7 mimarileri ile evrişim ve öz dikkat mekanizmasının birleşimi olan CoAtNet-0 ve CoAtNet-1 mimarileri ile sınıflandırma performansları karşılaştırılmıştır. ISIC 2019 veri setinde eğitilen ve test edilen mimarilerden elde edilen sonuçlara göre, öz dikkat ve evrişimin birleşiminden oluşan CoAtNet mimarilerinin, evrişimli sinir ağı mimarilerine göre daha yüksek sınıflandırma doğruluğu elde ettiği görülmektedir.

Son çalışmada ise tamamen evrişimli sinir ağları topluluğu ile dermoskopi görüntülerinin segmentasyonu yapılmıştır. Önerilen model, ilk olarak herhangi bir ön veya son işlem adımına ihtiyaç duymadan FCN, U-Net, SegNet ve DeepLabv3+ kullanarak deri lezyonlarını deri ve lezyon olmak üzere iki bölüme ayırır. Elde edilen semantik bölütleme

sonuçlarına topluluk yöntemlerinden biri olan çoğunluk oylama uygulanarak nihai görüntü elde edilmiştir. Deri ve lezyon sınıfı arasındaki sınıf dengesizliğini çözmek için ters sınıf frekans ağırlıklandırması kullanılır. ISIC 2017 veri kümesine göre sonuçlar, önerilen topluluk yönteminin FCNN modellerine kıyasla daha yüksek veya rekabetçi sonuçlar elde ettiğini göstermektedir.



4.ÖNERİLER

Bu tez çalışmasında ISIC2017 ve ISIC2019 veri seti kullanılarak çeşitli algoritmalar kullanılarak çeşitli ön işlemler, sınıflandırma ve segmentasyon işlemleri yapılmıştır. Yapılan segmentasyon ve sınıflandırma işlemleri karşılaştırılarak başarıları incelenmiştir. Bu doğrultuda çalışmalarla ilgili şu öneriler ön plana çıkmıştır:

Önişlem aşamasında dermoskopi görüntülerinde bulunan artefaktları kaldırmak için daha iyi yöntemler geliştirilebilir. Bu sayede segmentasyon aşamasının başarıları artırılabilir.

Sınıflandırma için veri setinde bulunan sınıflar arasındaki dengesizlik ve segmentasyon için piksel bazlı sınıflandırmada deri ve lezyon sınıfları arasındaki dengesizlik sebebiyle bireysel sınıflandırma başarıları, topluluk sınıflandırma başarılarına göre düşük çıkmaktadır. Derin öğrenmede son mimariler olan öz-dikkat ağları ile topluluk yöntemleri kullanılarak sınıflandırma ve segmentasyon başarıları artırılabilir.

