

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR BİLİMİ VE MÜHENDİSLİĞİ BİLİM DALI

**MALİGN MELANOM VE NEVUS'UN MAKİNE ÖĞRENİMİ VE
DERİN ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Enver Ekrem UÇAR

İstanbul
Şubat-2021

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR BİLİMİ VE MÜHENDİSLİĞİ BİLİM DALI

**MALİGN MELANOM VE NEVUS'UN MAKİNE ÖĞRENİMİ VE
DERİN ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Enver Ekrem UÇAR

Tez Danışmanı
Doç. Dr. Farzad KIANI

İstanbul
Şubat-2021

Lisansüstü Eğitim Enstitüsü Müdürlüğüne,

Bu çalışma, jürimiz tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Bilimi ve Mühendisliği Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman Doç. Dr. Farzad KIANI

Üye Dr. Öğr. Üyesi Akhtar JAMIL

Üye Dr. Öğr. Üyesi Mohammed Ahmed SHAH

Onay

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Prof. Dr. Ali GÜNEŞ
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİMİ

Yüksek lisans tezi olarak hazırladığım “**MALİGN MELANOM VE NEVUS'UN MAKİNE ÖĞRENİMİ VE DERİN ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI**” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

Enver Ekrem UÇAR

ÖN SÖZ

Araştırmamdaki her aşamada bana yol gösteren değerli tez danışmanım Doç. Dr. Farzad Kiani'ye ve yüksek lisans eğitimim boyunca benden desteğini esirgemeyen sevgili eşim Dr. Ayşe Uçar'a teşekkürlerimi sunarım.

Enver Ekrem UÇAR

İstanbul-2021



ÖZET

MALİGN MELANOM VE NEVUS'UN MAKİNE ÖĞRENİMİ VE DERİN ÖĞRENME YÖNTEMLERİ İLE SINIFLANDIRILMASI

Enver Ekrem Uçar

Yüksek Lisans, Bilgisayar Mühendisliği

Tez danışmanı: Doç. Dr. Farzad Kiani

Şubat-2021, 152 Sayfa

Bu çalışmanın amacı makine öğrenmesi yöntemleri kullanarak malin melanom ve nevüs sınıflandırması yapılması ve bu işlem sırasında lezyon sınırlarına riayet edilmesinin işlem sonucuna yaptığı etkinin incelenmesidir. Araştırmanın temel aldığı kaynak, The International Skin Imaging Collaboration (ISIC) tarafından sağlanan cilt lezyonları veri kümesidir. Bu veri kümesi içerisinde lezyon sınırları bilgisini içeren ve Memorial Sloan Kettering Cancer Center (MSK) tarafından sağlanmış olan veri kümesi çalışmada tercih edilmektedir. Sınıflandırma işlemi için makine öğrenmesi yöntemlerinden Convolutional Neurel Network (CNN), Long Short-Term Memory (LSTM), Recurrent Neural Network (RNN), K Nearest Neighbours (KNN) ve Support Vector Machine (SVM) isimli yöntemler kullanılmaktadır. Veri kümesindeki her bir resim CNN, gri değeri eş dizilim matrisi ve ham resim piksel özniteliklerine göre ayrı ayrı ve gri değeri eş dizilim matrisi öznitelikleri ile CNN öznitelikleri birlikte olmak üzere önce kırılmadan sınıflandırılmış akabinde lezyon sınırlarına göre kırılarak sınıflandırılmıştır. Her bir özelliğe göre 10-kat çapraz doğrulama işlemi yapılmış ve sonuçlar, lezyon sınırlarına göre kırılmış ve kırılmamış olarak, doğruluk, f1-puanı, ortalama kesinlik, eğri altında kalan alan, ortalama doğruluk ve 10-kat doğrulama ortalamasından standart sapma değerinden oluşacak şekilde sunulmuştur. Bunlara ek olarak hata matrisi, alıcı çalışma karakteristiği eğrisi ve kesinlik duyarlılık eğrisi gibi yöntemler de dikkate alınarak sonuçlar değerlendirilmiştir. Bu çalışmanın sonucunda elde edilen model, Pedro Hispano Hospital (PH²) tarafından sağlanan veri kümesi üzerinde uygulanarak başarılı olduğu gösterilmiş ve ayrıca bu çalışmamız, bir web uygulaması olarak akademik kullanıma açılmıştır. Çalışma sonunda elde edilen model bu alanda çalışan akademisyenler ve uzman doktorlar için faydalı olacaktır.

Anahtar Kelimeler: Cilt Kanseri, Makine Öğrenmesi, Derin Öğrenme

ABSTRACT

CLASSIFICATION OF MALIGNANT MELANOMA AND NEVUS BY MACHINE LEARNING AND DEEP LEARNING METHODS

Enver Ekrem Uçar

Master, Computer Science

Thesis Advisor: Assoc. Prof. Dr. Farzad Kiani

February-2021, 152 Pages

The main purpose of this study is to classify malignant melanoma and nevus using machine learning and deep learning methods and to examine the effect of respecting lesion boundaries on the outcome of this procedure. The research is based on the skin lesion dataset provided by The International Skin Imaging Collaboration (ISIC). Memorial Sloan Kettering Cancer Center (MSK) dataset was selected for the research because it is the largest subset containing lesion boundaries information among ISIC dataset. Machine learning methods named Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), Recurrent Neural Network (RNN), K Nearest Neighbours (KNN) and Support Vector Machine (SVM) were utilized for classification. Lesion images were classified using CNN features, gray level co-occurrence matrix features, raw image pixel features and CNN features plus gray level co-occurrence matrix features using 10-fold cross-validation process, first as provided then using crop method respecting to lesion boundaries. The results were saved for each fold from which we extract the accuracy, the f1-value, the average precision, the area under the curve, the mean accuracy value and the standard deviation value of the 10-fold validation, In addition to these, the results were evaluated by considering the methods such as confusion matrix, receiver operating characteristic curve and precision recall curve. The model selected at the end of the study was applied on a test dataset provided by Pedro Hispano Hospital (PH²) showing that the model is successful and also made available on the internet as a web application for academic usage.

Key Words: Skin Cancer, Machine Learning, Deep Learning

İÇİNDEKİLER

TEZ ONAYI	i
BİLİMSEL ETİK BİLDİRİMİ.....	ii
ÖN SÖZ.....	iii
ÖZET.....	iv
ABSTRACT	v
İÇİNDEKİLER	vi
TABLolar LİSTESİ.....	ix
ŞEKİLLER LİSTESİ.....	xi
KISALTMALAR LİSTESİ.....	xxi
BİRİNCİ BÖLÜM	
GİRİŞ	1
1.1.Problem	1
1.2.Amaç	2
1.3.Araştırmanın Önemi.....	2
1.4.Özgün Değer	3
1.5.Varsayımlar	3
1.6.Sınırlılıklar	3
1.7.Sonuç.....	4
İKİNCİ BÖLÜM	
MELANOM CİLT KANSERİ	5
2.1.Cilt kanseri	5
2.2.Cilt kanserinin tanınmasında kullanılan dermoskopik yöntemler.....	7
2.3.Sonuç.....	9

ÜÇÜNCÜ BÖLÜM

MAKİNE ÖĞRENMESİ.....	10
3.1.Makine öğrenmesi çeşitleri	10
3.1.1.Gözetimli öğrenme	11
3.1.2.Gözetimsiz öğrenme	12
3.1.3.Pekiştirmeli öğrenme	12
3.1.4.Derin öğrenme	13
3.2.Makine öğrenmesi yöntemleri.....	13
3.2.1.Yapay sinir ağları (ANN)	14
3.2.2.Evrişimsel sinir ağları (CNN).....	17
3.2.3.Geri beslemeli sinir ağları (RNN).....	18
3.2.4.Uzun kısa süreli bellek (LSTM)	19
3.2.5.K-En yakın komşu (KNN).....	20
3.2.6.Destek vektör makinesi (SVM)	21
3.3.Bu çalışmada kullanılan öznitelikler	24
3.3.1.Evrişimsel sinir ağı öznitelikleri	24
3.3.2.Gri seviyesi eş dizilim matrisi (Haralick) öznitelikleri.....	24
3.3.3.Ham resim piksel öznitelikleri	27
3.4.Sonuç.....	27

DÖRDÜNCÜ BÖLÜM

LİTERATÜR ÇALIŞMASI	28
4.1.Önceki çalışmalar.....	28
4.2.Sonuç.....	39

BEŞİNCİ BÖLÜM

ARAŞTIRMA YÖNTEMİ.....	41
5.1.Amaç ve Model	41
5.2.Evren ve Örneklem	46
5.3.Veritoplama Araçları	47
5.4.Değerlendirme kriterleri.....	48
5.4.1.Hata Matrisi (Confusion Matrix)	48

5.4.2. Alıcı Çalışma Karakteristiği Eğrisi (Receiver Operating Characteristic Curve)	50
5.4.3. Kesinlik Duyarlılık Eğrisi (Precision Recall Curve)	51
5.5. Araçlar	52
5.6. Sonuç	54

ALTINCI BÖLÜM

ARAŞTIRMA BULGULARININ DEĞERLENDİRİLMESİ	56
6.1. Simülasyon ayarları ve parametreleri	56
6.2. Sınıflandırma sonuçları	60
6.2.1. InceptionV3 modelinden elde edilen özniteliklerin sınıflandırılması	60
6.2.2. VGG16 modelinden elde edilen özniteliklerin sınıflandırılması	68
6.2.3. Gri seviyesi eş dizilim matrisi özniteliklerinin sınıflandırılması	77
6.2.4. InceptionV3 modelinden elde edilen özniteliklerin gri değeri eş dizilim matrisi öznitelikleri ile birlikte sınıflandırılması	85
6.2.5. VGG16 modelinden elde edilen özniteliklerin gri değeri eş dizilim matrisi öznitelikleri ile birlikte sınıflandırılması	94
6.2.6. Resim piksel özniteliklerinin sınıflandırılması	103
6.2.7. Örnek model ile yapılan test sonucu	113
6.3. Sonuç	115

YEDİNCİ BÖLÜM

TARTIŞMA VE DEĞERLENDİRME	116
7.1. Genel Değerlendirme ve Tartışma	116

SEKİZİNCİ BÖLÜM

SONUÇ VE GELECEKTEKİ ÇALIŞMALAR	122
8.1. Araştırmanın sonucu	122
8.2. Gelecekteki yapılabilecek çalışmalar	122
KAYNAKÇA	124
ÖZGEÇMİŞ	131

TABLolar LİSTESİ

Tablo 2.1: Lezyon örnekleri tablosu	7
Tablo 5.1: Lezyon sınırları maskesi ve kırpma işlemi	46
Tablo 5.4: Hata matrisini açıklayıcı tablo	48
Tablo 6.2.1.1: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçları	61
Tablo 6.2.1.2: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçları	61
Tablo 6.2.2.1: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçları.....	69
Tablo 6.2.2.2: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçları.....	69
Tablo 6.2.3.1: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçları.....	78
Tablo 6.2.3.2: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçları.....	78
Tablo 6.2.4.1: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçları.....	87
Tablo 6.2.4.2: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçları.....	87
Tablo 6.2.5.1: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçları.....	95

Tablo 6.2.5.2: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçları..... 95

Tablo 6.2.6.1: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçları 104

Tablo 6.2.6.2: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçları 104



ŞEKİLLER LİSTESİ

İKİNCİ BÖLÜM

Şekil 2.1: Derinin yatay kesiti	6
Şekil 2.2: Cilt kanseri tanıma yöntemlerinin gösterimi	8

ÜÇÜNCÜ BÖLÜM

Şekil 3.1: Gözetimli öğrenme diyagramı	12
Şekil 3.2: Biyolojik Sinir Hücresi	15
Şekil 3.3: Rosenblatt'ın perceptron'u	16
Şekil 3.4: Örnek sinir ağı	17
Şekil 3.5: Hochreiter ve Schmidhuber makalesinde bir uzun kısa süreli bellek hücresinin gösterimi	20
Şekil 3.6: SVM'in en geniş boşluk ve destek vektörleri	22
Şekil 3.7: SVM'de çekirdek fonksiyonunun işlevi	22
Şekil 3.8: InceptionV3 mimarisinde sınıflandırıcı ve öznitelik çıkarıcı katmanların gösterimi	24

DÖRDÜNCÜ BÖLÜM

Şekil 4.1: Brinker ve arkadaşlarının incelediği çalışmalardan bir kısmının kullandıkları yönteme göre şema üzerinde gösterimi	39
---	----

BEŞİNCİ BÖLÜM

Şekil 5.1 Çalışmanın akış diyagramı.....	44
Şekil 5.2: ISIC galeri sayfasının ekran görüntüsü.....	47
Şekil 5.3: Örnek hata matrisi.....	49
Şekil 5.4: Örnek alıcı çalışma karakteristiği eğrisi ve eğri altında kalan alan	51
Şekil 5.5: Örnek kesinlik duyarlılık eğrisi ve ortalama kesinlik.....	52

ALTINCI BÖLÜM

Şekil 6.1: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri.....	61
Şekil 6.2: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri.	62
Şekil 6.3: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	62
Şekil 6.4: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri ...	63
Şekil 6.5: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model eğitim kayıp eğrileri	63
Şekil 6.6: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model sağlama kayıp eğrileri.....	64
Şekil 6.7: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının hata matrisleri.....	64
Şekil 6.8: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri.....	65

Şekil 6.9: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri .	65
Şekil 6.10: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	66
Şekil 6.11: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri ...	66
Şekil 6.12: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model eğitim kayıp eğrileri.....	67
Şekil 6.13: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model sağlama kayıp eğrileri.....	67
Şekil 6.14: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının hata matrisleri.....	68
Şekil 6.15: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri.....	70
Şekil 6.16: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri .	70
Şekil 6.17: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	71
Şekil 6.18: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri ...	71
Şekil 6.19: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model eğitim kayıp eğrileri.....	72
Şekil 6.20: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model sağlama kayıp eğrileri.....	72
Şekil 6.21: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının hata matrisleri.....	73

Şekil 6.22: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri.....	73
Şekil 6.23: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri.....	74
Şekil 6.24: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	74
Şekil 6.25: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri	75
Şekil 6.26: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model eğitim kayıp eğrileri.....	75
Şekil 6.27: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model sağlama kayıp eğrileri.....	76
Şekil 6.28: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının hata matrisleri	76
Şekil 6.29: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri	78
Şekil 6.30: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri	79
Şekil 6.31: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	79
Şekil 6.32: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri	80

Şekil 6.33: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model eğitim kayıp eğrileri	80
Şekil 6.34: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri	81
Şekil 6.35: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının hata matrisleri	81
Şekil 6.36: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri	82
Şekil 6.37: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri	82
Şekil 6.38: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	83
Şekil 6.39: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri	83
Şekil 6.40: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model eğitim kayıp eğrileri	84
Şekil 6.41: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri	84
Şekil 6.42: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının hata matrisleri	85

Şekil 6.43: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri.....	87
Şekil 6.44: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri.....	88
Şekil 6.45: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	88
Şekil 6.46: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama doğruluk eğrileri.....	89
Şekil 6.47: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim kayıp eğrileri	89
Şekil 6.48: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama kayıp eğrileri	90
Şekil 6.49: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının hata matrisleri.....	90
Şekil 6.50: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri.....	91
Şekil 6.51: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri.....	91

Şekil 6.52: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	92
Şekil 6.53: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama doğruluk eğrileri.....	92
Şekil 6.54: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim kayıp eğrileri	93
Şekil 6.55: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama kayıp eğrileri	93
Şekil 6.56: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının hata matrisleri.....	94
Şekil 6.57: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri.....	96
Şekil 6.58: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri.....	96
Şekil 6.59: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	97
Şekil 6.60: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama doğruluk eğrileri.....	97

Şekil 6.61: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim kayıp eğrileri	98
Şekil 6.62: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama kayıp eğrileri	98
Şekil 6.63: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının hata matrisleri.....	99
Şekil 6.64: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri	100
Şekil 6.65: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri	100
Şekil 6.66: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim doğruluk eğrileri.....	100
Şekil 6.67: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama doğruluk eğrileri.....	101
Şekil 6.68: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim kayıp eğrileri	101
Şekil 6.69: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama kayıp eğrileri	102

Şekil 6.70: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının hata matrisleri	102
Şekil 6.71: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri	105
Şekil 6.72: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri	105
Şekil 6.73: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	106
Şekil 6.74: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri	106
Şekil 6.75: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model eğitim kayıp eğrileri.....	107
Şekil 6.76: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri.....	107
Şekil 6.77: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının hata matrisleri	108
Şekil 6.78: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri	109
Şekil 6.79: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri	109
Şekil 6.80: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri	110
Şekil 6.81: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri	110
Şekil 6.82: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model eğitim kayıp eğrileri.....	111

Şekil 6.83: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri (InceptionV3 Fine Tune).....	111
Şekil 6.84: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri (Diğerleri)	112
Şekil 6.85: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının hata matrisleri	113
Şekil 6.86: Örnek model ile yapılan test sonucunun kesinlik duyarlılık eğrisi.....	114
Şekil 6.87: Örnek model ile yapılan test sonucunun alıcı çalışma karakteristiği eğrisi	114
Şekil 6.88: Örnek model ile yapılan test sonucunun hata matrisi	114

KISALTMALAR LİSTESİ

- ANN : (Artificial Neural Network) Yapay sinir ađı
- AP : (Average Precision) Ortalama Kesinlik
- AUC : (Area Under the Curve) Eğri Altında Kalan Alan
- CNN : (Convolutional Neural Network) Evrişimsel sinir ađı
- FN : (False Negative) Yanlış Negatif
- FP : (False Positive) Yanlış Pozitif
- ISIC : The International Skin Imaging Collaboration
- KNN : (K-Nearest Neighbors) K-En yakın komşu
- LSTM : (Long Short-Term Memory) Uzun kısa süreli bellek
- MSK : Memorial Sloan Kettering Cancer Center
- PRC : (Precision Recall Curve) Kesinlik Duyarlılık Eğrisi
- RNN : (Recurrent Neural Network) Tekrarlayan Sinir Ađı
- ROC : (Receiver Operating Characteristic Curve) Alıcı Çalışma Karakteristiđi Eğrisi
- SVM : (Support Vector Machine) Destek vektör makinesi
- TN : (True Negative) Doğru Negatif
- TP : (True Positive) Doğru Pozitif
- vd : ve diđerleri

BİRİNCİ BÖLÜM

GİRİŞ

Son yıllarda makine öğrenmesi yöntemleri dikkat çekici ilerleme kaydetmiş ve birçok alanda kendine yer bularak kullanılmaya başlamışlardır. Son yıllardaki artış 2009 yılında derin öğrenmenin bazı diğer teknikleri geride bırakacak sonuçlar elde etmesiyle başlamıştır (Lundervold ve Lundervold, 2019). Medikal görüntüleme alanında daha erken, daha doğru ve daha hızlı teşhis için doktorlara yol göstermesi amacıyla makine öğrenmesi ve derin öğrenme teknikleri ile sınıflandırma çalışmalarında da ilerleme kaydedilmiştir. Bu çalışmaların bir kısmı geleneksel teşhis yöntemlerini taklit etmeye ve renk, şekil, doku özelliklerini veya bunların kombinasyonlarını tanımaya odaklanmışlardır. Dolayısıyla belli bir sorun özelinde çözüme odaklandıkları için de daha genel bir problem çözme kabiliyetinden ve genelleştirilebilir bir model ortaya koymak imkanından yoksun kalırlar. Çalışmaların bir diğer kısmı ise resimlerin ham piksellerinden etiket tahmininde bulunmak için etkin bir yöntem olan derin öğrenmeyi kullanmışlardır. Fakat derin öğrenme sistemlerini kullanmak da küçük veri kümeleri ve yüksek çözünürlüklü resimler ile başa çıkmayı gerektirmekte ve yüksek hesaplama gücü ihtiyacını ortaya çıkarmaktadır (Lai ve Deng, 2018). Bu çalışmada resmin ham piksellerinin yanı sıra evrişimsel sinir ağı öznelikleri ve yine resimden elde edilen fakat derin öğrenme sistemlerinin kendiliğinden elde edemediği gri değeri eş dizilim matrisi de öznelik olarak sinir ağları ve diğer klasik sınıflandırıcılar ile sınıflandırmaya tabi tutulmuştur. Bunlara ek olarak gri değeri eş dizilim matrisi öznelikleri ile evrişimsel sinir ağı öznelikleri birlikte sınıflandırılmaya tabi tutulmuştur. Bu işlemler lezyon resimlerinin ham halinden elde edilen özneliklerle yapıldığı gibi lezyonun uzman doktorlar tarafından belirlenmiş sınırlarına göre kırılması ile elde edilen haliyle de tekrarlanmıştır. Her sınıflandırma işlemi 10 kat çapraz doğrulama ile tamamlanmış ve ilgili sınıflandırıcı için en yüksek doğruluk değeri not edilmiştir.