5.KAYNAKLAR

1. <https://www.losante.com.tr/Content/brosur/DS%C3%96%20Kanser%20Verileri%20Tablo%20%C3%87evirisi.pdf>, 06.05.2023
2. <https://www.cancer.org/content/dam/cancer-org/research/cancer-facts-and-statistics/annual-cancer-facts-and-figures/2023/2023-cancer-facts-and-figures.pdf>, 06.05.2023
3. <https://www.cdc.gov/cancer/skin/>, 06.05.2023
4. Vidya, M. ve Karki, M. V., Skin Cancer Detection using Machine Learning Techniques, 2020 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT), 2020, Bangalore, India, Bildiriler Kitabı, 1-5.
5. Celebi, M. E., Kingravi, H. A., Uddin, B., Iyatomi, H., Aslandogan, Y. A., Stoecker, W. V., ve Moss, R. H., A methodological approach to the classification of dermoscopy image, Computerized medical imaging and graphics : the official journal of the Computerized Medical Imaging Society, (2007) 362–373.
6. Chang, W. Y., Huang, A., Yang, C. Y., Lee, C. H., Chen, Y. C., Wu, T. Y., ve Chen, G. S., Computer-aided diagnosis of skin lesions using conventional digital photography: a reliability and feasibility study, PloS one, 8(11) (2013).
7. Daghrir, J., Tlig, L., Bouchouicha, M. Ve Sayadi, M., Melanoma skin cancer detection using deep learning and classical machine learning techniques: A hybrid approach, 2020 5th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP), 2020, Sousse, Tunisia, Bildiriler Kitabı 1-5.
8. Serener, A. ve Serte, S., “Keratinocyte carcinoma detection via Convolutional neural networks, 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), 2019, Bildiriler Kitabı 1–5.
9. Steppan, J. ve Hanke, S., Analysis of skin lesion images with deep learning, arXiv preprint arXiv:2101.03814, (2021).
10. Jaisakthi, S.M., Aravindan, C., ve Mirunalini, P., Automatic Skin Lesion Segmentation using Semi-supervised Learning Technique, ArXiv, abs/1703.04301, (2017).
11. Li, Y. ve Shen, L., Skin lesion analysis towards melanoma Detection using deep learning network, Sensors, (2018) 556.
12. Yuan, Y., Automatic skin lesion segmentation with fully Convolutional deconvolutional networks, arXiv preprint arXiv:1703.05165, (2017).

13. Chen, P., Huang, S. ve Yue, Q., Skin Lesion Segmentation Using Recurrent Attentional Convolutional Networks, IEEE Access, (2022) 94007-94018.
14. Goyal, M., ve Yap, M., Multi-class Semantic Segmentation of Skin Lesions via Fully Convolutional Networks, Bioinformatics, (2017)
15. Zafar, K., Gilani, S.O., Waris, A., Ahmed, A., Jamil, M., Khan, M.N., Kashif, A.S., Skin Lesion Segmentation from Dermoscopic Images Using Convolutional Neural Network, Sensors , (2020) 1601.
16. Akyel, C., Arıcı, N., LinkNet-B7: Noise Removal and Lesion Segmentation in Images of Skin Cancer, Mathematics, (2022) 736.
17. Nawaz, M., Nazir, T., Masood, M., Ali, F., Khan, M.A., Tariq, U., Sahar, N. ve Damaševičius, R., Melanoma segmentation: A framework of improved DenseNet77 and UNET convolutional neural network, International Journal of Imaging Systems Technology, (2022) 2137- 2153.
18. https://acikders.ankara.edu.tr/pluginfile.php/68064/mod_resource/content/0/Derinin%20yap%C4%B1s%C4%B1%20fonksiyonlar%C4%B1.pdf, 06.05.2023
19. Maranduca M.A., Branisteanu, D., Serban D.N., Branisteanu D.C., Stoleriu, G., Manolache, N., Serban, I.L., Synthesis and physiological implications of melanic pigments, Oncol Lett, (2019) 4183-4187.
20. Someya, T. ve Amagai, M., Toward a new generation of smart skins. Nat Biotechnol., (2019) 382-388.
21. <https://challenge.isic-archive.com/landing/2019/>, 06.05.2023.
22. Çoşkun, K.B. ve Çobanoğlu, B., Bazal Hücreli Karsinoma ve Skuamoz Hücreli Karsinomanın Histokimyasal Özelliklerinin Bax, Bcl-2 ve Ki-67 ile Belirlenmesi, TÜRKDERM, (2005).
23. Coit, D. G., Andtbacka, R., Bichakjian, C. K., Dilawari, R. A., DiMaio, D., Guild, V., Halpern, A. C., Hodi, F. S., Kashani-Sabet, M., Lange, J. R., Lind, A., Martin, L., Martini, M. C., Pruitt, S. K., Ross, M. I., Sener, S. F., Swetter, S. M., Tanabe, K. K., Thompson, J. A., Trisal, V., Urist, M. M., Weber, J. ve Wong, M. K., Melanoma, Journal of the National Comprehensive Cancer Network, (2009) 250-275.
24. Yavuz, G.Ö. ve Yavuz, İ.H., Melanositik Nevusler, Van Tıp Dergisi, (2014), 259-268
25. Karaarslan, I., Aktinik Keratoz, Bowen Hastalığı ve Skuamöz Hücreli Karsinomlarda Dermoskopi, Turk J Dermatol, (2016), 27-32.