1.1.Problem

Cilt kanseri erken safhada teşhis edilmediği takdirde ölümcül sonuçları olan ciddi bir rahatsızlıktır. Cildiye uzmanları cilt kanserini yüksek oranda tespit etmektedirler fakat gözden kaçırdıkları durumlar da olabilmektedir. Birçok ülkede cildiye uzmanı

eksikliği bulunmakla beraber ayrıca bir cildiye uzmanının ortalamanın üstünde performans gösterebilmesi için uzun zaman gerekmektedir. Yani teşhis oranı doktorun tecrübesine göre farklılık göstermektedir. Bu çalışmada dermoskopik resimler kullanılarak cilt kanserini tanımak amacıyla makine öğrenmesi tekniklerinden faydalanılmış ve elde edilen sonuçlar karşılaştırılmıştır.

1.2.Amaç

Melanom gayet ölümcül bir kanser türü olduğundan cilt doktorlarının günlük çalışmalarında herhangi bir teşhisi gözden kaçırmalarına engel olmak ve teşhis oranını yükseltecek bir çalışma ortaya koymak hayat kurtarıcı olacaktır. Ayrıca cilt doktorlarına erişimin kısıtlı olduğu yerlerde melanom teşhisi için kullanılacak faydalı bir model yine birçok hayatı kurtarabilir. Yine cilt doktorlarının eğitimi uzun sürdüğünden ve melanomu yüksek oranda teşhis etme kabiliyetine sahip olmak zaman aldığından tecrübesiz doktorların hata oranını düşürmekte kullanılacak bir model ortaya koymak da önem arz etmektedir. Bu çalışmanın amacı cilt kanseri teşhisi için makine öğrenmesi tekniklerini kullanarak benin ve malin cilt lezyonlarını birbirinden ayırarak melanom teşhisinde cilt doktorlarına yardımcı olacak bir model geliştirmek ve bunu yaparken ilgili resimlerin lezyon sınırlarına göre kırılması ve kırılmaması arasında bir fark olup olmadığını tespit etmektir. Lezyon sınırlarına dikkat edilmesinin etkisini incelemekten maksat ise makine öğrenmesi modellerinin çok sayıda girdi ile çalışması beklendiğinden ve lezyon sınırlarını tespit etmenin ayrıca bir maliyeti olduğundan bu maliyete katlanmaya gerçekten ihtiyaç var mıdır ya da hangi model için bu maliyete katlanmak gerekli hangi model için gereksizdir gibi sorulara cevap bulmaya çalışmaktır. Bunlara ek olarak çalışmamızın bir amacı da tecrübe bakımından daha geride olan doktorlara yol göstermek, sağlık kurumlarına erişimin kısıtlı olduğu yerlerde erken teşhis sağlamak ve cilt kanserinin daha hızlı daha doğru tanınması için doktorlara ve hastalara yardımcı olabilmek için bir model geliştirmektir.

1.3.Araştırmanın Önemi

Melanom cilt kanseri dünyada her yıl binlerce hayat almaktadır. Melanom cilt kanserinin erken teşhis edilmesi, tedavinin başarılı olması açısından büyük önem arz etmektedir. Son yıllarda makine öğrenmesindeki ve teknolojiye erişimdeki hızlı

ilerleme medikal tanılama sistemlerinde bu ikisinin bir arada kullanılması ile ilgili çalışmaları da hızlandırmıştır. Bu çalışmalar daha erken ve daha doğru teşhisi de mümkün kılacak seviyeye ulaşmış bulunmaktadır. Bazı çalışmalarda melanom teşhisinde makine öğrenmesinin doktorlardan daha doğru neticeler elde ettiği gösterilmiştir. Bu açıdan bakıldığında gelecekte genel olarak medikal görüntüleme ve teşhis açısından ülkemizin dünyadan geride kalmaması için benzeri çalışmaların yapılması gerekliliği de görülmektedir. Doktorlara yardımcı olacak karar destek modellerinin geliştirilmesi hayat kurtarıcı olabileceğinden çalışmamız bir kat daha önem kazanmaktadır. Ayrıca medikal görüntüleme araçlarından elde edilen görüntülerin ön işleme aşamasından geçirilmesinin gerekliliğinin araştırılması da bir açıdan bu alanda çalışacak olan diğer insanların işlerini kolaylaştıracaktır.

1.4.Özgün Değer

Cilt lezyonlarının tanınmasında lezyon resimlerinin lezyon sınırlarına göre kırılarak sınıflandırılması ile kırılmadan sınıflandırılması arasındaki farkın öznel çeşitleri bazında ve makine öğrenmesi algoritması bazında sistemli olarak karşılaştırılması çalışmamızın öne çıkan özelliğidir. Çalışmamızda bir yandan en iyi sınıflandırma sonucuna ulaşmaya çalışırken diğer yandan kırma işleminin etkisi her zaman göz önünde bulundurulmakta ve değerlendirilmektedir.

1.5.Varsayımlar

Bu çalışmada ISIC veri kümesinden elde edilen verilerin ve ilgili etiketlerinin doğru olduğu varsayılmaktadır. ISIC kümesindeki veriler çeşitli hastanelerden elde edilmiş ve veriler ilgili çalışmaya katılan uzman doktorlar tarafından etiketlenmiştir.

1.6.Sınırlılıklar

Çalışma ISIC veri kümesinin lezyon sınırları belirlenmiş ve en az meyilli olan MSK isimli alt kümesi ile sınırlıdır.

1.7.Sonuç

Bu bölümde çalışmanın elimizdeki problemi ve çözümüne dair ortaya koyacağımız çalışmanın amacını ve önemini açıklamaya çalıştık. Bir sonraki bölümde çalışmaya temel teşkil eden sorun olan cilt kanserini anlatacağız.




İKİNCİ BÖLÜM

MELANOM CİLT KANSERİ

Bu bölümde cildin yapısı, kanser, cilt kanserlerinin çeşitleri, cilt kanserinin kaynağı, cilt kanserinin teşhis edilmesi için doktorların kullandığı genel geçer yöntemler açıklanacaktır. Cilt kanserini ve doktorların kullandığı yöntemleri tanımak, doktorların teşhis koyarken hangi kriterleri göz önünde bulundurduğunu anlamakta bize yardımcı olacaktır. Bu yöntemler dünya çapında kabul görmüş ve kullanılmaktadır. Cilt doktorları, uzun yıllar eğitim alarak aşağıda yer alan görsel özellikleri teşhis etmekte uzmanlaşırlar. Bu özelliklerin tespit edilerek literatürde yer alması uzun zaman almıştır. Bununla birlikte bu özelliklerin tespit edilmesi cilt kanseri teşhisinin otomatikleştirilmesi için bir kapı aralamıştır. ABCD (Asymmetry, Border, Color, Differential structure) kuralı, Menzies kuralı, 7 Nokta kontrolü ve 3 Nokta kontrolü olarak isimlendirilen kurallar literatürde en çok yer tutan kurallardır.

2.1.Cilt kanseri

Kanser, vücudun herhangi bir yerinde anormal hücrelerin kontrolsüz büyümesidir. Bu anormal hücrelere kanser hücreleri, kötü huylu hücreler veya tümör hücreleri denir. Bu hücreler normal vücut dokularına sıçrayabilir. Yüzden fazla kanser çeşidi vardır ve birçok kanser ve tümör, anormal hücrelerin kaynaklandığı organın veya dokunun adıyla tanımlanır (örneğin cilt kanseri, akciğer kanseri ve gırtlak kanseri). Hasar görmüş veya onarılmamış hücreler ölmediğinde ve kanser hücreleri haline geldiğinde, kontrolsüz bölünme ve büyüme gösterdiğinde bir yığın kanser hücresi gelişir. Sıklıkla, kanser hücreleri bu orijinal hücre kütesinden kopabilir, kan ve lenf sistemlerinde dolaşabilir ve kontrolsüz büyüme döngüsünü tekrarlayabilecekleri başka organlara yerleşebilirler. Bir bölgeden ayrılan ve başka bir vücut bölgesinde büyüyen kanser hücrelerinin bu süreci, metastatik yayılma veya metastaz olarak adlandırılır (Kumari ve Kaushik, 2018).



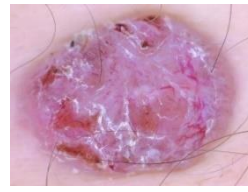
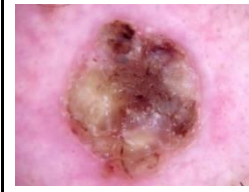


Şekil 2.1: Derinin yatay kesiti

Kaynak: (krebsliga.ch, 2010)

Cilt kanserleri de insan derisinin içindeki köken aldıkları hücreye göre sınıflandırılırlar. Sıklıkla derinin **Şekil 2.1**'de gösterilen en üst tabaka bileşenlerinden bazal hücre (keratinosit) ve pigment hücresi (melanosit) kaynaklı olurlar. Bazen de başka hücrelerden kaynaklı olarak ortaya çıkabilirler (Fitzpatrick ve Aeling, 2000: 313). Cilt kanserleri melanom ve melanom dışı olmak üzere iki ana başlıkta sınıflandırılır. Melanom dışı cilt kanserleri 'basal cell carcinoma' ve 'squamous cell carcinoma' olarak iki alt başlıkta değerlendirilir. Dünya sağlık örgütü verilerine göre melanom ve melanom dışı cilt kanseri vakaları geçen yıllar içerisinde artış göstermektedir. Her yıl 2 ila 3 milyon non-melanom 132000 kadar da melanom cilt kanseri vakası görülmektedir. Teşhis edilen her üç kanserden biri cilt kanseridir (who.int, 2020). En sık görülen cilt kanseri bazal hücreli karsinom ve skuamöz hücreli karsinom olmasına karşın melanom en agresif ve en ölümcül olanıdır. Nevüs, melanom ve karsinom lezyon örnekleri **Tablo 2.1**'de verilmektedir. Cilt kanserinin erken teşhis edilmesi hayati öneme sahiptir. Cildinde atipik nevüs varlığı bulunanların uzman hekimler tarafından aralıklı olarak izlenmesi, dermoskop veya diğer görüntüleme teknikleri ile tüm vücut deri muayenesinin yapılması ile melanomun erken evrelerde teşhis edilmesi ve tedavisi mümkün olabilir (Acer ve Erdoğan, 2019). Cilt kanserlerine eksizyon, basamaklı cerrahi veya medikal uygulamalarla müdahale edilerek tedavisi amaçlanır (Uçar, vd., 2018).

Tablo 2.1: Lezyon örnekleri tablosu

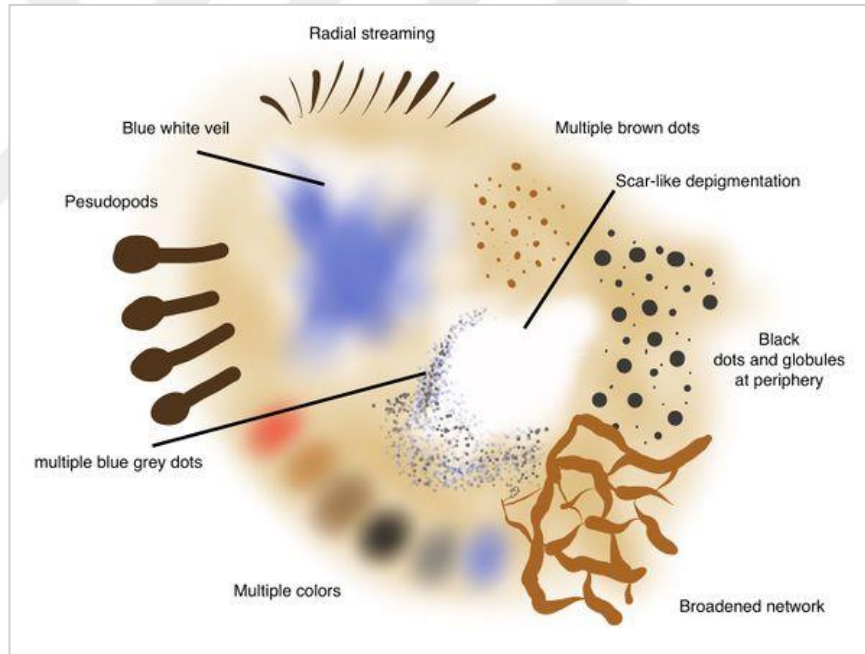
			
Nevus	Malignant Melanoma	Basal Cell Carcinoma	Squamous Cell Carcinoma

Her ne kadar kesin teşhis biyopsi sonuçlarına dayandırılarak elde edilse de hastanın biyopsi yaptırmasına ya da yaptırmamasına uzman doktorlar çıplak gözle ya da dermoskop ile bakarak karar vermekte olduğundan cilt kanseri teşhisinde hasta olan fakat sağlıklı zannedilerek biyopsi istenmeyen örneklerin sayısını azaltmak hayati önem arz etmektedir. Bunun için yıllar içerisinde bazı yöntemler geliştirilmiştir.

2.2.Cilt kanserinin tanınmasında kullanılan dermoskopik yöntemler

Stolz ve arkadaşları 1994 yılında melanositik cilt lezyonlarının tanımlanması amacıyla ABCD kuralını önermişlerdir (Stolz, Reimann ve Cognetta: 1994). Nachbar ve arkadaşlarının çalışmasında bu yöntemin melanom tanınmasında hassasiyeti %92.8, özgüllüğü %91.2 olarak ölçülmüştür. ABCD kuralına göre A : Melanom lezyonları düzensiz şekilde olurlar, B : Melanom lezyonlarının kenarları düzensiz olur, C : Melanom lezyonları genellikle birden fazla renkte olur ve D : Melanom lezyonlarının çapı genellikle büyük olur (Nachbar, vd., 1994). Menzies ve arkadaşları tarafından 1996 yılında önerilen sisteme göre negatif özellikler olduğu gibi pozitif özellikler de bulunmaktadır. Lezyonda simetrik örüntü ve tek renk bulunması negatif özellik olarak adlandırılmakta ve lezyonun selim olduğuna işaret etmektedir. Üzerinde beyaz 'perde' bulunan düzensiz ve birbirine karışan mavi pigmentasyon, bir alanda yoğunlaşmış çok sayıda koyu kahverengi noktalar, lezyonun ana kütesinden deriye doğru uzanan doğrusal veya ampul şeklinde uzantılar, lezyonun ana kütesinden deriye doğru uzanan ışınsal uzantılar, tamamen beyaz renkte iyileşmiş yara görünümlü düzensiz depigmentasyon, birden fazla (beş, altı) renk, serpilmiş karabiber görünümlü birden fazla mavi-gri noktalar, lezyon kenarında siyah noktalar, yayılmış ağ görünümü lezyonun habis olduğuna işaret eden pozitif özelliklerdir (Menzies, vd., 1996).

Argenziano ve arkadaşları tarafından 1998 yılında önerilen 7 nokta kontrolü yöntemi %95 hassasiyet ve %75 özgüllük oranına sahiptir. Bu sisteme göre belirgin ve yaygın pigmentli ağ yapısında görüntü; düzensiz, girişken, gri-mavi ila beyazımsı mavi dağınık kırmızı-mavi boşluklar ile ilişkili olmayan pigmentasyon veya akçaağaç yaprağı pigmentasyonu; lezyon dışına yakın dağılmış ve diğer melanositik pigment desenleri ile ilişkili düzensiz doğrusal, noktalı veya küresel kırmızı yapılar; lezyonun kenarında radyal ve asimetrik olarak bulunan doğrusal veya ampul benzeri uzantılar; düzensiz şekil veya dağılımlı ve aniden biten kahverengi, gri ve siyah pigmentasyon; lezyon içerisinde dağılmış düzensiz siyah, kahverengi veya mavi yuvarlak yapılar; lezyon içinde düzensiz olarak dağılmış beyaz yara benzeri depigmentasyon ve serpilmiş karabiber görünümü 7 noktayı oluşturmaktadır. Lezyonlar bu özellikleri barındırıp barındırmadığına göre bir puanlama sistemi ile değerlendirilir (Argenziano, vd., 1998).



Şekil 2.2: Cilt kanseri tanıma yöntemlerinin gösterimi

Kaynak: (dermoscopia.org, 2020)

2003 yılında internet üzerinden yapılan ‘Consensus Net Meeting on Dermoscopy’ çalışması kapsamında oluşturulmuş olan 3 nokta kontrolü yöntemi 2004 yılında Soyer ve arkadaşları tarafından bir çalışma ile ele alınmış ve uzman olmayanlar tarafından kullanıldığında dahi %96.3 hassasiyetle tanı konulabildiği gösterilmiştir (Argenziano,

ve diğeri, 2003). Bu yöntemle göre lezyonda bulunan renklerin ve diğeri yapıların asimetrik dağılımı; lezyonda pigmentli ağ yapısı, düzensiz boşluklar ve kalın çizgiler bulunması; lezyonda herhangi bir şekilde mavi veya beyaz renk bulunması pozitif tanıya işaret etmektedir (Soyer, vd, 2004).

Bu bölümde konusu geçen çalışmalarda kullanılan bazı özellikler **Şekil 2.2**'de gösterilmiştir. Kullanılan terminolojinin Özdemir ve arkadaşlarının “Dermoskopik Terminolojinin Dilimize Uyarlanması: Türk Dermatoloji Derneği Dermoskopi Çalışma Grubu Uzlaşısı” başlıklı çalışmasına uygun olmasına çalışılmıştır (Özdemir, vd, 2013).

2.3.Sonuç

Bu bölümde cilt kanserini tanıtmaya ve ne kadar ölümcül bir hastalık olduğunu açıklamaya çalıştık. Cilt kanserinin doktorlardan tarafından teşhis edilmesi sırasında kullanılan dermoskopik yöntemleri ve başarı oranlarını bu bölümde açıkladık. Doğru teşhisin ne kadar önemli olduğunu ve hastalardan biyopsi istenmesi aşamasında verilecek kararın hayati olduğundan bu bölümde bahsettik. Bir sonraki bölümde ise uzman doktorlara cilt kanseri teşhisinde yardımcı olabileceğini düşündüğümüz makine öğrenmesi konusunu açıklamaya çalışacağız.

ÜÇÜNCÜ BÖLÜM

MAKİNE ÖĞRENMESİ

Makine öğrenmesi, öğrenme kümesinin etiketli veya etiketsiz olmasına göre, öğrenme sırasında erişilmeye çalışılan amaca göre veya kurulan öğrenme mekanizmasının yapısına göre, gözetimli öğrenme, gözetimsiz öğrenme, pekiştirmeli öğrenme ve derin öğrenme gibi çeşitli sınıflara ayrılmaktadır. Bu kavramlarla birlikte destek vektör makineleri (SVM), k-en yakın komşu (KNN), uzun kısa süreli bellek (LSTM), tekrarlayan sinir ağı (RNN), yapay sinir ağı (ANN) ve evrişimsel sinir ağı (CNN) gibi yöntemlerle bu yöntemleri beslemek için kullanılan öznelikler bu bölümde açıklanmaya çalışılmıştır.

3.1.Makine öğrenmesi çeşitleri

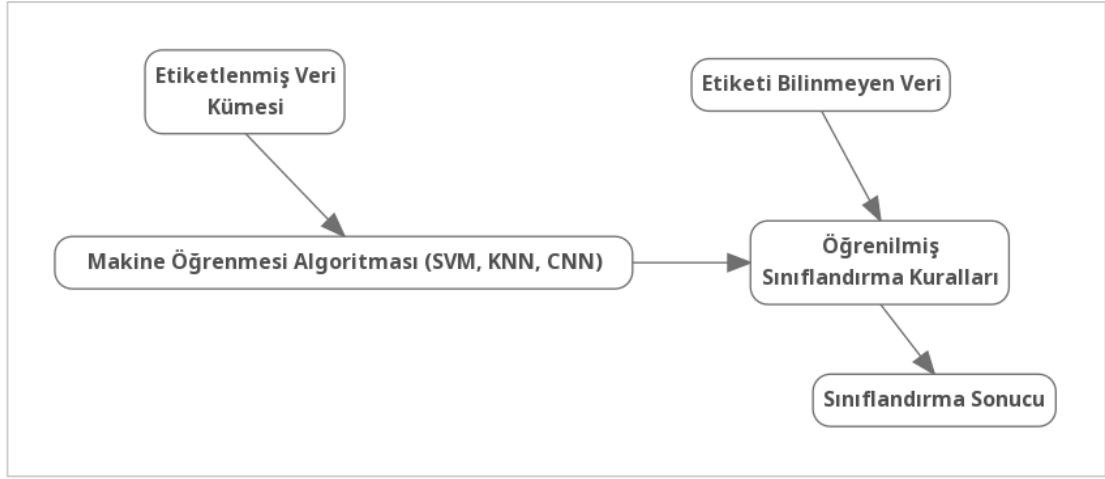
Makine öğrenmesi dört ana başlıkta incelenmektedir. Bunlar gözetimli öğrenme, gözetimsiz öğrenme, pekiştirmeli öğrenme ve derin öğrenme olarak isimlendirilmektedirler. Bu başlıkların dışında hibrit paradigmlar da bulunmakla birlikte bu çalışmayı anlamak açısından adı geçen paradigmları kısaca açıklamak yeterli olacaktır. Bu paradigmların temelde yaptığı iş öznelik adı verilen değer kümeleri arasında ayırım yapabilen bir formüle ulaşmaktır. Öznelik, sınıflandırılacak olan veriye ait ayırt edici, genellikle sayısal değerlerden oluşan fakat bazen de alfanümerik olabilen değerlerdir. Protein dizileri, medikal resimler veya benzeri birçok konuda sınıflandırma işlemi öznelik çıkarma işlemine bağlıdır. Öznelik, görüntü işleme alanında çok önemli bir rol oynar. Öznelikler elde edilmeden önce, görüntü üzerinde çeşitli görüntü ön işleme teknikleri uygulanır. Bundan sonra, görüntülerin sınıflandırılması ve tanınmasında yararlı olacak öznelikler elde etmek için öznelik çıkarma teknikleri uygulanır. Bu alanla ilgili literatürde yapılan bazı çalışmalara şunlar örnek olarak gösterilebilir (Torkamaniafshar, vd., 2020; Kumar ve Bhatia, 2014). Makine öğrenmesi yöntemleri; nesne tanıma, görüntü işleme, artırılmış gerçeklik, ses tanıma, robot ve araç programlama gibi alanlarda ve tıp, otomotiv, eğlence, pazarlama sektörlerinde çok çeşitli amaçlar için kullanılabilir (Küçük ve Kiani, 2018).

3.1.1.Gözetimli öğrenme

Gözetimli öğrenme etiketleri bilinen sınıflandırılmış bir veri kümesinin nasıl sınıflandırıldığına dair kalıpları veriden çıkarmaya dayalı bir yöntemdir. Bu yöntemde etiketler bilinmektedir ve eldeki kümeden bu etiketlere ait olan verilerin ortak noktalarını tespit etmeye yarayan algoritmalar kullanılır (Hurwitz ve Kirsch, 2018: 15). Gözetimli öğrenme teknikleri, bir dizi tanımlayıcı özellik ile bir dizi hedef özellik arasındaki ilişkinin modelini önceki örneklere dayanarak otomatik olarak öğrenir. Daha sonra bu modeli yeni örnekleri tahmin etmek için kullanabiliriz (Kelleher, Namee ve D'Arcy: 2015: 43).

Gözetimli öğrenmenin en büyük avantajı bu yöntemin ele aldığı tüm sınıfların ve çıktılarının insanlar için anlamlı olmasıdır. Onun için sınıflandırma veya regresyon için kullanılabilir. Fakat bazı dezavantajları da bulunmaktadır. En başta 'gözetimin' bir araya toplanması yani **Şekil 3.1**'de görüldüğü üzere eğitim için gerekli olan verilerin etiketlenmiş olması gelmektedir. Söz gelimi çok büyük miktarda resimden oluşan veri kümesini etiketlemek kolay değildir. Ayrıca gerçek hayatta her şeyin sınırları kesin olarak belirli olmayabilir. Mesela 'sıcak' ve 'soğuk' ayrımının çok net olmaması gibi. Bu gibi kısıtlamaların üstesinden gelmek için bazı durumlarda gözetimsiz öğrenme, yarı gözetimli öğrenme ya da pekiştirmeli öğrenme gibi yaklaşımlar uygulanmaktadır (Liu ve Wu, 2012: 3243-3245).

Gözetimli öğrenme bazı görevlerde makinanın insanın davranışını öğrenmesini sağlar. Öğrenilen bilgi daha sonra makinanın bu görevlerde benzeri aksiyonları almasına yardımcı olur. Bilgisayarların girdi çıktı eşleşmesini daha hızlı ve daha sağlıklı yapabilmesinden yola çıkarak bir gözetimli öğrenici makine benzeri görevleri insandan daha hızlı ve daha kesin yapabilir. Fakat donanım, yazılım ve algoritmalarındaki eksikliklerden dolayı elde bulunan gözetimli öğrenme algoritmaları, karmaşık görevlerde halen insanın öğrenme yeteneklerine erişebilmiş değildir (A.g.e).



Şekil 3.1: Gözetimli öğrenme diyagramı

3.1.2. Gözetimsiz öğrenme

Sınıflandırılmamış büyük miktarda veriden bu verinin arkasında yatan anlamları tespit etmek için kullanılan kümeleme ve sınıflandırma algoritmalarına verilen isimdir. Gözetimli öğrenme gibi bu algoritmalar da veri içerisindeki örüntüleri veya kalıpları bulmaya çalışırlar. Fakat aradaki fark gözetimsiz öğrenmede kullanılan verinin henüz anlaşılmamış olmasıdır. Çok miktarda verinin etiketlenmesi çok zaman aldığından gözetimsiz öğrenme ile çalışmak daha hızlı sonuç vermektedir (Hurwitz ve Kirsch, 2018: 16). Temelde kümeleme işlemine dayanır. Kümeleme basitçe bir nesne öbeği içerisinde benzer olanlarını aynı kümeye farklı olanları ise bir başka kümeye koymak demektir. Kümeleme işlemi sosyal bilimler, biyoloji veya bilgisayar bilimleri gibi birçok alanda kullanılan bir veri analizi tekniğidir. Çünkü insanlar öncelikle ellerindeki veri yığınına anlamlı şekilde gruplandırarak bir izlenim edinmek isterler (Shalev-Shwartz ve Ben-David, 2014: 307).

3.1.3. Pekiştirmeli öğrenme

Örnek veri kümesi yerine deneme yanılma yöntemiyle en iyi sonucu bulmaya çalışan algoritmalar (Hurwitz ve Kirsch, 2018: 16). Pekiştirmeli öğrenme, bir ödül değerini yükseltmek üzere durumlar ile eylemleri eşleştirerek ne yapılacağını öğrenmeye denilmektedir. Öğrenciye ne yapılacağı direk olarak söylenmez, bunun yerine eylemleri deneyerek hangisinin en iyi ödül değerini verdiğini çıkarması beklenir. Bazı

durumlarda eylemler ödölü hemen yükseltmez, bir önceki ya da bir sonraki eyleme bağılı olarak ve bir dizi eylem arka arkaya eklenerek ödöl değeri belirlenebilir. Etkileşimli problemlerde genellikle doğru olan ve öğrencinin karar vermesi gereken tüm durumları ve yapması gereken tüm davranışları örneklendirmek pratik değildir. Böyle bir davranış ve durum şemasının olmadığı durumlarda öğrencinin kendi deneyimlerinden öğrenebilmesi gerekmektedir. Pekiştirmeli öğrenmenin bir çeşit gözetimsiz öğrenme olduğu düşünülmemelidir. Çünkü gözetimsiz öğrenme veri içerisindeki gizli yapıları bulmaya çalışırken, pekiştirmeli öğrenme bir ödöl değerini yükseltmeye çalışmaktadır. Öğrencinin hareketlerindeki gizli yapıları ortaya çıkarmaya çalışmak da faydalı bir çalışma olabilir fakat bu pekiştirmeli öğrenmeyi açıklamaya yeterli olmaz. Onun için pekiştirmeli öğrenme gözetimli ve gözetimsiz öğrenmeden sonra üçüncü makine öğrenmesi paradigmasıdır denilmektedir (Sutton ve Barto, 2018: 1).

3.1.4. Derin öğrenme

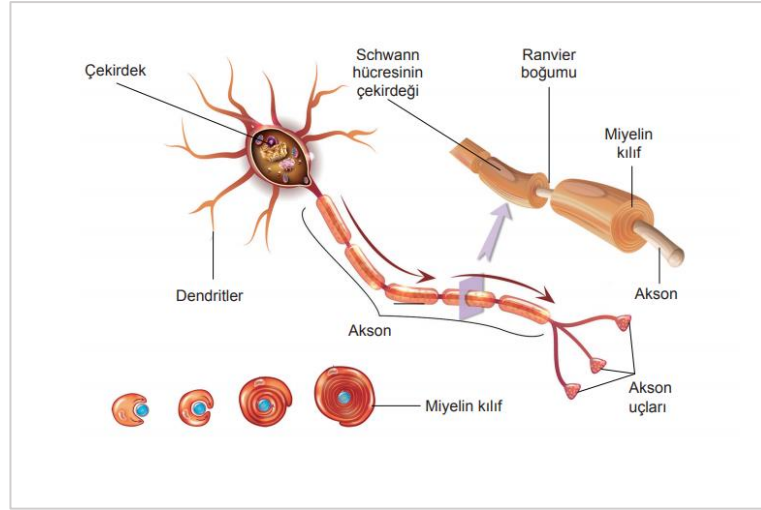
İnsan beyninin işleyişini taklit eden, katmanlı yapay nöron ağlarından oluşan, yapısal olmayan verilerden kalıpları çıkarmak üzere kullanılan algoritmalarıdır (Hurwitz ve Kirsch, 2018: 17). Derin Öğrenme veya Derin Sinir Ağı terimi, çok katmanlı yapay sinir ağlarını ifade eder. Son yıllarda büyük miktarda veriyi işleyebildiği için literatürde çok popüler hale geldi ve güçlü makine öğrenmesi araçlarından biri olarak kabul gördü. Daha derin gizli katmanlara sahip olma ilgisi son zamanlarda farklı alanlarda klasik yöntemlerin performansını aşmaya başladı; özellikle örüntü tanıma. En popüler derin sinir ağlarından biri, Evrişimsel Sinir Ağıdır (CNN). Bu ismi matrisler arasındaki evrişim adı verilen matematiksel işlemden alır (Albawi, Mohammed ve Al-Zawi: 2017). Evrişimsel sinir ağı ilerleyen kısımlarda ayrıntılı olarak açıklanacaktır.

3.2. Makine öğrenmesi yöntemleri

Bir önceki başlıkta incelenmiş olan makine öğrenmesi çeşitlerinin gerçekleşmesi ile elde edilen ve bu çalışmada kullanılan yöntemleri bu başlık altında açıklamaya çalıştık.

3.2.1.Yapay sinir ađları (ANN)

Yapay sinir ađları alıřmaları, biyolojik ğrenme sistemlerinin birbirine bađlı nronların meydana getirdiđi ok karmařık ađlardan oluřtuđu gzleminden esinlenmiřtir. Yapay sinir ađları beyindeki sinir ađlarının yapısından esinlenen bir hesaplama modelidir. Biyolojik sinir hcresinin rnek izimi **řekil 3.2**'de verilmektedir. Beynin basitleřtirilmiř modellerinde, sinir ađı son derece karmařık hesaplamalar yapabildiđi karmařık bir iletiřim ađında birbirine bađlı ok sayıda biyolojik sinir hcresini taklit eden temel nronlardan (Perceptron ya da Sigmoid gibi) oluřur. Yapay sinir ađları, bu hesaplama paradigmasına gre modellenen matematiksel hesaplama yapılarıdır. Bir sinir ađı, dđmleri (node) nronlara ve kenarları (edge) bunların arasındaki bađlantılara karřılık gelen bir eřit ynl graf (directed graph) olarak tanımlanabilir. Bylece yapay sinir ađları, birbirine bađlı bir dizi basit nrondan oluřur, burada her nron girdi olarak bir dizi gerel sayı deđerini alır ve tek bir gerel sayı deđerini ıktı retir. Her nron, girdi olarak kendisine bađlı kenarların diđer ucundaki nronların ıktılarının ađırlıklı bir toplamını alır ve bunlar da diđer birok birime girdi olarak verilebilir. Bu benzeřimi daha iyi anlayabilmek iin nrobiyolojiden gerek bir rnek vermek gerekirse, insan beyni birbirine yođun bir řekilde bađlı olan 10^{11} nrondan oluřmaktadır. Bunlardan her biri yaklařık olarak 10^4 diđer nrona bađlıdır. Nron aktivitesi tipik olarak diđer nronlara bađlantılar yoluyla uyarılır veya durdurulur. En hızlı nron ama kapama sresinin 10^{-3} saniye olduđu bilinmektedir. Bu sre bilgisayarlarda 10^{-10} olan ama kapama hızına kıyasla oldukça yavařtır. Yine de insanlar řařırtıcı derecede hızlı řekilde karmařık kararlar verebilirler. rneđin, annenizi grsel olarak tanımak iin yaklařık 10^{-1} saniye gerekir. Tek bir nronun ama kapama hızı gz nne alındıđında, bu 10^{-1} saniyelik aralıktaki gerekleřebilecek nronları ama kapama iřleminin birka yz adımdan daha uzun olamayacađını dikkati ekmektedir. Bu gzlem biyolojik ğrenme sistemlerinin birok nron zerine dađıtılarak alıřan paralel bir iřlem olduđunun dřnlmesine yol amıřtır. Nral ađların motivasyonu da bu řekilde beyinin paralel hesaplama yntemini taklit etmektir (Mitchell, 1997: 81; Shalev-Shwartz ve Ben-David, 2014: 268).



Şekil 3.2: Biyolojik Sinir Hücresi

Kaynak: (www.eba.gov.tr, 2020)

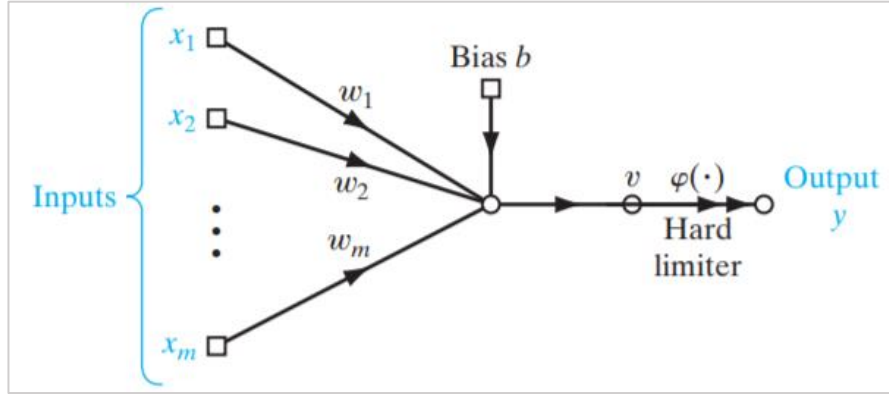
a) Algılayıcı (Perceptron)

Temelleri Warren S. McCulloch ve Walter Pitts tarafından “A Logical Calculus Of The Ideas Immanent In Nervous Activity” başlıklı makale ile atılan makine öğrenmesi Frank Rosenblatt’ın “Perceptron” isimli yapay nöron algoritmasını geliştirmesiyle önemli bir aşama kaydetmiştir. Bu algoritmanın bir şeması **Şekil 3.3**’te gösterilmiştir. Perceptron algoritması, birçok ikili girdi alıp bir tane ikili cevap üretir. Nöronun çıktısı, girdilerin belli bir ağırlık değeri ile çarpılıp toplanmalarıyla elde edilen sonucun bir eşik değeri geçmesi durumunda 1 olur geçmediği durumda 0 olur. Perceptron’un girdilerindeki ağırlık değerleri ve eşik değeri gerçel sayılar kümesinden olup bunlara uygun değerler atandığında girdilere göre doğru cevaplar veren karar verme fonksiyonları hayata geçirilebilmektedir. Perceptron’u daha basit şekilde ifade etmek istersek ‘w.x’ girdilerin ve ağırlıkların çarpımlarının toplamını ve ‘b’ eşik değerinin denklemin diğer yanına aktarıldığı halini ifade etmesiyle perceptron’un çıktısı (3.1) nolu denklemdeki gibi olacaktır.