26. Hafner, C. Ve Vogt, T., Seborrheic keratosis, JDDG: Journal der Deutschen Dermatologischen Gesellschaft, (2008) 664-677.
27. Myers, D. J. ve Fillman, E. P., Dermatofibroma, StatPearls Publishing, (2022).
28. Oakley, A., Dermofibroma, <https://dermnetnz.org/topics/dermatofibroma>, 06.05.2023
29. Bucak, A., Ulu, Ş., Gönül, Y. ve Ayçiçek A., Baş-Boyun Bölgesi Vasküler Lezyonları. ODÜ Tıp Dergisi, (2015).
30. Senturk, N., Vasküler Lezyonlarda Lazer, Turkderm, (2012), 15-22.
31. <https://www.mayoclinic.org/diseases-conditions/skin-cancer/symptoms-causes/syc-20377605>, 06.05.2023.
32. <https://www.hakanbuzoglu.com/benlerin-kisisel-muayenesi-ve-takibi/194-dermatoloji/benlerin-degerlendirilmesi-ve-ben-takibi/1387-dermoskopi>, 06.05.2023.
33. <https://www.buyukanadoluhastanesi.com/haber/1557/yapay-zeka-ile-dijital-dermatoskopi>, 06.05.2023.
34. https://hsgm.saglik.gov.tr/depo/birimler/kanser-db/istatistik/Turkiye_Kanser_Istatistikleri_2017_OZETLI.pdf, 06.05.2023.
35. <https://www.iarc.who.int/cancer-type/skin-cancer/>, 06.05.2023.
36. [https://www.who.int/news-room/questions-and-answers/item/radiation-ultraviolet-\(uv\)-radiation-and-skin-cancer#:~:text=Currently%2C%20between%20%20and%203,skin%20cancer%20in%20their%20lifetime](https://www.who.int/news-room/questions-and-answers/item/radiation-ultraviolet-(uv)-radiation-and-skin-cancer#:~:text=Currently%2C%20between%20%20and%203,skin%20cancer%20in%20their%20lifetime), 07.05.2023.
37. https://www.tutorialspoint.com/opencv_python/opencv_python_resize_rotate_image.htm, 06.05.2023.
38. Lee, T., Ng, V., Gallagher, R., Coldman, A. ve McLean, D. DullRazor: a software approach to hair removal from images. Computers in biology and medicine, (1997) 533–543.
39. Kurniawan, A., Yuniarno, E.M., Setijadi, E., Alsagaff, M.Y. ve Purnama, I. K. E., Disease Classification based on Dermoscopic Skin Images Using Convolutional Neural Network in Teledermatology System, 2019 International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM), Surabaya, Indonesia, (2019) 1-5.