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

Burada b değeri ‘bias’ yani yanlılık olarak ifade edilmektedir. Perceptron’dan başka yapay nöronlar da bulunmaktadır. Örneğin ağırlık ve yanlılık değerleri küçük

miktarlarda deęiştirildiğinde sonucun 1 veya 0 gibi radikal deęişmedięi sonuç olarak 1 ile 0 arasında gerçel bir sayı üreten Sigmoid nöronu gibi. (Nielsen, 2015: 2-7)

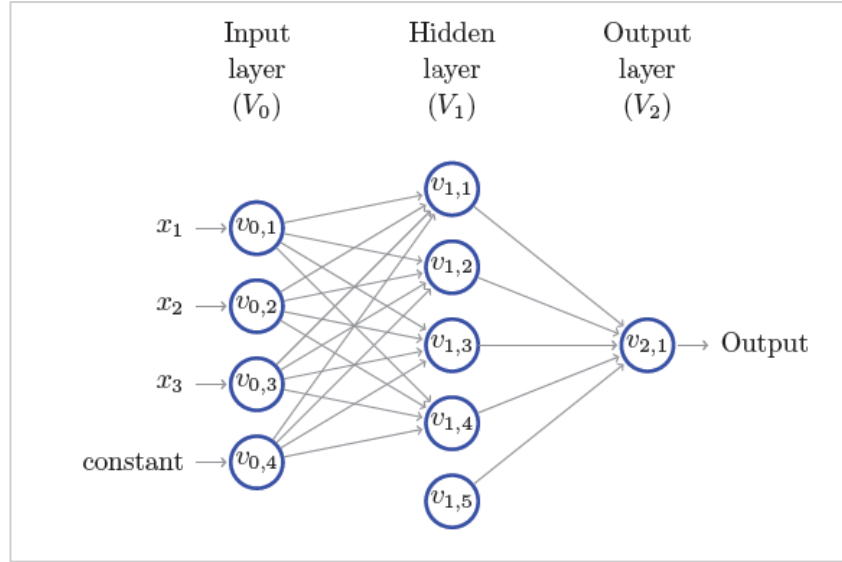


Şekil 3.3: Rosenblatt'ın perceptron'u

Kaynak: (Haykin, 2009)

b) Çok katmanlı algılayıcı (Multi layer perceptron)

Çok katmanlı algılayıcılar, giriş ve çıkış katmanları arasında bir veya daha fazla -gizli- katmanı olan ileri beslemeli (feed-forward) ağlardır. Çıkış birimleri, girdi örüntüleri uzayında bir hiper düzlemi temsil eder. Sigmoidal aktivasyon fonksiyonunu kullanan üç katmanlı bir 'çok katmanlı algılayıcı'nın, herhangi bir sürekli çok deęişkenli fonksiyonu herhangi bir doğruluęa yaklaştıracabileceęi matematiksel olarak kanıtlanmıştır (Du ve Swamy, 2013: 86-87). Bu tür bir yapay sinir ağının bir giriş katmanı, bir veya daha fazla gizli katmanı ve bir çıkış katmanı vardır. Bir veya iki gizli katman ile kullanılması en iyi uygulama olarak önerilmektedir. Bunun nedeni, aynı sonucun, gizli katmanların sayısını artırmak yerine gizli katmandaki nöron sayısını artırarak elde edilebilmesidir. Şekil 3.4'te bir yapay sinir aęı çizimi gösterilmektedir. Çok katmanlı algılayıcılar, aynı katmandaki tüm nöronların bir sonraki katmanın tüm nöronlarına baęlı olduęu, ancak aynı katmandaki nöronların birbirine baęlı olmadığı ileri beslemeli ağlardır. Bilgi akışı giriş katmanından çıkış katmanına geçtięi için ileri besleme olarak adlandırılır. Çok katmanlı ağlar için kullanılan eğitim algoritması, çok katmanlı ağın çeşitli giriş verilerinden istenen bir çıktıyı öğrendięi, denetimli bir öğrenme algoritması olan geriye yayılım algoritmasıdır. (Oliveira, Barbar, ve Soares: 2016) Bu alanla ilgili literatürde yapılan bazı çalışmalar sunulmaktadır (Seyyedabbasi, Candan ve Kiani: 2018; Türk ve Kiani, 2019; Kutlugün, Çakır ve Kiani: 2017).



Şekil 3.4: Örnek sinir ağı

Kaynak: (Shalev-Shwartz ve Ben-David, 2014: 270)

3.2.2. Evrişimsel sinir ağları (CNN)

En popüler derin sinir ağlarından biri, Evrişimsel Sinir Ağıdır (CNN). Bu ismi evrişim adı verilen matrisler arasındaki matematiksel işlemden alır. CNN'nin birden fazla katmanı vardır; evrişimsel katman, doğrusal olmayan katman, havuzlama katmanı ve tam bağlı katman dahil. Katlamalı ve tam bağlı katmanların parametreleri vardır ancak havuzlama ve doğrusal olmayan katmanların parametreleri yoktur. CNN, makine öğrenimi problemlerinde iyi bir performansa sahiptir. Özellikle en büyük görüntü sınıflandırma, bilgisayarla görme ve doğal dil işleme gibi görüntü verileriyle ilgili uygulamalarda iyi bir performans ortaya koymaktadır.

CNN'lerin en faydalı yönü yapay sinir ağlarındaki parametre sayısını azaltmaktır. Bu başarı, klasik yapay sinir ağlarıyla mümkün olmayan karmaşık görevleri çözmek için hem araştırmacıları hem de geliştiricilerin daha büyük modeller oluşturmalarına imkan sağlamıştır. CNN tarafından çözülen problemlerle ilgili en önemli varsayım, mekânsal olarak bağımlı özelliklere sahip olmamalıdır. Başka bir deyişle, örneğin, bir yüz algılama uygulamasında, yüzlerin görüntülerde nerede bulunduğu dikkat etmemiz gerekmez. Dikkat edilmesi gereken, verilen görüntülerdeki konumlarına bakılmaksızın onları tespit etmektir. CNN'nin bir başka önemli yönü, girdi daha derin katmanlara doğru yayıldığı zaman soyut özellikler elde etmektir. Örneğin, görüntü

sınıflandırmasında, ‘kenar’lar ilk katmanlarda, basit şekiller ikinci katmanlarda ve ardından sonraki katmanlardaki yüzler gibi daha yüksek düzey özellikler algılanabilir. (Albawi, Mohammed ve Al-Zawi: 2017) Bu alanla ilgili literatürde yapılan bazı çalışmalar sunulmaktadır (Kiani, Kutlugün ve Çakır: 2017).

a) Öğrenme aktarımı

Evrişimsel sinir ağlarının en kullanışlı özelliklerinden biri de önceden hazırlanmış olan modellerin öğrenme aktarımı yolu ile yeni modellerde kullanılarak yeni modelin doğruluk oranının artırılabilmesidir. Bunun için en sık kullanılan modellerden biri VGG16 diğeri ise InceptionV3 isimli modellerdir. VGG16 Oxford üniversitesinden Simonyan ve Zisserman tarafından InceptionV3 ise Google’dan Szegedy ve arkadaşları tarafından hazırlanmıştır. Öğrenme aktarımında evrişimsel ağın ağırlıklarının aktarım yapılan katmanlara doğru yayılmasına ‘ince ayarlama’ (fine tuning) denmektedir. Öğrenme aktarımı yapılırken aktarım yapılan modelin sınıflandırıcısı modelden ayrılarak öznetelik çıkaran kısım üzerine yeni sınıflandırıcı eklenir ve yeni modelin sınıflarına göre sınıflandırma yapılır.


3.2.3.Geri beslemeli sinir ağları (RNN)

İnsan beyni yoğun şekilde geri beslemeli ve kendini tekrarlayan bir yapıdır. Bu büyük kendini tekrarlayan yapı, kendini besleme dinamiklerinin algılama, davranış, öğrenme ve organizmanın canlı tutulmasında önemli bir rol oynadığını göstermektedir. Geri beslemeli ağlar (RNN) beyin benzeri bilgi işlemenin gücünden yararlanır. Geri beslemeli ağlarda en az bir geri besleme bağlantısı vardır. Geri beslemeli ağlar kullanıldığında, aynı oranda doğruluğun elde edilmesi için gereken ağ boyutu ileri beslemeli ağlarla karşılaştırıldığında önemli ölçüde küçüktür. Çok katmanlı algılayıcı, topolojik ilişki sorunlarını çözme kabiliyeti bakımından temel olarak sınırlıdır. Çok katmanlı algılayıcı, tamamen statiktir ve zaman bilgisini işleyemez. Halbuki verinin üzerine bir zaman penceresi eklenerek önceki verilerin hatırlanması ve işlenmesi sağlanabilir ve böylece uygulamada, $t + 1$ zamanındaki ağ durumundan t zamanındaki bir girdiyi tahmin etmemiz mümkün olabilir. Dinamik bir işlemi modellemek için ortaya çıkan bu ağ modeli, zamana bağlı ilişkisel ağ olarak adlandırılır. Zamana bağlı ilişkilendirme ağları, ilişkilendirmenin zamana bağlı yapısını işleyecek şekilde

Yinelenen bir mimariye sahip olmalıdır. Geri beslemeli ağılar, zamana bağılı durum bilgisi de olan dinamik sistemlerdir. Hesaplama açısından güçlüdürler ve birçok zamana bağılı işleme modeli ve uygulamasında kullanılabilirler. Ayrıca, geri beslemeli ağılar sıradan diferansiyel denklem sistemleri ile modellenmiş olduğundan, sıradan diferansiyel denklemlerin entegrasyonu için standart yazılım kullanılarak uygulanmak için de uygundur. Hopfield modeli ve Cohen-Grossberg modeli iki yaygın tekrarlanan ağ modelidir (Du ve Swamy, 2013: 351-352).

3.2.4. Uzun kısa süreli bellek (LSTM)

Hochreiter ve Schmidhuber tarafından RNN'deki sorunları çözmek için RNN'in gelişmiş hali olan Uzun Kısa Süreli Bellek, ortaya çıkarılmıştır. **Şekil 3.5**'de yazarların ilgili makalesinde önerdiği yöntemin çizimi görülmektedir (Hochreiter & Schmidhuber, 1997). Uzun kısa süreli bellek (LSTM), uzun süreli bağımlılıkları öğrenebilen ve uzun süreler boyunca bilgileri hatırlayabilen özel bir RNN türüdür. LSTM modeli bir zincir yapısı şeklinde düzenlenmiştir. Ancak, tekrarlayan modülün farklı bir yapısı vardır. Standart bir RNN gibi tek bir sinir ağı yerine birbirleriyle etkileşen dört katmanı vardır. Tipik bir LSTM ağı, hücreler adı verilen bellek bloklarından oluşur. Hücre durumu ve gizli durum adı verilen iki durum bir sonraki hücreye aktarılmaktadır. Hücre durumu, bazı lineer dönüşümlere uğrayabilirse de verilerin temelde değişmeden ileri akmasına izin veren ana veri akışı zinciridir. Veriler sigmoid kapılar yoluyla hücre durumuna eklenebilir veya hücre durumundan çıkarılabilir. Bir kapı, birbirinden farklı ağırlıklar içeren bir katmana veya bir dizi matris işlemine benzer. Uzun kısa süreli bellek, ezberleme sürecini kontrol etmek için kapılar kullanarak uzun süreli bağımlılık probleminin kaçınmak üzere tasarlanmıştır. (Le, vd., 2019)



Şekil 3.5: Hochreiter ve Schmidhuber makalesinde bir uzun kısa süreli bellek hücresinin gösterimi

Kaynak: (Hochreiter ve Schmidhuber, 1997)

3.2.5.K-En yakın komşu (KNN)

Gözetimli makine öğrenmesi algoritmalarından olan “K en yakın komşu” (KNN) algoritması basit ve etkili bir sınıflandırma metodudur. Arkasında yatan ana fikir gayet basittir. Örnekler yakınlarındaki komşularına göre sınıflandırılır. Genelde birden fazla komşu dikkate alınarak sınıflandırma yapıldığı için “k en yakın komşu” ismini almıştır. KNN model temelli olmadığından bütün örnekleri hafızada tutar ve yeni gelen örneği en yakın komşularına göre sınıflandırarak kümeye ekler. Ana amacı bilinmeyen bir örneği var olan örneklerden en yakın komşusuna göre sınıflandırmaktır. Komşu yakınlığını hesaplamak için çeşitli metotlar kullanılabilir. Orjinal KNN algoritması ve bazı yakınlık hesaplama metotları aşağıdaki gibidir (Asim ve Zakria, 2020).

a) *KNN algoritması*

1. Veri kümesini toparla
2. k değişkenine bir değer ata
3. Her bir yeni eklenen örnek için
 - 3.1 Yeni örnek ve diğer bütün örnekler arasındaki uzaklığı hesapla.
 - 3.2 Uzaklıkları artan şekilde sırala.
 - 3.3 En üstteki k uzaklığı ve etiketini seç.
 - 3.4 Yeni örneğin ait olduğu sınıf seçilenler arasında en fazla olanıdır

b) Yakınlık Metodları

1. Öklid

$$\sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (3.2)$$

2. Manhattan

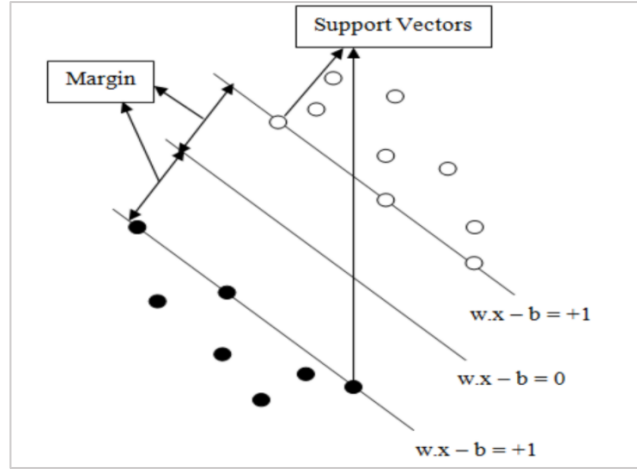
$$d_1(p, q) = \sum_{i=1}^n |p_i - q_i| \quad (3.3)$$

3. Minkowski

$$D(X, Y) = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (3.4)$$

3.2.6. Destek vektör makinesi (SVM)


Destek vektör makineleri 1992 yılında Boser, Guyon, ve Vapnik tarafından önerilmiş bir makine öğrenmesi ve örüntü tanıma algoritmasıdır (Boser, Guyon, ve Vapnik: 1992). Destek vektör makinesi her birisi bir sınıfa ait etiketli örneklerle eğitilen ve yeni verilen örneğin hangi sınıfa ait olduğunu tahmin edebilen bir model üreten gözetimli bir makine öğrenmesi algoritmasıdır. İlk başlarda ikili sınıflandırma yapmak üzere geliştirilmiş olan destek vektör makinesi algoritması ilerleyen zamanda daha fazla sınıfları tanımlamak üzere geliştirilmiştir. Destek vektör makinesinin arkasındaki temel fikir doğrusal olarak birbirinden ayrılacak olan örüntüleri sınıflandırmak için en iyi “aşırı düzlem” bulmaktır. **Şekil 3.6**'da destek vektörleri ve aşırı düzlem ile SVM örneği verilmektedir. Burada “aşırı düzlem” örneklerin arasında kalan boşluk olarak düşünülebilir. En iyi aşırı düzlem, bulunan aşırı düzlemler arasından boşluğu en fazla olanın seçilmesiyle bulunur. Bu boşluk ne kadar büyük olursa destek vektör makinesinin örüntüleri sınıflandırma işlemi o kadar doğru olacaktır (Pradhan, 2012).



Şekil 3.6: SVM'in en geniş boşluk ve destek vektörleri

Kaynak: (Pradhan, 2012)

Eğitim kümesi birbirinden tamamen ve en yüksek boşluk ile ayrılabilen iki ayrı sınıftan oluşuyorsa bu doğrusal destek vektör makinesi olarak adlandırılır. Eğer veri doğrusal olarak ayrılmıyorsa destek vektör makinesi “gelişigüzel değişkenler” ile genişletilerek bazı hatalara izin verir hale getirilir. Buna “yumuşak kenarlı” destek vektör makinesi denilir. Bu durumda destek vektör makinesi bütün örnekleri doğru sınıflandırmaya çalışmak yerine bazı örnekleri yanlış sınıflandırmaya izin vererek en çok sayıda örneği doğru sınıflandırmaya çalışır. Eğer bir veri kümesi lineer olarak ayrılmıyorsa yumuşak kenarlı destek vektör makinesi uygun aşırı düzlemi bulamaz, yanlış sınıflandırılan örnek sayısını en aza indiremez ve bir çözüme ulaşamaz. Bu durumda Şekil 3.7’deki gibi çekirdek fonksiyonları kullanılarak veri daha yüksek bir boyuta taşınır ve bu “çekirdek boyutu”nda ayrılabilir (Awad ve Khanna, 2015).



Şekil 3.7: SVM'de çekirdek fonksiyonunun işlevi

Bu fonksiyonlardan bazıları aşağıda verilmektedir (Awad ve Khanna, 2015).

a) Çekirdek fonksiyonları

1. Polynomial

$$k(x_i, x_j) = (x_i \cdot x_j + 1)^d \quad (3.5)$$

2. Gaussian

$$k(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (3.6)$$

3. Gaussian RBF

$$k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3.7)$$

4. Laplace RBF

$$k(x, y) = \exp\left(-\frac{\|x - y\|}{\sigma}\right) \quad (3.8)$$

5. Hyperbolic tangent

$$k(x_i, x_j) = \tanh(\kappa x_i \cdot x_j + c) \quad (3.9)$$

6. Sigmoid

$$k(x_i, x_j) = \tanh(\kappa x_i \cdot x_j + c) \quad (3.10)$$

7. Anova Radial basis kernel

$$k(x, y) = \sum_{k=1}^n \exp(-\sigma(x^k - y^k)^2)^d \quad (3.11)$$

8. Linear splines kernel 1D


$$k(x, y) = 1 + xy + xy \min(x, y) - \frac{x + y}{2} \min(x, y)^2 + \frac{1}{3} \min(x, y)^3 \quad (3.12)$$

3.3.Bu çalışmada kullanılan öznitelikler

Çalışmamız temel olarak üç çeşit öznitelikten faydalanarak sınıflandırma yapmak üzerine kuruludur. Bunlar evrişimsel sinir ağından elde edilen öznitelikler, gri değeri eş dizilim matrisi öznitelikleri ve ham resim piksel öznitelikleri olmak üzere bu başlık altında açıklanmaktadır.

3.3.1.Evrişimsel sinir ağı öznitelikleri

Evrişimsel sinir ağları iki parçadan oluşur. Birinci parçası resimden öznitelik öğrenirken ikinci parçası ise sınıflandırıcı olarak çalışır. Bu iki parçayı birbirinden ayırdığımızda öznitelik öğrenen kısım bir öznitelik çıkarıcısı olarak çalışabilir. Bu öznitelikler çeşitli boyutlarda dizilerdir. Örneğin VGG16 7x7x512 boyutlarında bir dizi üretirken InceptionV3 8x8x2048 boyutlarında öznitelik dizisi üretmektedir. Bu öznitelik dizileri daha sonra çeşitli sınıflandırıcılarla sınıflandırılabilir. **Şekil 3.8'**de InceptionV3 mimarisindeki sınıflandırıcı ve öznitelik çıkarıcı katmanlar gösterilmektedir.



Şekil 3.8: InceptionV3 mimarisinde sınıflandırıcı ve öznitelik çıkarıcı katmanların gösterimi

Kaynak: (Google AI Blog, 2020)

3.3.2.Gri seviyesi eş dizilim matrisi (Haralick) öznitelikleri

Bir resmi veya dokuyu tanımlamak için en basit yöntemlerden birisi resmin tamamının veya bir bölgesinin yoğunluk histogramının istatistiksel momentlerini kullanmaktır.

Hesaplama sadece histogramı kullanmak sadece yoğunlukların dağılımı hakkında bilgi verir fakat o dokudaki piksellerin birbirlerine göre durumları hakkında bilgi vermez. Eş dizilim matrisi gibi istatistiksel bir yaklaşım resimdeki komşu piksellerin birbirlerine göre durumları hakkında değerli bilgiler verir. Haarlick 1973 senesinde 14 istatistiksel öznitelik önermiştir. Bu öznitelikler 0° , 45° , 90° , and 135° 'lik eş dizilim matrisleri hesaplanıp ortalamaları alınarak oluşturulmaktadır. Genellikle uzaklık parametresi 1 olarak seçilir. Bu 14 istatistiksel öznitelik eş dizilim matrisini oluşturmada kullanılır (Eleyan ve Demirel, 2011).

Gri seviyesi eş dizilim matrisi i ve ona göre belli bir uzaysal uzaklıkta olan j pikselinin gri değerlerinin eşlenik olma durumunun girdi olarak verilen resimde kaç kere geçtiğini göstermektedir. $P(i, j | \Delta x, \Delta y)$ matris elemanı $(\Delta x, \Delta y)$ uzaklıkta bulunan piksele görece sıklığı ifade eder. $P(i, j | d, \theta)$ olarak gösterilen matris elemanı ise teta açısıyla d uzaklığında bulunan j pikseli ile i arasındaki değişimin ikinci dereceden olasılığını ifade eder. Eş dizilim matrisinden birçok özellik çıkarılabilir. G kullanılan gri seviyeleri, μP nin ortalama değeri $\mu_x, \mu_y, \sigma_x, \sigma_y, P_x$ ve P_y 'nin ortalama değer ve standart sapmasıdır. $P_x(i)$, $P(i, j)$ satırları toplanarak elde edilen i 'inci değer olmak üzere şu denklemler tanımlanmaktadır;

$$p_x(i) = \sum_{j=0}^{G-1} P(i, j) \quad (3.13)$$

$$P_y(j) = \sum_{i=0}^{G-1} P(i, j) \quad (3.14)$$

$$\mu_x = \sum_{i=0}^{G-1} iP_x(i) \quad (3.15)$$

$$\mu_y = \sum_{j=0}^{G-1} jP_y(j) \quad (3.16)$$

$$\sigma_x^2 = \sum_{i=0}^{G-1} (P_x(i) - \mu_x(i))^2 \quad (3.17)$$

$$\sigma_y^2 = \sum_{j=0}^{G-1} (P_y(j) - \mu_y(j))^2 \quad (3.18)$$

Tanımlanan denklemler kullanılarak ilgili makalelerinde Haralick ve arkadaşları tarafından tanımlanmış olan aşağıdaki öznelikler elde edilebilir (Haralick, Shanmugam ve Dinstein: 1973).

Karşıtlık (Contrast) resimde bulunan yerel farklılıkların ölçüsüdür. Bir piksel kümesinde bulunan en yüksek ve en düşük değerlerin arasındaki fark ile bağlantılıdır. Resimde yüksek miktarda değişkenlik varsa karşıtlık değeri yüksek olur.

$$\sum_{i,j=0}^{G-1} P_{i,j} (i - j)^2 \quad (3.19)$$

Farklılık (Dissimilarity, Difference Average) resimdeki gri değeri fark dağılımının ortalamasını ölçer. Daha büyük bir değer, komşu vokseller arasında yoğunluk değeri bakımından daha büyük eşitsizlik anlamına gelir.

$$\sum_{i,j=0}^{G-1} P_{i,j} |i - j| \quad (3.20)$$

Homojenlik (Inverse Difference Moment, Homogeneity) resmin yerel homojenliğini ölçer. Piksel çiftlerinin eş dizilimli olması oranı, gri ölçüsü değerleri birbirine yakın olduğunda artar ve bu da “homojenlik” değerini artırır. $1/(1 + (i - j)^2)$ ağırlık çarpanı sebebiyle $i \neq j$ olduğu durumlarda homojen olmayan alanlardan küçük katkılar alacaktır. Sonuç olarak homojen olmayan resimler için küçük fakat homojen olan resimler için görece daha büyük değerler elde edilir.

$$\sum_{i,j=0}^{G-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (3.21)$$

Ortak Enerji (Joint Energy, Angular Second Moment) resmin homojenliğinin ölçülerinden biridir. Homojen bir resim sadece birkaç gri seviyesi barındırır, böylece

eş dizilim matrisi bir kaç tane görece yüksek $p(i, j)$ değerleri içerecektir. Böylece karelerin toplamı yüksek olacaktır. Yüksek değerler dokusal tekdüzeliğe işaret etmektedir. Yani resim homojense enerji özneliğinin değeri yüksek olacaktır.

$$\sum_{i,j=0}^{G-1} P_{i,j}^2 \quad (3.22)$$

Enerji (Energy)

Ortak enerjinin kare kökü kadardır.

$$\sqrt{\sum_{i,j=0}^{G-1} P_{i,j}^2} \quad (3.23)$$

Bağıntı (Correlation) komşu piksellerin veya belirlenen noktaların gri değerlerinin doğrusal bağımlılığını ölçer. Resimdeki yerel gri seviyesi bağımlılığını gösterir. Benzeri gri seviyesi bölgeleri için yüksek değerler elde edilir.

$$\sum_{i,j=0}^{G-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (3.24)$$

3.3.3. Ham resim piksel öznelikleri

Kaynak resimlerin orijinal halinin herhangi bir öznelik çıkarımı yapmadan sınıflandırıcıya verilmesi durumudur. Bu öznelik çeşidi sıfırdan evrişimsel sinir ağı oluşturulup kullanıldığında ya da önceden eğitilmiş bir evrişimsel sinir ağı ile öğrenme aktarımı yapıldığında kullanılmaktadır. Bu çalışmada bunlara ek olarak diğer sınıflandırıcılar da resimlerin ham halleriyle çalışmaya tabi tutulmuşlardır.

3.4. Sonuç

Bu bölümde makine öğrenmesi paradigmaları ile bu paradigmaları gerçekleyen ve çalışmamızda kullanılan yöntemleri açıklamaya çalıştık. Ayrıca çalışmamızda kullanılan öznelikleri bu bölümde ele aldık. Bir sonraki bölümde bu alanda yapılmış olan çalışmaların bir kısmını incelediğimiz literatür taraması yer almaktadır.

DÖRDÜNCÜ BÖLÜM

LİTERATÜR ÇALIŞMASI

Daha önceki bölümlerde cilt kanserinin ne olduğu, ne derece tehlikeli olduğu ve makine öğrenmesi kullanılarak bu tehlikenin bir kısmının dahi bertaraf edilebilmesinin ne kadar önemli olduğunu açıklamaya çalıştık. Bu bölümde daha önceden bu alanda yapılan çalışmaların bize yol göstermesi için yaptığımız literatür taramasına yer verilmektedir. Makine öğrenmesi yöntemleri ile özellikle cilt kanseri tanıma konusunda yapılmış olan çalışmaları ve makine öğrenmesinin bazı diğer medikal uygulamalarıyla ilgili çalışmalar da bu bölümde ele alınmıştır.

4.1.Önceki çalışmalar

Nunari ve Sonntag (2019), “A CNN toolbox for skin cancer classification” isimli çalışmalarında yazılım geliştiriciler ve dermatoloji uzmanları için bir makine öğrenmesi altyapısı hazırlamayı amaçlamışlardır. Çalışmada ISIC veri kümesinden bir kısmı çıkarılmış ve kalan 12319 resim kullanılmıştır. VGG16 evrimsel sinir ağı kullanılarak 0.762 özgüllük ve 0.85 hassasiyet elde edilmiştir. Sistem “100-image MClass-D” test kümesi üzerinde denenmiş ve bu testi geçtiği gösterilmiştir. Nunari ve Sonntag’ın test için kullandığı “100-image MClass-D” kümesi aynı çalışmada eğitim için kullanılmış olan ISIC veri setinden resimler içermektedir. Böyle durumlarda çalışmada kullanılan resimler ile test kümesindeki resimlerin örtüşme ihtimali olabilmektedir. Bizim çalışmamızda elde ettiğimiz modellerden bir tanesi, buna benzer bir teste ISIC veri kümesinden herhangi bir örnek içermeyen PH² veri kümesi ile tabi tutulmuştur.

Mustafa ve Kimura (2018), “A SVM-Based Diagnosis of Melanoma using Only Useful Image Features” başlıklı çalışmalarında Dermquest ve Dermins isimli internet sayfalarından elde ettikleri 100 malign ve 100 benign lezyon resmini SVM ile sınıflandırmışlardır. Sınıflandırma öncesinde resimleri ön işlemeye tabi tutmuşlar ve GrabCut isimli uygulama vasıtasıyla lezyonun olduğu bölgeyi bulup resmi buna göre kesmişlerdir. Resim işleme teknikleriyle şekil, renk ve geometri özniteliklerini (circularity, solidity, aspect ratio, shape skewness, shape kurtosis, average pixel intensity, average luminance, color skewness, color curtosis, high luminance scale,

entropy, variance, fast corners, boundry skewness, boundry kurtosis) çıkarmışlardır. Grid search ile en uygun SVM parametrelerini tespit etmiş ve RBF çekirdek fonksiyonunu kullanarak sınıflandırma işlemini tamamlamışlardır. Sonuç olarak %86.67 doğruluk oranı ve 0.90 eğri altında kalan değeri ile %85.71 keskinlik ve %96.77 duyarlılık değerleri elde etmişlerdir.

Min Chen vd. (2020), “AI-Skin: Skin Disease Recognition based on Self-learning and Wide Data Collection through a Closed Loop Framework” başlıklı çalışmalarında cilt kanseri resimlerinin mobil istemci uygulaması ile toplanması ve merkezi bir sunucuya iletilerek sunucuda evrişimsel sinir ağlarının eğitimden kullanılmasını kapsayan bir sistem önermişlerdir. Örnek olarak bir sistem kurmuşlar ve elde ettikleri veri kümesi ile LeNet, AlexNet ve VGG16 isimli sinir ağlarını ‘ince ayar’ ile eğitmişler, çıkan sonuçları karşılaştırmışlardır. Akne, leke, siyah nokta, koyu halka ve temiz yüz olmak üzere beş sınıfa göre sınıflandırma yapılan bu çalışmada AlexNet isimli evrişimsel sinir ağını kullanmanın en başarılı sonucu verdiğini tespit etmişlerdir.

Milton (2019), “Automated Skin Lesion Classification Using Ensemble of Deep Neural Networks in ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection Challenge” başlıklı çalışmasında ISIC veri kümesinden 2000 kadar resmi kesme, döndürme, ışık ayarlama gibi tekniklerle çoğaltarak kullanmış, PNASNet-5-Large, InceptionResNetV2, SENet154, InceptionV4 isimli evrişimsel sinir ağlarını ‘ince ayar’ yaparak eğitmiş ve sonuçları karşılaştırmıştır. Milton bu çalışmasında PNASNet-5-Large modeli kullanılarak 0.76 doğrulama değeri ile en iyi sonucun alındığını tespit etmiştir.

Elgamal (2013), “Automatic Skin Cancer Images Classification” başlıklı çalışmasında bir haber sitesinden elde ettiği 40 adet lezyon resmini renk düzeltme, kontrast artırma ve istenmeyen özellik silme gibi ön işleme tabi tuttukten sonra “Discrete Wavelet Transform” ile özniteliklerini çıkarmış ve “Principial Component Analysis” yöntemi ile öznitelikleri indirgeme işlemine tabi tutarak en uygun özellikleri bulmaya çalışmıştır. Daha sonra bu öznitelikleri k-Nearest neighbors (k-NN) sınıflandırıcısı ve Feedforward-Backpropagation Neural Network (FP-ANN) sınıflandırıcısı ile sınıflandırılmıştır. Çıkan sonuca göre ANN %95 doğruluk başarısı elde ederken k-NN %97.5 ile daha iyi bir sonuç göstermektedir.

Sharma ve Srivastava (2016), “Automatically Detection of Skin Cancer by Classification of Neural Network” başlıklı çalışmalarında resimlerdeki istenmeyen baloncuk veya kıl gibi artefaktları ön işlemeye tabi tutarak yok ettikten sonra lezyonu resimden ayırarak sadece lezyonun bulunduğu resimler elde etmişlerdir. “2D wavelet transform” ile resimlerin özniteliklerini elde etmişler ve bunları kullanarak iki ayrı yapay sinir ağını eğiterek sonuçları karşılaştırmışlardır. Bunlardan Auto-associative neural network (AANN) farklı gizli katman ve nöron sayıları kullanıldığında benzer sonuçlar verirken, Back-propagation neural network (BNN) ile farklı katman ve nöron sayıları kullanarak daha iyi sonuç elde edilmiştir. ANN ile elde edilen en iyi doğruluk sonucu %81.5 olurken, BNN ile %90.2’lik bir doğruluk sonucu elde edilmiştir.

Azawi ve arkadaşları (2018), “Brain Tumors Classification by Using Gray Level Co-occurrence Matrix, Genetic Algorithm and Probabilistic Neural Network” başlıklı çalışmalarında Gray Level Co-occurrence Matrix ile MRI resimlerini kullanarak beyin tümörü sınıflandırması yapmışlar ve yüksek sonuçlar elde etmişlerdir. Ön işleme aşamasında Mean filtresi ile gürültü azaltma işlemi uygulamışlardır. Gri değeri eş dizilim matrisi özniteliklerini KNN ve Genetic algoritma vasıtasıyla değerlendirip en iyi öznitelikleri tespit etmeye çalışmışlardır. Energy, Entropy, Variance, Contrast, Sum Entropy, Difference Entropy, Homogeneity, Cluster Prominence, Cluster Shade and Dissimilarity isimli gir değeri özniteliklerinin en iyi sonucu verdiğini tespit edip bunu Probabilistic Neural Network ile sınıflandırmaya tabi tutmuşlardır. 140 resim ile yapılan çalışmada en yüksek değeri 45 derecelik gri değeri eş dizilim matrisi açısıyla %100 olarak elde etmişlerdir.

Fidan vd. (2016), “Cilt Lezyonlarının YSA ile Sınıflandırılması” isimli çalışmalarında PH^2 veri kümesinden elde ettikleri 200 kadar resim ile yaptıkları çalışmada dik iniş ve Newton algoritmalarından türetilmiş olan Levenberg-Marquardt algoritmasını kullandıkları bir yapay sinir ağını Matlab kullanarak eğitmişler ve %93.33 oranında bir doğruluk sonucu elde etmişlerdir.

Senan ve Jadhav (2019), “Classification of Dermoscopy Images for Early Detection of Skin Cancer - A Review” isimli çalışmalarında dermoskopik resimler kullanılarak cilt lezyonlarının sınıflandırılması ile ilgili 40’tan fazla çalışmayı özetlemişlerdir.

Han vd. (2018), “Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm” başlıklı çalışmalarında Asan,

Med-Node ve Atlas veri kümelerinden elde edilen 19398 kullanarak ResNet-152 modelini 12 çeşit (basal cell carcinoma, squamous cell carcinoma, intraepithelial carcinoma, actinic keratosis, seborrheic keratosis, malignant melanoma, melanocytic nevus, lentigo, pyogenic granuloma, hemangioma, dermatofibroma, wart) hastalığı tanımak üzere ‘ince ayar’ ile eğitmişlerdir. Çalışmada kullanılan resimler uzman dermatologlar tarafından lezyon sınırlarına göre kırılmış ve veri çoklama yöntemiyle çoğaltılarak 855370 adet örnek elde edilmiştir. Model eğitildikten sonra Edinburgh, Hallym ve Asan veri kümesinden ayrılmış olan test kümesiyle test edilmiştir. Asan veri kümesi testinde eğri altında kalan alan basal cell carcinoma, squamous cell carcinoma, intraepithelial carcinoma ve melanoma için sırasıyla 0.96, 0.83, 0.82 ve 0.96 olarak elde edilmiştir. Edinburgh veri kümesi testinde ise aynı sınıflar için eğri altında kalan alan 0.90, 0.91, 0.83, 0.88 olarak tespit edilmiştir. Hallym veri kümesi testinde basal cell carcinoma teşhisinde duyarlılık %87.1 olarak tespit edilmiştir. Çalışma her bir resim için 12 sınıflandırma ihtimali elde edilecek şekilde yapılmış ve belirlenen bir eşik değerinin altında kalan sınıflandırma sonuçları ihmal edilmiştir. Modelin en yüksek ihtimali hesapladığı etiketin doğru olma oranı (Top-1 accuracy) Asan test kümesinde 57.3, Edinburgh test kümesinde 55.7 olmuştur. Test sonuçları 16 dermatolog, 6 klinisyen ve 10 profesör tarafından konulan teşhisler ile karşılaştırılmış ve elde edilen modelin 12 çeşit hastalığı sınıflandırmada 16 dermatolog ile yarışacak düzeyde olduğu tespit edilmiştir.

Jain vd. (2015), “Computer aided Melanoma skin cancer detection using Image Processing” başlıklı çalışmalarında makine öğrenmesi teknikleri kullanmamışlar, görüntü işleme teknikleri kullanarak tanıma işlemi yapmışlardır. Öngörülen sistem resmin boyutunu ayarladıktan sonra en büyük parçayı bularak lezyonu resmin geri kalanından ayırır. Sonra ABCD kuralına göre öznitelikleri çıkarır. Buradan elde edilen özelliklerden elde edilen parametreleri daha önceden belirlenmiş değerlerle karşılaştırarak sınıflandırır. Lezyon çıkarma işleminden sonra elde edilen resimde lezyonun toplam piksel sayısı, alan özniteliğini (A), kenar piksellerin sayısı lezyonun çevresini ifade eden özniteliği (P), lezyonun orta noktasından geçen ve iki en uzak ucu birleştiren çizginin uzunluğu en uzun çap özniteliğini (GD), lezyonun orta noktasından geçen ve en yakın iki ucu birleştiren çizginin uzunluğu en kısa çap özniteliğini (SD) ifade etmek üzere bu özelliklerden elde edilen parametreler şunlardır: Dairesellik = $4A\pi/P^2A$, Düzensizlik A = P/A , Düzensizlik B = P/GD , Düzensizlik C = $Px(1/$

$SD - 1/GD$), Düzensizlik $D = GD - SD$. Öngörülen sistemin başarı oranı çalışmada değerlendirilmemiştir.

Yalçın (2015), “Characterization of Melanomas Using a Variety of Features” başlıklı çalışmasında lezyonların simetriklik özelliği için birtakım öznitelikler önermektedir. Aktif kontur modeli yöntemi ile lezyonun sınırları ve kontur düzensizliği özneliğini, Hu momentleri (Hu), Eliptik Fourier Tanımlayıcıları (EFD), Işınsal Uzaklık Fonksiyonu (IUF) ve Jaccard Benzerlik Katsayısı (JBK) kullanarak simetri ile ilgili öznitelikleri önermektedir. Bu öznitelikler PH^2 veri seti üzerinde denenmiş ve simetri açısından kullanılan fonksiyonların sonuçları karşılaştırılmıştır.