40. Ergün, E. ve Kılıç, K., Derin Öğrenme ile Artırılmış Görüntü Seti üzerinden Cilt Kanseri Tespiti . Black Sea Journal of Engineering and Science , (2021) 192-200.
41. Mohanaiah, P., Sathyanarayana, P., ve GuruKumar, L., Image texture feature extraction using GLCM approach. International journal of scientific and research publications, (2013) 1-5.
42. A. -R. H. Ali, J. Li ve G. Yang, Automating the ABCD Rule for Melanoma Detection: A Survey, IEEE Access, (2020) 83333-83346.
43. N. F. Lattoofi, Al-Sharuee, I.F., Kamil, M.Y., Obaid A.H., Mahidi, A.A., Omar, A.A. ve Saleh, A.K., Melanoma Skin Cancer Detection Based on ABCD Rule, 2019 First International Conference of Computer and Applied Sciences (CAS), Baghdad, Iraq, (2019) 154-157.
44. Walia, M., Semantic Segmentation vs. Instance Segmentation: Explained, <https://blog.roboflow.com/difference-semantic-segmentation-instance-segmentation/>, 06.05.2023.
45. N. Otsu, A Threshold Selection Method from Gray-Level Histograms, IEEE Transactions on Systems, Man, and Cybernetics,(1979) 62-66.
46. Acton, S.T., Diffusion Partial Differential Equations for Edge, The Essential Guide to Image Processing, (2009).
47. Long, J., Shelhamer, E., ve Darrell, T. Fully convolutional networks for semantic segmentation. Proceedings of the IEEE conference on computer vision and pattern recognition, (2015) 3431-3440.
48. Romero, D. W., Bruintjes, R. J., Tomczak, J. M., Bekkers, E. J., Hoogendoorn, M., Gemert, V. J. C., Flexconv: Continuous kernel convolutions with differentiable kernel sizes. arXiv preprint, (2021).
49. Zaniolo, L., ve Marques, O., On the use of variable stride in convolutional neural networks. Multimedia Tools and Applications, (2020), 13581-13598.
50. Naseri, H., ve Mehrdad, V., Novel CNN with investigation on accuracy by modifying stride, padding, kernel size and filter numbers, Multimedia Tools and Applications, (2023)1-19.
51. Pröve, P.L., An Introduction to different types of convolutions in deep learning, <https://towardsdatascience.com/types-of-convolutions-in-deep-learning-717013397f4d>, 06.05.2023.

52. Yadhav, S. Y., Senthilkumar, T., Jayanthi, S. ve Kovilpillai, J. J. A., Plant Disease Detection and Classification using CNN Model with Optimized Activation Function, 2020 International Conference on Electronics and Sustainable Communication Systems (ICESC), Coimbatore, India, (2020) 564-569.
53. Zafar, A., Aamir, M, Navi, N. M., Arshad, A., Riaz, S., Alruban, A., Dutta, A.K., Almotairi, S., A Comparison of Pooling Methods for Convolutional Neural Networks, Applied Sciences, (2022); 8643.
54. Dumoulin, V., ve Visin, F., A guide to convolution arithmetic for deep learning. arXiv preprint,(2016).
55. Drozdal, M., Vorontsov, E., Chartrand, G., Kadoury, S., ve Pal, C., The importance of skip connections in biomedical image segmentation, In International Workshop on Deep Learning in Medical Image Analysis, International Workshop on Large-Scale Annotation of Biomedical Data and Expert Label Synthesis, Cham, (2016) 179-187.
56. Long, J., Shelhamer, E., ve Darrell, T., Fully convolutional networks for semantic segmentation, Proceedings of the IEEE conference on computer vision and pattern recognition, (2015) 3431-3440.
57. Ronneberger, O., Fischer, P., & Brox, T., U-net: Convolutional networks for biomedical image segmentation. In Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, (2015), 234-241.
58. Badrinarayanan, V., Kendall, A., ve Cipolla, R., Segnet: A deep convolutional encoder-decoder architecture for image segmentation. IEEE transactions on pattern analysis and machine intelligence, (2017) 2481-2495.
59. Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., ve Adam, H., Encoder-decoder with atrous separable convolution for semantic image segmentation. In Proceedings of the European conference on computer vision (ECCV),(2018) 801-818
60. <https://hasty.ai/docs/mp-wiki/model-architectures/deeplabv3>, 06.05.2023
61. Chen, L. C., Papandreou, G., Schroff, F., ve Adam, H., Rethinking atrous convolution for semantic image segmentation, (2017).