Gavrilov vd. (2019), “Deep Learning Based Skin Lesions Diagnosis” başlıklı çalışmalarında ISIC veri setinden alınan 10000 resim 1000000 tane olacak şekilde çeşitlendirerek ImageNet isimli evrişimsel sinir ağını ve farklı ağırlık parametreleri kullanarak 5 yeni ağ eğitmişlerdir. Daha iyi bir sonuç alabilmek için InceptionV3 modelinin 700x700 boyutlarında resim ile çalışması sağlanmıştır. Sonuç olarak %85 duyarlılık, %92 özgüllük ve %91 doğruluk elde edilmiştir.

Brinker vd. (2019), “Deep learning outperformed 136 of 157 dermatologists in a head-to-head dermoscopic melanoma image classification task” başlıklı çalışmalarında ISIC veri setinden rastgele seçtikleri 80 atipik nevi ve 20 melanom resminin Almanya’da bulunan 12 üniversite hastanesinden 175 doktor tarafından elektronik ortamda sınıflandırılmasını sağlamışlardır. Elektronik ortamda verilen özensiz cevaplar “local outlier factor” metodu ile elendikten sonra 157 doktorun verdiği cevaplar dikkate alınmıştır. ResNET50 isimli evrişimsel sinir ağı 1888 melanom ve 10490 atipik nevi resmi ile eğitilmiştir. Doğrulama için 210 melanom ve 1049 atipik nevi resmine ek olarak doktorlar tarafından sınıflandırılmış olan resimler de kullanılmıştır. ‘Youden index’ ile yapılan karşılaştırma sonucunda sadece 7 doktor evrişimsel sinir ağını ‘geçmeyi’ başarmıştır. Bu çalışmanın başlığı biraz saldırgan görünmekle beraber derin öğrenme ile yapılan tanıma işleminin gerçek hayattaki başarısını ortaya koyması bakımından burada yer almaktadır. Bizim çalışmamızın amacı kıymetli hekimlerimizi ‘geçmek’ değil onlara yardımcı olacak bir model geliştirmektir.

Esteva vd. (2017), “Dermatologist-level classification of skin cancer with deep neural networks” başlıklı çalışmalarında 2032 farklı hastalığa ait 129450 adet klinik resim, 3374 dermoskopik resim kullanmış ve sistemin başarısını 21 cilt uzmanı ile

karşılaştırmışlardır. İki ayrı karşılaştırma durumu oluşturulmuştur. Bunlardan ilki ‘keratinocyte carcinoma’ ve ‘benign seborrheic keratosis’ arasında diğeri ‘malignant melanoma’ ve ‘benign nevi’ arasında yapılmıştır. İlk durum en çok karşılaşılan kanser türlerini ikincisi en ölümcül kanser türünü temsil etmektedir. Inception v3 kullanılarak eğitilen evrişimsel sinir ağının iki durumda da özgüllük ve duyarlılık değerleri bakımından 21 uzmanı geçtiği gösterilmiştir. Çalışmada eğitilen evrişimsel sinir ağının iç durumu t-SEN kullanılarak görselleştirilmiştir. ISIC ve Edinburgh veri kümeleri ile Stanford Üniversitesinden izinli olarak alınan veri kümesi kullanılmıştır. Çalışmada kullanılan CNN 757 sınıf üzerinden eğitilmiştir. Örneğin melanom hastalığının alt sınıfları olan Amelanotic melanom ve Lentigo melanom ayrı birer sınıf olarak ele alınmış, sınıflandırma sonucunda bu gibi alt sınıfların ihtimalleri toplanarak üst sınıf olan melanom sınıfına ait olan sınıflandırma ihtimali elde edilmiştir. 9-kat çapraz doğrulama işlemi uygulanarak yapılan çalışmada 3 sınıf, 9 sınıf ve 757 sınıflı eğitim işlemi yapılmıştır. 3 sınıflı olanda CNN 0.72 doğruluk oranını yakalarken 9 sınıflı olan işlemde CNN 0.55’lik bir oranı yakalamıştır. 757 sınıflı işlemin sonucu ise verilmemiş fakat diğer ikisinden daha iyi olduğu belirtilmiştir. Sonuçlar 21 dermatolog ile yapılan çalışmayla karşılaştırılmış ve ortalama olarak eğitilen CNN’in dermatologlardan daha iyi sonuç verdiği gösterilmiştir.

Tschandl vd. (2020) “Human-computer collaboration for skin cancer recognition” başlıklı çalışmalarında COVID-19 pandemisi sebebiyle sağlık kuruluşlarına fiziksel erişimin kısıtlı olmasına dikkat çekmişler ve uzaktan sağlık erişimi uygulamalarında yapay zeka destekli insan-bilgisayar iş birliğinin fırsatlarını ve risklerini araştırmışlardır. Bunun için ISIC veri kümesini kullanarak yedi ayrı cilt lezyonunu tanımak üzere (melanoma, basal cell carcinoma, actinic keratose, intraepithelial carcinoma, melanocytic nevi, benign keratinocytic lezyonlar, dermatofibroma, vascular lezyonlar) ResNet-34 tabanlı bir model eğitmişlerdir. Bu modelin test kümesi üzerinde duyarlılığının %77.7, doğruluğunun ise %80.3 olduğunu tespit etmişlerdir. Bu modelin uzmanları etkileyip etkilemediğini araştırmak üzere CNN’den gelen üç çeşit çıktıyı karar destek amacıyla uzmanlara sunan bir web arayüzü geliştirmişlerdir. Birinci çıktı CNN’den elde edilen çoklu sınıflandırma sonuçları olurken ikinci çıktı ise malign ve benign ihtimalidir. Üçüncü olarak uzmanlara o anda değerlendirdikleri lezyona benzeyen lezyonları ve ilgili teşhisi gösteren bir resim arama motoru sunmuşlardır. Ayrıca daha önceden 511 uzman tarafından konulan tanıları içeren çok

sınıflı ihtimaller de uzmanlara gösterilmiştir. 41 ülkeden 302 katılımcıyla yapılan çalışmada uzmanlardan bir kısım lezyonları önce karar destek olmadan daha sonra ise bir karar destek seçeneğinin yardımıyla sınıflandırmaları istenmiştir. Sonuç olarak yapay zeka destekli (CNN) çoklu sınıflandırma sonuçlarının uzmanların kararlarını %63.6 dan %77'ye yükselttiği gözlenmiştir. İkili sınıflandırma ihtimalleri desteğinin veya benzer lezyon sunma sisteminin iyileştirme sağlamadığı gözlenmiştir. Buradan sunulan karar destek sisteminin çözülmek istenen soruna göre seçilmesi gerektiğinin anlaşıldığı belirtilmiştir. Benzer lezyon görüntüleme sisteminin diğerlerine göre daha fazla zaman aldığı ve uzmanların bir müddet sonra bu sistemi kullanmadığı gözlemlenmiştir. Çok sınıflı ihtimal sunma desteğinin en iyi yöntem olduğunu tespit ettikten sonra yazarlar bu sistemi daha fazla araştırmak üzere bu konuya eğilmişler ve deneyimi az olan uzmanların deneyimi daha fazla olanlara göre ilk teşhislerini değiştirmeye daha yatkın olduklarını gözlemlemişlerdir. Deneyimli uzmanlar daha az sayıda ve eğer tam olarak emin değillerse ilk teşhislerini değiştirmişlerdir. Deneyimi az olan uzmanların ise CNN'den elde edilen ilk üç teşhise uymayan teşhislerini değiştirmeye daha fazla yakın oldukları gözlenmiştir. Yazarlar bu aşamada 'kusurlu yapay zeka'nın (eğitildiği alanda kullanılmayan yapay zeka veya bir saldırı durumu) etkisini araştırmak üzere CNN'den gelen sonuçları bilerek bozup uzmanlara göstermişlerdir. Bu durumda yapay zeka destek sisteminin getirdiği faydanın bir zarara dönüştüğü ve uzmanlık seviyesi fark etmeksizin daha kötü sonuçlar elde edildiği gözlenmiştir. Ayrıca çalışmada olumlu etkinin hastalık sınıfına göre ve uzman doktorun kararını değiştirme yatkınlığına bağlı olduğu tespit edilmiştir. Ayrıca çok sınıflı ihtimal desteğinin ve diğer hekimlerin teşhisleri desteğinin (crowd wisdom) doğru teşhis oranını gözle görülür oranda artırdığı tespit edilmiştir.

Mishra vd. (2019), "Interpreting Fine-Grained Dermatological Classification by Deep Learning" başlıklı çalışmalarında Asya kökenli kişilerin cilt hastalıklarının sınıflandırılması hususuna eğilmişlerdir. ResNet-34, ResNet-50, ResNet-101 ve ResNet-152 evrimsel sinir ağlarını kullanarak 10 ayrı cilt hastalığını sınıflandırdıkları bu çalışmada elde edilen doğruluk oranı her bir ağ için %88.9 ile %89.8 arasında değişiklik göstermektedir. Çalışmada kullanılan resimler gönüllülerden ve hastanelerden toplanmış ve uzmanlar tarafından etiketlenmiştir. Doğum lekesi, yara izi, dövme gibi izler bulunan resimler çalışmaya dahil edilmemiştir. 7264 adet resim on sınıf bölünmüş ve %20'lik bir kısmı doğrulama için

ayrılmıştır. Dinamik resim çoklama işlemi uygulanarak kaynak resim sayısı artırılmıştır. Çalışma sırasında ‘learning rate’ optimizasyonuna odaklanılmıştır. ‘İnce ayar’ yapılan birçok çalışmada olduğu gibi ilk devirlerde öğrenme aktarımı yapılan katmanlar dondurulmuş ilerleyen devirlerde açılarak modelin alt katmanlarındaki ağırlıkların değişmesine izin verilmiştir.

Menegola vd. (2017), “Knowledge Transfer for Melanoma Screening with Deep Learning” başlıklı çalışmalarında öğrenme aktarma yönteminin cilt kanseri tanıma örneği üzerinde etkisini incelemişlerdir. Bunun için ATLAS ve ISIC cilt lezyonları veri kümelerinin yanı sıra retina resimlerinden oluşan Kaggle Retinopathy veri kümesi de kullanılmıştır. Burada amaç öğrenme aktarma yönteminde farklı tıbbi alanlardan gelen resimlerin etkisini incelemektir. VGG-16 ve VGG-M evrimsel sinir ağıları dermoskopik resimler ve retinopati resimleri ile hem sıfırdan hem ‘ince ayar’ ile hem ikisi bir arada hem de ayrı ayrı eğitilmiştir. Sonuç olarak dermoskopik resimler ile ‘ince ayar’ yapılarak eğitilen VGG16 temelli evrimsel sinir ağı %83.8 AUC (Area under curve, alıcı çalışma karakteristiği eğrisinin altında kalan alan) değeri ile en iyi sonucu vermiştir. Retinopati resimleri ile yapılan öğrenme aktarma işleminin sonucu verimli olmamıştır. Bizim çalışmamızda bulunan modellerden biri bu çalışmadaki model ile benzerlik göstermektedir ancak modelimiz %87 AUC değeri ile daha iyi bir sonuç elde etmiştir.

Haenssle vd. (2018), “Man against machine diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists” başlıklı çalışmalarında InceptionV4 modelini Tensorflow kullanarak çalışmaya katılan dermatologlardan ve ISIC veri kümesinden elde edilen resimlerle benign ve malign sınıflarını tanımak üzere eğitmişlerdir. Çalışmada kullanılan eğitim kümesi dengesiz olduğu için sınıflar arasındaki dengesizliği malign sınıf üzerinde rastgele çoğaltma işlemi uygulayarak çözmüşlerdir. Heidelberg Üniversitesinden elde ettikleri resimlerle 100 ve 300 resimden oluşan iki ayrı test kümesi oluşturmuşlardır. Bu test kümeleri üzerinde CNN ile elde ettikleri sınıflandırma sonuçlarını 58 dermatolog ile karşılaştırmışlardır. Dermatologlar çalışmaya email ile davet edilmiş ve internet üzerinden katılmışlardır. Katılımcılardan 17 dermatolog 2 yıldan daha az tecrübeye sahipken 11 tanesi 2 ila 5 yıl arasında tecrübeye sahip olduğunu, 30 tanesi ise 5 yıldan daha fazla tecrübeye sahip olduğunu bildirmiştir. Karşılaştırma iki aşamalı olarak yapılmıştır. Birinci aşamada

dermatologlara sadece dermoskopik resimler verilerek, ikinci aşamada ise dermoskopik resimlerle birlikte klinik bilgiler de verilerek teşhisleri sorulmuştur. Sonuç olarak ilk aşama test sırasında dermatologların ‘duyarlılık’ değerinin en yüksek olduğu %86.6 karşılaştırma noktası olarak kabul edildiğinde o noktadaki CNN’in ‘özgüllüğü’nün (%82.5) dermatologların ‘özgüllüğü’nden daha yüksek olduğu görülmüştür. Ayrıca alıcı çalışma karakteristiği eğrisinin altında kalan alan CNN’de 0.86 olurken dermatologlarda 0.79 olmuştur. İkinci aşama testte ise dermatologlar daha fazla klinik bilgi aldıklarında daha iyi performans göstermişlerdir. Bu testte dermatologların ortalama ‘duyarlılığı’ olan %88.9 karşılaştırma noktası olarak alındığında ise CNN’in ‘özgüllüğü’ %82.5 olurken dermatologların ortalama ‘özgüllüğü’ ise 75.7 olarak belirlenmiştir. Yine eğri altında kalan alan karşılaştırmasında CNN 0.86 değerine ulaşırken dermatologlar 0.82 değerine ulaşmıştır. Bu çalışmada geliştirilmiş olan CNN ayrıca ISIC yarışmasında kullanılan bir başka test kümesi üzerinde uygulandığında AUC değeri olarak 0.79 elde edilmiştir.

Yıldız (2019), “Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study” başlıklı çalışmasında ISIC veri kümesinden elde ettiği 3920 resim ile yaptığı çalışmada kendi önerdiği CNN ile AlexNet, ResNet, GoogLeNet ve VGGNet ile KNN ve SVM’i karşılaştırmıştır. KNN ve SVM’de sınıflandırma için gri değeri eş dizilim matrisi değerlerini kullanırken CNN’ler için resimlerin ham piksel değerlerini kullanmıştır. Çalışmasında 10 kat çapraz doğrulama tekniğini kullanarak kendi önerdiği CNN modelinin diğer modellerden daha iyi sonuçlar elde ettiğini göstermiştir.

Yap vd. (2018) “Multimodal skin lesion classification using deep learning” başlıklı makalelerinde her bir lezyon için dermoskopik ve makroskopik resimlerin özniteliklerini ResNet50 kullanarak elde etmişler ve bunlara yaş, cinsiyet gibi meta özniteliklerini eklemişlerdir. Çalışmaya en az 100 örneği bulunan sınıflar dahil edilmiştir. Çalışmayı etkileyebilecek örneğin yüzük, kolye, yara izi vesaire gibi etkenleri içeren resimleri dahil etmemişlerdir. Çalışmayı 2917 resimden ve 5 sınıftan oluşan bir veri kümesi ile yapmışlardır. Her bir lezyon için ResNet 50’den elde edilen öznitelik sayısı dermoskopik ve makroskopik resimler için 2048’er tane olmak üzere ve meta verisi olarak da 11 öznitelik eklendiğinde 4107 uzunluğunda bir dizi elde edilmiş ve 5 sınıf olacak şekilde sınıflandırılmıştır. Sınıflandırma 3 ayrı şekilde yapılmıştır. Birinci durumda yukarıda geçen öznitelikler iki katmanlı 1024

uzunluğunda 'Fully connected' katman kullanılarak sınıflandırılmıştır, ikinci durumda bu katman eklenmeden sınıflandırılmıştır, üçüncü durumda ise sadece meta öznitelikleri CNN kullanmadan Random Forest sınıflandırıcısı ile sınıflandırılmıştır. Sonuç olarak dermoskopik resimlerin yanı sıra makroskopik resimleri de kullanmanın doğruluk payını artırdığı fakat meta verilerini de eklemenin çok büyük etkisi olmadığı görülmüştür. En iyi sonuç ise 0.88 ile 'Fully Connected' katmanların eklendiği versiyonla elde edilmiştir.

Hajabdollahi vd. (2020), "Multiple Abnormality Detection for Automatic Medical Image Diagnosis Using Bifurcated Convolutional Neural Network" başlıklı çalışmalarında endoskopi ve dermoskopi resimleri üzerinde çalışan bir 'çatal' sinir ağı örneği önermişlerdir. İlk aşamada iki sinir ağı ayrı ayrı eğitilmiş, ikinci aşamada ortak olan kısımlar birlikte kullanılacak şekilde sinir ağları birleştirilmiştir. Böylece bazı network özelliklerinin ortak kullanılması sağlanmıştır. PH² veri kümesi kullanılarak yüksek sonuçlar elde edilmiştir.

Ly vd. (2018), "New Compact Deep Learning Model for Skin Cancer Recognition" başlıklı çalışmalarında büyük evrimsel sinir ağları küçük ve dengesiz veri kümelerinde 'overfitting' sorununa yol açar düşüncesiyle ve mobil cihazlarda da kullanılabilir diye küçük bir sinir ağı ve dengeli bir veri kümesi kullanılmıştır. Genel olarak yapılan çalışmalarda 'benign' deri kanseri resimleri fazla kullanıldığı için 'benign' sonucuna doğru kayma oluyor tespitinde bulunmuşlardır. ISIC, Dermnet NZ, MED-NODE ve PH² veri kümelerinden benign ve malign eşit sayıda olmak üzere 20 binden fazla örnek seçilmiş ve resimler 40 kata kadar çoklanmıştır. Elde edilen veri kümesi ile dört ayrı evrimsel sinir ağı eğitilmiş ve %86 oranında bir doğruluk elde edilmiştir.

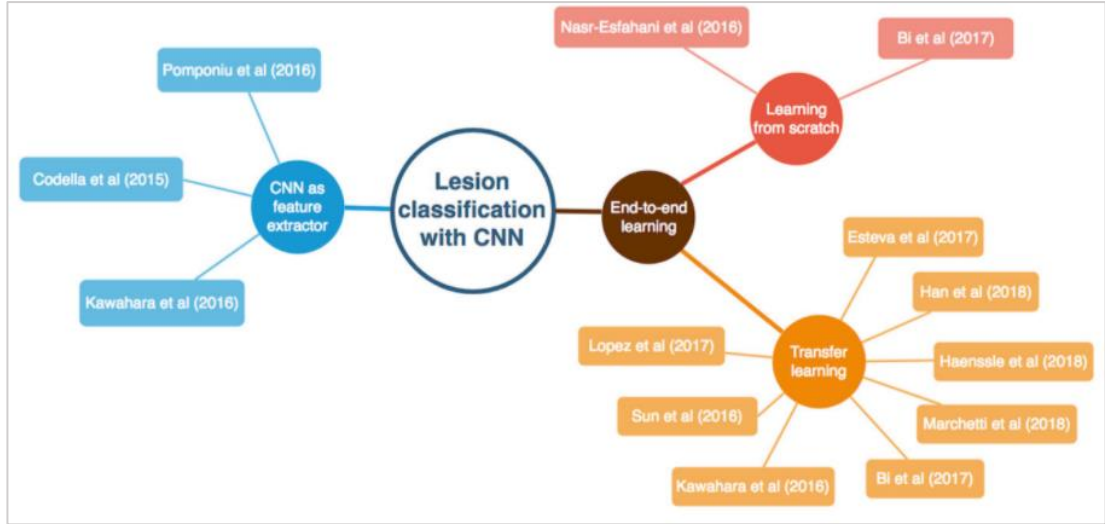
Masood vd. (2015), "Self-supervised learning model for skin cancer diagnosis" başlıklı çalışmalarında Royal Prince Alfred hastanesi Sydney Melanoma tanı merkezinden elde ettikleri 290 adet resmi kullanmışlardır. Resimler 'adaptive median filter' ile temizlenmiş ve 'Histogram based fuzzy C Means' yöntemi ile lezyonlar çıkarılmıştır. 'Autoregressive modeling', 'Gray Level Co-occurrence Matrix' (gri değeri eş dizilim matrisi) ve 'Fuzzy-Mutual Information based Wavelet packet Transform' yöntemleri ile öznitelikleri elde edilmiştir. Bu veri kümesi etiketli ve etiketsiz olmak üzere ikiye bölünmüş ve bu küme ile iki ayrı SVM ve bir adet DBN (Deep belief network) eğitilmiştir. Bunlardan elde edilen sonuçlar 'least square

estimation weighting' kullanılarak birleştirilmiştir. Sonuç olarak %89 oranında doğruluk elde edilmiştir.

Lopez vd. (2017), "Skin Lesion Classification From Dermoscopic Images Using Deep Learning Techniques" başlıklı çalışmalarında ISIC veri kümesinden elde ettikleri 346 adet resmi kullanarak çoklrama işlemi ile çoğalttıktan sonra VGG16 modelini üç farklı şekilde (sıfırdan, öğrenme aktarımıyla, ince ayarla) eğitmişlerdir. Test için aynı veri kümesinden elde edilen 150 adet resim kullanmışlardır. Kütüphane olarak Keras ve Theano kullanmışlardır. Rmsprop optimizasyon algoritmasını tercih etmişlerdir. Sonuç olarak sıfırdan eğitim yapıldığında %66, öğrenme aktarma işlemi uygulandığında %68.67 ve son olarak 'ince ayar' ile eğitim yapıldığında ise %81.33 oranında doğruluk değeri elde edilmiştir. En yüksek doğruluk oranının olduğu modelde duyarlılık 0.79 keskinlik ise 0.80 olmuştur.

Brinker vd. (2018), "Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review" başlıklı çalışmalarında evrimsel sinir ağı kullanarak cilt kanseri tanıma işlemi konusunda yapılan çalışmaları incelemişlerdir. İncelenmiş olan çalışmaların bazıları kullandıkları yöntemlere göre sınıflandırılarak **Şekil 4.1**'de gösterilmiştir.

Bizim çalışmamızda Brinker vd. (2018)'nin diğer çalışmaları sınıflandırmak için kullandığı üç yöntem de yer almaktadır. Çalışmamızda CNN'den elde edilen özniteliklerin sınıflandırılması (Cnn as feature extractor) yönteminde InceptionV3 ve VGG16 öznitelikleri kullanılmıştır. Bu öznitelikler CNN, LSTM, RNN, KNN ve SVM ile sınıflandırılmıştır. Ayrıca bu öznitelikler gri değeri eş dizilim matrisi öznitelikleri ile birleştirilerek de sınıflandırılmıştır. Learning from scratch yönteminde resim piksel değerleri öznitelik olarak kullanılmış ve sıfırdan bir CNN oluşturulmuştur. Transfer learning yönteminde VGG16 ve InceptionV3 modelleri ile transfer learning işlemi hem fine tuning ile hem fine tuning olmadan uygulanmıştır. Bunlara ek olarak gri değeri eş dizilim matrisi öznitelikleri CNN, LSTM, RNN, KNN ve SVM ile sınıflandırılmıştır.



Şekil 4.1: Brinker ve arkadaşlarının incelediği çalışmalardan bir kısmının kullandıkları yönteme göre şema üzerinde gösterimi

Kaynak: (Brinker, vd., 2018)

Chaturvedi vd. (2020), “Skin Lesion Analyser: An Efficient Seven-Way Multi-Class Skin Cancer Classification Using MobileNet” isimli çalışmalarında HAM10000 veri kümesini kullanılmışlardır. Resimler çoklanarak 7 ayrı cilt lezyonu sınıflandırılmış ve %83’ün üzerinde sınıfsal doğruluk elde edilmiştir.

Pacheco ve Krohling (2020), “The Impact Of Patient Clinical Information On Automated Skin Cancer Detection” başlıklı çalışmalarında Espirito Santo Üniversitesi dermatoloji doktorları ve asistanları tarafından kullanılmak üzere bir mobil uygulama yapmışlar ve bu uygulama ile elde ettikleri 1612 resimden oluşan veri kümesini kullanmışlardır. GoogleNet, ResNet50/101, VGGNet13 ve MobileNet kullanarak iki ayrı senaryo koşmuşlardır. Birincisinde sadece resimler üzerinden işlem yaparken ikincisinde ise hastanın klinik bilgilerini de eğitime dahil etmişlerdir. İkinci senaryonun %7 iyileşme sağladığı tespit edilmiştir. Ayrıca ResNet50 modeli diğer modellere göre %4 daha iyi sonuç vermiştir.

4.2.Sonuç

Bu bölümde genel olarak medikal görüntüleme ve özelde cilt kanseri sınıflandırma konusunda makine öğrenmesi yöntemleri kullanılarak yapılmış olan çalışmalarını gözden geçirmeye çalıştık. Daha çok ilgili çalışmada hangi veri kümesi ile hangi

yöntem kullanıldığı ve hangi değerlendirme kriterine göre ne sonuç elde edildiğini tespit ederek çalışmanın özetini aktardık. Bizim çalışmamızın yöntemi, veri kümesi ve değerlendirme kriterlerini ise bir sonraki bölümde ele alacağız.



BEŞİNCİ BÖLÜM

ARAŞTIRMA YÖNTEMİ

Bu bölümde çalışmamızda kullandığımız veri kaynağını, örnekleme, veri toplama yöntemini, çalışmanın yöntemini, bu çalışmada kullanılan yazılımları, kütüphaneleri, çalışmanın yapıldığı makine öğrenmesi için tasarlanmış donanımı ve sınıflandırıcılardan elde edilen test sonuçlarını değerlendirmek için kullandığımız değerlendirme kriterlerini açıklamaya çalışacağız.

5.1.Amaç ve Model

Bu çalışmada ISIC veri kümesi içerisinde lezyon sınırları uzmanlarca işaretlenmiş ve en az derecede yanlılığa sahip olduğu için seçilen MSK veri kümesi kullanılarak malign melanom cilt kanserlerini tanımak için bir veya daha fazla model geliştirilmesi ve resimlerin lezyon sınırlarına göre kırılmasının bu modeller üzerindeki etkisinin değerlendirilmesi amaçlanmaktadır. Çalışma sonunda elde edilen modellerin malign melanom cilt kanserlerini teşhis etme aşamasında cilt hastalıkları uzmanlarına destek olabilecek seviyede olması planlanmaktadır. Bu alanda çeşitli çalışmalar bulunmakla birlikte ülkemizde sadece dermoskopik resimleri girdi olarak kabul eden çalışmaların yeterince bulunmadığını düşünmekteyiz. Bu çalışma ile lezyon veya hasta ile ilgili herhangi bir başka bilgiyi girmeden sadece dermoskopik resim girdisi ile yüksek oranda doğru teşhis yönlendirmesi yapılabilmesi planlanmaktadır. Değerlendirme kriterlerine göre öne çıkan modellerin uygulama olarak uzmanların kullanımına sunulması düşünülmektedir. Bu uygulama ile cilt hastalıkları uzmanlarına karar destek aşamasında yardımcı olunabilecektir. Çalışmamızda diğer yandan çeşitli algoritmalar ve öznitelikler birbirleri ile karşılaştırmalı olarak ele alınacaktır. Okuyucu bu sayede ilgili modelin kendi çalışmasında faydalı olup olmayacağına dair fikir sahibi olacaktır. Böylece bu çalışma aynı zamanda tıbbi tanılamada yapay zeka, derin öğrenme ve makine öğrenmesi kullanarak yapılacak sonraki çalışmalara yol gösterici bir doküman olma niteliği de taşıyacaktır.

Çalışmada dermoskopik lezyon resimlerinden elde edilen evrişimsel sinir ağı öznitelikleri, gri seviyesi eş dizilim matrisi (Haralick) öznitelikleri ve ham resim öznitelikleri kullanılarak sınıflandırma işlemi yapılmaktadır. Evrişimsel sinir ağlarını

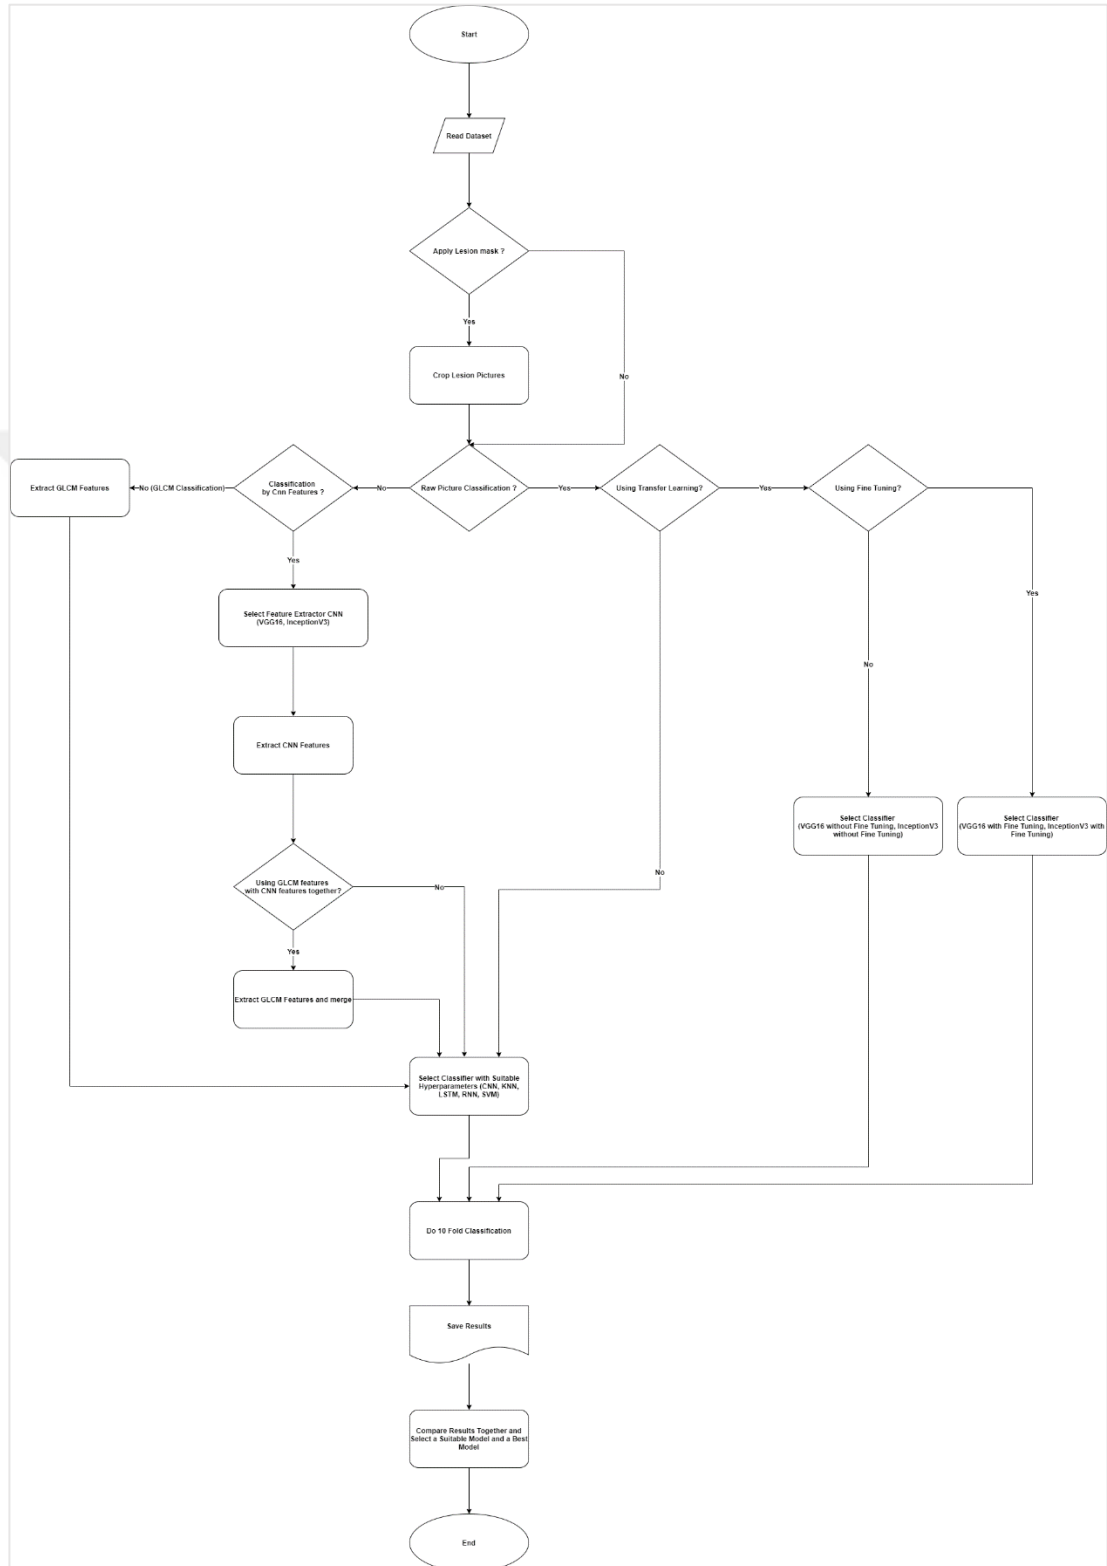
oluşturan iki parçadan biri olan öznitelik çıkarıcı ile elde edilen özniteliklerin bu çalışmada kullanılmasını tercih etmemizin bir sebebi öğrenme aktarımını doğrulamak diğer bir sebebi ise bu özniteliklerin diğer sınıflandırıcılar ile kullanılabilir olup olmadığını araştırmaktır. İstatistiksel öznitelikler sınıfına dahil olan gri değeri eş dizilim matrisi özniteliklerini kullanmak istememizin sebebi ise bu öznitelik çeşidinin melanom sınıflandırma işleminde literatürde yer aldığı derecede faydalı olup olmadığını ve diğer özniteliklerle birlikte kullanıldığında katkı sağlayıp sağlamayacağını araştırmaktır. Ham resim öznitelikleri dediğimizde ise dermoskopik resimler kastedilmektedir. Bu öznitelik çeşidini kullanmak istememizin sebebi ise lezyon veya hasta ile ilgili olarak, örneğin hastanın yaşı, lezyonun boyutları, lezyonun rengi gibi bir bilgi girişi yapmadan sadece görsel girdi kullanarak tanılama yapabilecek bir model elde etmeye çalışmaktır.

Çalışmada yukarıdaki öznitelikler, resimlerden hem lezyon sınırlarına göre kırılarak hem de kırılmadan elde edilerek ve CNN, RNN, SVM, KNN ve LSTM sınıflandırıcıları ile 10 kat çapraz doğrulama yöntemi kullanılarak sınıflandırılmaktadır. Gri seviyesi eş dizilim matrisi ile evrimsel sinir ağı öznitelikleri ayrıca bir arada kullanılarak da sınıflandırmaya tabi tutulmakta ve gri seviyesi eş dizilim matrisi özniteliklerinin evrimsel sinir ağı özniteliklerine olumlu etkisi olup olmadığı incelenmektedir. Çalışmamızda CNN sınıflandırıcısı, ham resim sınıflandırma işleminde son yıllarda CNN ile elde edilen başarıları dikkate alarak tercih edilmiştir. RNN ve LSTM sınıflandırıcıları lezyon resimlerinde sıralı olarak yer alan örüntüleri yakalayabilmek için tercih edilmiştir. KNN ve SVM sınıflandırıcıları ise gri değeri eş dizilim matrisi ve evrimsel sinir ağı özniteliklerini sınıflandırma işlemi için tercih edilmiştir. Bununla birlikte kullanılması mümkün olan her öznitelik sınıflandırıcı çifti kullanılmıştır. Uygulanan yöntem **Şekil 5.1**'de, uygulanan algoritma **Algoritma 5.1**'de gösterilmektedir, uygulanan kırma yöntemi ise **Tablo 5.1**'de gösterilmektedir. Bu amaçla çalışmanın ilk aşamasında lezyon resimlerini ve maskelerini elde etmek için bazı araçlar kullanılmıştır. Veri kümesi elde edildikten sonra Anaconda arayüzü kullanılarak ilgili kodlar yazılmış ve Keras kütüphanesi aracılığıyla Tensorflow makine öğrenmesi kütüphanesi yardımı ile sınıflandırma işlemi yapılmıştır. Her bir öznitelik ve sınıflandırıcı çifti için ayrı bir model oluşturulmuş ve hiper parametreler aranmıştır. Hiper parametrelerin bulunmasında Grid Search yönteminden de faydalanılmıştır. Gerekli olduğu noktada modellerde

değişiklikler yapılarak en iyi doğruluk değeri aranmıştır. Örneğin resim ham piksel özniteliklerine göre sınıflandırılırken kullanılan ‘VGG16 öğrenme aktarımı modeli’ ile ‘InceptionV3 öğrenme aktarımı modeli’ birbirinden farklı modellerdir. KNN ve SVM gibi bazı modellerin hiper parametreleri için ise bütün sınıflandırma işlemlerinde aynı değerler kullanılmıştır. CNN modelleri üç boyutlu girdi kabul ederken RNN ve LSTM modelleri iki boyutlu, KNN ve SVM modelleri ise tek boyutlu girdi kabul etmekte olduğundan öznitelik girdilerinin boyutları modele göre uyarlanmıştır. Gri seviyesi eş dizilim matrisi öznitelikleri ile evrimsel sinir ağı öznitelikleri bir arada sınıflandırılırken CNN, LSTM ve RNN modellerinde iki ayrı alt ağ oluşturulmuş ve tam bağlı katmandan önce birleştirilmiştir. KNN ve SVM ile sınıflandırırken ise öznitelikler önceden birleştirilerek veri girişi yapılmıştır. Her eğitim aşamasında model eğitildikten sonra çapraz doğrulama için ayrılan sağlama kümesi üzerinde uygulanarak elde edilen tahmin sonuçları ve test kümesi etiketleri kayıt altına alınmıştır. Bu aşamada KNN ve SVM tek aşamada tek bir sonuç ve model üretirken CNN, LSTM ve RNN ise her devir sonrasında bir sonuç ve model üretmektedir. Çalışmamızda derin öğrenme modelleri 50 devir boyunca eğitilmiştir ve en yüksek doğruluk değerinin üretildiği devire ait olan model ve sonuçları kayıt altına alınmıştır. Böylece 10 kat çapraz doğrulama için her seferinde 10 modelden elde edilen sonuçlar kayıt altına alınmış olmakla birlikte bunların en yüksek doğruluk değerine göre kayıt altına alındığını, söz gelimi en yüksek eğri altında kalan alan değerini üreten modelin belki görmezden gelindiğini bilmek faydalı olacaktır. Eğitimler sonunda bütün test sonuçları karşılaştırılarak en yüksek doğruluk değerini alan modellerin elde ettiği sonuçlarla çalışma tamamlanmıştır. Çalışma sonucunda elde edilen değerler plot yöntemi ile görselleştirilmiştir. Bütün modellerin hata matrisi, kesinlik duyarlılık eğrisi, alıcı çalışma karakteristiği eğrisi plotları çizilmiştir. KNN ve SVM’de eğitim devirlerden oluşmadığı için eğitim aşamasında doğruluk, sağlama aşamasında doğruluk, eğitim aşamasında kayıp, sağlama aşamasında kayıp plotları CNN, LSTM ve RNN için çizilmiştir.