62. A. Singh, N. Thakur ve A. Sharma, A review of supervised machine learning algorithms, 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), New Delhi, India, (2016) 1310-1315.
63. https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm#cite_note-1,06.05.2023.
64. Cortes, C. ve Vapnik, V., Support vector networks, Machine Learning, (1995) 1-25.
65. Y. Freund, ve R. Schapire, A Decision-Theoretic Generalization of on-Line Learning and an Application to Boosting, (1995).
66. J. Friedman, Greedy Function Approximation: A Gradient Boosting Machine, The Annals of Statistics, 2001.
67. Slocum, M., Decision making using id3 algorithm, Insight: River Academic J, 8(2).
68. Kavzoğlu, T. ve Çölkesen, İ. (2010). Karar Ağaçları İle Uydu Görüntülerinin Sınıflandırılması: . Harita Teknolojileri Elektronik Dergisi, 36-45 .
69. X. -Y. Liu, J. Wu ve Z. -H. Zhou, Exploratory Undersampling for Class-Imbalance Learning, IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2009, 539-550.
70. Seiffert, C., Khoshgoftaar, T. M., Van Hulse, J., ve Napolitano, A., RUSBoost: A hybrid approach to alleviating class imbalance, IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans, (2009) 185-197.
71. Breiman, L., Bagging predictors. Machine Learning, (2004) 123-140.
72. Breiman, L., Random Forests, Machine Learning, (2001) 5–32.
73. Chen, C., Using Random Forest to Learn Imbalanced Data,(2004).
74. <https://machinelearningmastery.com/bagging-and-random-forest-for-imbalanced-classification/>, 08.05.2003
75. Bello, I., Fedus, W., Du, X., Cubuk, E. D., Srinivas, A., Lin, T. Y. ve Zoph, B., Revisiting resnets: Improved training and scaling strategies, Advances in Neural Information Processing Systems, (2021),22614-22627.

76. Tan, M., ve Le, Q., Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning,(2019) 6105-6114.
77. Zhou, A., Ma, Y., Ji, W., Zong, M., Yang, P., Wu, M., ve Liu, M., Multi-head attention-based two-stream EfficientNet for action recognition, Multimedia Systems, (2023)487–498.
78. Hu, J., Shen, L., Albanie, S., Sun G. ve Wu E., Squeeze-and-Excitation Networks, 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (2017) 7132-7141.
79. Dai, Z., Liu, H., Le, Q. V. ve Tan, M., Coatnet: Marrying convolution and attention for all data sizes, Advances in Neural Information Processing Systems,(2021) 3965-3977.
80. Kingma, D. P. ve Ba, J., Adam: A method for stochastic optimization. arXiv preprint (2014).
81. <https://challenge.isic-archive.com/landing/2017/>

ÖZGEÇMİŞ

Elif KANCA, İlköğretim ve liseyi Sürmene’de tamamlamış olup 2020 yılında Karabük Üniversitesi Bilgisayar Mühendisliği Bölümünden onur öğrencisi olarak mezun olmuştur. Aynı yıl Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümünde yüksek lisans eğitimine başlamıştır. 2023 yılında Mühendislik Fakültesi Yazılım Mühendisliği bölümünde araştırma görevlisi olarak göreve başlamıştır.

Yayınlar

Kanca, E. ve Ayas, S., Learning Hand Crafted Features for K-NN based Skin Disease Classification, Human-Computer Interaction, Optimization and Robotic Applications (HORA 2022), Ankara, (2022) 1-4.

Kanca, E. ve Ayas, S., An Ensemble of Fully Convolutional Neural Networks for Automatic Skin Lesion Segmentation, Medical Technologies Congress (TIPTEKNO 2022), Antalya, (2022) 1-4.

Kanca, E. ve Ayas, S., Dengesiz Veri Kümelerinde Topluluk Yöntemlerine Dayalı Melanom Sınıflandırılması, Karadeniz Fen Bilimleri Dergisi, 12(2) 1127-1132.

Kanca, E. ve Ayas, S., Classification of Skin Lesions from Dermoscopic Images using CoAtNet, 10th International Conference on Advanced Technologies(ICAT’22), Van, (2022) 435-439.