Uygulanan yöntemin daha iyi anlaşılması açısından lezyon resimlerinin elde edilmesinde kullanılan araçlar, sınıflandırma için kullanılan programlar ve elde edilen sonuçları değerlendirmek için kullanılan kriterleri bu bölümde ayrıntılı olarak incelemeye devam edeceğiz. Oluşturulan modellerde kullanılan hiper parametreleri ve sınıflandırma sonucunda elde edilen doğruluk, fl puanı, eğri altında kalan alan,

ortalama kesinlik gibi deęerleri bir sonraki bölümde karşılaştırmalı olarak deęerlendireceęiz.

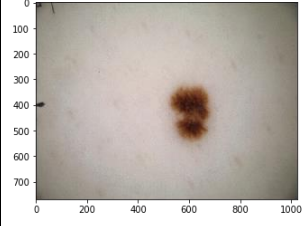
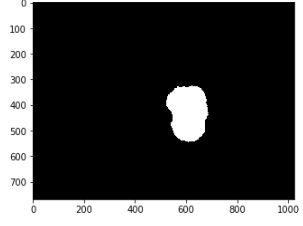
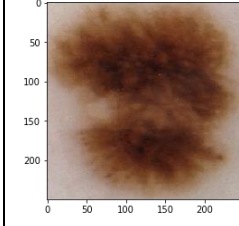
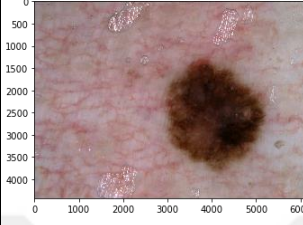
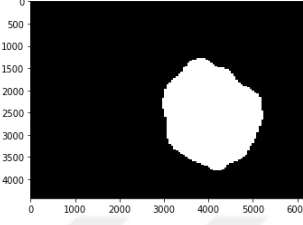
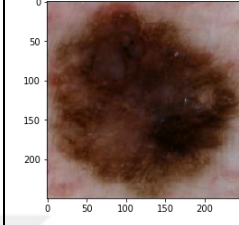


Şekil 5.1 Çalışmanın akış diyagramı

Algoritma 5.1 Önerilen Metodun Sözde Kodu

```
1. dataset = Read Data Set()
2.
3. if Crop Picture to Lesion Borders then
4.   for each item in dataset
5.     mask = Load Mask(item)
6.     crop(item, mask) //Crop lesion picture according to lesion border mask
7.   end for
8. end if
9.
10.
11. if Raw Picture Classification then
12.   features = dataset
13.
14.   if Using Transfer Learning then
15.     if Using Fine Tuning then
16.       classifier = Select Classifier ("VGG16 with FT", "InceptionV3 with FT")
17.     else
18.       classifier = Select Classifier ("VGG16 without FT", "InceptionV3 without FT")
19.     end if
20.   else
21.     classifier = Select Classifier ("CNN", "KNN", "LSTM", "RNN", "SVM")
22.   end if
23.
24. else if Classification Using Cnn Features then
25.
26.   featureExtractor = Select Feature Extractor CNN ("VGG16", "InceptionV3")
27.   features = featureExtractor.extractFeatures(dataset)
28.
29.   if Using GLCM features with CNN features together then
30.     glmFeatures = Extract Glcm Features(dataset)
31.     features = features + glmFeatures
32.   end if
33.
34.   classifier = Select Classifier("CNN", "KNN", "LSTM", "RNN", "SVM")
35.
36. else //Classification using Grey level coocurance matrix features
37.
38.   features = Extract Glcm Features(dataset)
39.   classifier = Select Classifier("CNN", "KNN", "LSTM", "RNN", "SVM")
40.
41. end if
42.
43.
44. //10-fold cross validation
45. for 1 .. 10 do
46.   result = classifier.classify(features)
47.   save(result)
48. end for
49.
50. results = Load Saved Results()
51.
52.
53. Best Model = Compare For Best Model(results)
54.
55.
56. Suitable Model = Compare For Suitable Model(results)
```

Tablo 5.1: Lezyon sınırları maskesi ve kırpma işlemi

	Dermoskopik resim	Lezyon sınırları maskesi	Resmin kırpılmış hali
Benign			
Malign			

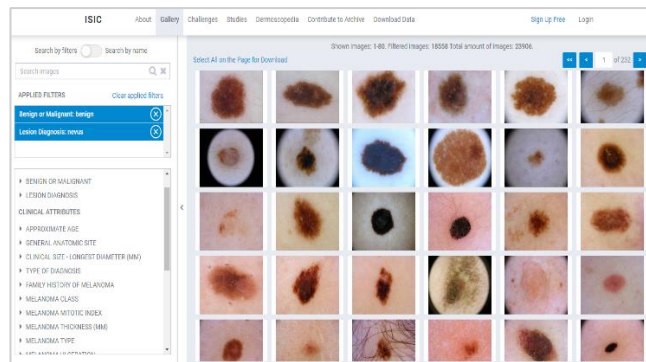
5.2.Evren ve Örneklem

Çalışmanın kaynağı, ISIC 2019 (Codella, vd., 2019) veri kümesinden oluşmaktadır. ISIC veri kümesi birkaç parçadan oluşmakla birlikte bunlardan bir kısmı yanlışlık sebebiyle ve bir kısmı da lezyon sınırları uzman doktorlar tarafından belirlenmediğinden çalışmaya dahil edilmemiştir. Bunların dışında kalan lezyon resimlerinden 826 melanom lezyon resmi ile aynı sayıda nevüs (melanom olmayan) lezyon resmi seçilmiş ve sınıflandırmada kullanılmıştır. ISIC veri kümesi, ‘The International Skin Imaging Collaboration’ tarafından 2017 yılında ‘International Symposium On Biomedical Imaging’ konferansı kapsamında yapılan ‘Skin Lesion Analysis Towards Melanoma Detection’ yarışması için ‘Creative Commons Attribution-NonCommercial 4.0 International License’ lisansı kapsamında yayınlanmış olan veri kümesidir. 2018 ve 2019 yıllarında veri kümesi genişletilmiş ve yarışma tekrar düzenlenmiştir. Veri kümesini oluşturan alt kümelerden BCN20000 veri kümesi ‘Department of Dermatology of the Hospital Clínic de Barcelona’ tarafından ISIC 2019 yarışması için sağlanmış, Actinic Keratosis, Squamous Cell Carcinoma, Basal Cell Carcinoma, Seborrheic Keratosis, Solar Lentigo, Dermatofibroma, Nevi, Melanoma, and Vascular lezyonlar gibi en yaygın cilt lezyonu sınıflarından oluşan veri kümesidir. 2006 ile 2010 yılları arasında toplanmış toplamda 19424 resimden oluşmaktadır. HAM10000 veri kümesi, Viyana Tıp Üniversitesi Dermatoloji bölümü tarafından toplanmış ve üyelerinden Tschandl ve arkadaşları

tarafından ISIC yarışması kapsamında yayınlanmıştır. Toplamda 10015 dermoskopik resimden oluşan veri kümesinin yarısının tanısı patoloji ile onaylanmış ve geri kalanı da takip edilerek, uzmanların görüş birliğiyle ya da ‘in-vivo confocal microscopy’ yöntemiyle tespit edilmiştir. Bu çalışmada kullanılan MSK Veri kümesi ise ISIC yarışması kapsamında Memorial Sloan Kettering Cancer Center tarafından sağlanan dermoskopik resimleri ve lezyon sınırlarını gösteren maskeleri içermektedir. Bu çalışma kapsamında yer alan veri kümesinin elde edilmesi için kullanılan yöntem ve araçlar bir sonraki başlıkta açıklanmaktadır (Codella, vd., 2017; Tschandl, Rosendahl ve Kittler:2018; Codella, vd., 2019; Combalia, vd., 2019).

5.3. Veri Toplama Araçları

ISIC veri kümesine <https://www.isic-archive.com/> adresinden ulaşılabilmektedir. Web sitesinde bulunan galeri sayfasında veri kümesi incelenebilir, içerisinde arama yapılabilir ve seçilen resimler indirilebilmektedir. Resimleri ve özniteliklerini indirebilmek için <https://isic-archive.com/api/v1/> adresinde bulunan API’den de faydalanılabilmektedir. Github sitesinde bu API’ı kullanan hazır uygulamalarda bulunmaktadır. Bu çalışmamızda veri kümesine ait olan csv dosyası web sayfasından indirilmiş, lezyon sınırları belli olanları işaretlemek için bir sütun, veri kümesi ismi için bir başka sütun eklenmiş, API yardımı ile bu sütunlar doldurularak yine API vasıtası ile lezyon sınırları belli olan resimler ile veri kümesi MSK olan resimler ve bunlara ait lezyon sınırı resimleri indirilmiştir. Bunun için <https://github.com/GalAvineri/ISIC-Archive-Downloader> adresinde bulunan betiklerden de faydalanılmıştır.



Şekil 5.2: ISIC galeri sayfasının ekran görüntüsü

5.4.Değerlendirme kriterleri

İkili sınıflandırıcılar, bir veri kümesini pozitif ve negatif olmak üzere iki gruba ayıran modellerdir. Son yıllarda çok çeşitli biyolojik ve tıbbi soruna başarıyla uygulanmışlardır. Bir sınıflandırıcının tahmin performansının değerlendirilmesi, rakip yöntemlere kıyasla yararlılığını değerlendirebilmek için büyük önem taşımaktadır. Model yapımı aşamasında sınıflandırıcı performansının yaygın olarak kullanılan ölçüleri, doğruluk, hata oranı ve alıcı çalışma karakteristiği eğrisi altındaki alandır. Nihai modelin değerlendirilmesi için çeşitli ek ölçümler yararlı olacaktır ve alıcı çalışma karakteristiği eğrisi (ROC) ve kesinlik duyarlılık eğrisi (PRC) grafikleri gibi bazı grafikler görsel temsil sağlarlar (Saito ve Rehmsmeier, 2015).

Bazı tanılama sistemleri karmaşık olmasına rağmen tanılama sistemlerinin genellikle iki sınıf arasında ayrım yapması beklenir. İki alternatif durum ve buna karşılık gelen iki tanı söz konusu olduğunda ikiye iki bir sonuç tablosu elde edilir (**Tablo 5.4:** Hata matrisini açıklayıcı tablo). Tablodaki durumlar pozitif ve negatif olarak adlandırılır ve tanı pozitif ve negatif olarak konulur. Tanı sistemlerinde aslında istenmeyen sonuca “pozitif” denmektedir (Swets, 1988).

Tablo 5.4: Hata matrisini açıklayıcı tablo

		Tahmin edilen	
		Negatif tahmin	Pozitif tahmin
Aslında olan	Negatif değer	TN	FP
	Pozitif değer	FN	TP

5.4.1.Hata Matrisi (Confusion Matrix)

Hata matrisi bir sınıflandırıcının tahmin ettiği ve gerçekte olan sınıflandırma bilgisini tutar. Sistemin performansı genellikle bu matris içerisindeki bilgilerden ölçülebilir. Örneğin bir ikili sınıflandırıcının hata matrisi **Şekil 5.3**'teki gibi görünür.

	Benign	Malignant
Benign	57	25
Malignant	21	62
	Benign	Malignant

Şekil 5.3: Örnek hata matrisi

Tanılama sistemlerinde gerçek durum ile elde edilen tanının uyduğu iki durum olabilmektedir. Bu iki doğru tanı “true positive” yani doğru pozitif ve “true negative” yani doğru negatif olarak adlandırılır. **Tablo 5.4**'de TN (True Negative) kutucuğunda yer alan değer, aslında negatif olan ve doğru sınıflandırılmış olan örneklerin sayısını gösterir. Bu çalışmada “benin” yani selim olan lezyonlar negatif anlam taşımaktadır. TP (True Positive) kutucuğunda yer alan değer aslında pozitif olan ve doğru sınıflandırılmış örneklerin sayısını gösterir. Bu çalışmada “malin” yani habis olan lezyonlar pozitif anlamını taşımaktadır. Tanılama sistemlerinde gerçek durum ile konulan tanının uyuşmadığı iki durum olabilmektedir. Bu iki hata durumu “false positive” ve “false negative” yani yanlış pozitif ve yanlış negatif olarak adlandırılır. Yine **Tablo 5.4**'de FN (False Negative) kutucuğunda yer alan değer aslında pozitif olan fakat negatif olduğu tahmin edilmiş örneklerin sayısını ifade etmektedir. FP (False Positive) kutucuğunda yer alan değer ise aslında negatif olan fakat pozitif olduğu tahmin edilmiş olan örneklerin sayısını göstermektedir. Bir tanılama sisteminin test edilmesi ile elde edilen veri bu dört sonuçtan birine tekabül edecektir. Bu tür tanılama sistemlerinin tamamen doğru sonuç veremeyeceği ve doğruluk derecelerine ilişkin nicel değerlendirmelerin faydalı olacağı açıktır. Sistemin doğruluğunun geçerli ve kesin değerlendirmeleri, kullanıcıların sistemleri nasıl veya ne zaman kullanacaklarını ve sisteme ne kadar güveneceklerini belirlemelerine yardımcı olur (Swets, 1988).

Hata matrisinden elde edilen ölçütlerin başında doğruluk (accuracy) gelir. Doğruluk basitçe doğru tahmin edilmiş tanıların toplam tanılarına oranıdır. En temel değerlendirme kriteri olarak sayılabilir. Simetrik veri kümelerinde daha doğru sonuçlar verir.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (5.1)$$

Simetrik olmayan veri kümeleri için diğer değerlendirme kriterlerini de göz önünde bulundurmak iyi olacaktır. Örneğin kesinlik (precision) ise doğru tahmin edilen pozitif gözlemlerin toplam tahmin edilen pozitif gözlemlere oranıdır. Hasta olarak tahmin edilmiş olan örneklerden ne kadarının hasta olduğunu gösterir. Yüksek kesinlik oranı düşük yanlış pozitif değerinin göstergesidir.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (5.2)$$

Duyarlılık değeri ise (recall, sensitivity), doğru pozitif tahminlerin bütün pozitif örneklere oranı ile elde edilir. Bütün hastalar arasından ne kadarının doğru tahmin edildiğini gösterir. Gerçek hastaları bulma oranı diye ifade edilebilir. Doğru pozitif oranı (TPR) olarak da adlandırılır.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (5.3)$$

Özgüllük (Specificity) değeri, doğru negatif tahminlerinin bütün negatif örneklere oranı ile elde edilir. Bütün sağlıklı örnekler arasından ne kadarının doğru tahmin edildiğini gösterir. Gerçek sağlıklı örnekleri bulma oranı diye ifade edilebilir.

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (5.4)$$

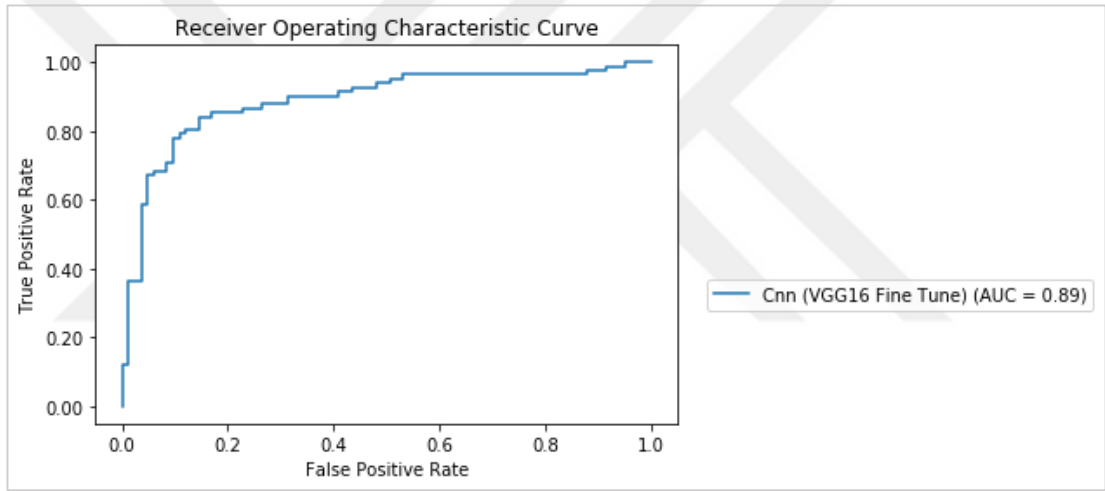
F1 Score veya F Measure ise kesinlik ve duyarlılığın harmonik ortalamasıdır. Eğer kesinlik ve duyarlılık birbirine yakınsa kullanılması daha uygun olur.

$$\text{F1 Score} = \frac{2 * (\text{Recall} * \text{Precision})}{(\text{Recall} + \text{Precision})} \quad (5.5)$$

5.4.2. Alıcı Çalışma Karakteristiği Eğrisi (Receiver Operating Characteristic Curve)

İki sonuçlu tanı testinde geleneksel tanı testi değerlendirme yaklaşımı, doğruluk ölçüsü olarak duyarlılık ve özgüllüğü kullanır. Test sonuçları sürekli olarak raporlandığında yani her bir eşik değeri için elimizde bir sonuç bulunduğunda duyarlılık ve özgüllük de olası bütün eşik değerleri için hesaplanabilir. Duyarlılık ve özgüllük farklı eşik değerleri için farklılık gösterir ve duyarlılık özgüllük ile ters orantılıdır. Bu durumda

duyarlılık ve 1-özgüllük baz alınarak elde edilecek olan grafiğe alıcı çalışma karakteristiği eğrisi (ROC) denir ve eğrinin altında kalan alan (AUC Area under curve) ile birlikte etkili bir doğruluk ölçüsü olarak kabul görmektedir (Hajian-Tilaki, 2013). Alıcı çalışma karakteristiği, ilk başta sinyal işleme alanında kullanıldığı için bu isimle anılmaktadır. Genel uygulamalarda ise görece çalışma karakteristiği (relative operating characteristic) olarak da isimlendirilir (Swets, 1988). Alıcı çalışma karakteristiği eğrisinin altında eğri altında kalan alan (area under the curve) denir ve ikili tıbbi tanılama testlerinin başlıca ölçütlerindedir. 0 ile 1 arasında değer alır ve genellikle 0.5 altında kalan değer faydasız kabul edilir. Fakat hangi değer işe yarar olduğu konuya bağlı olarak değişir. **Şekil 5.4**'te örnek olarak bir alıcı çalışma karakteristiği eğrisi verilmektedir.

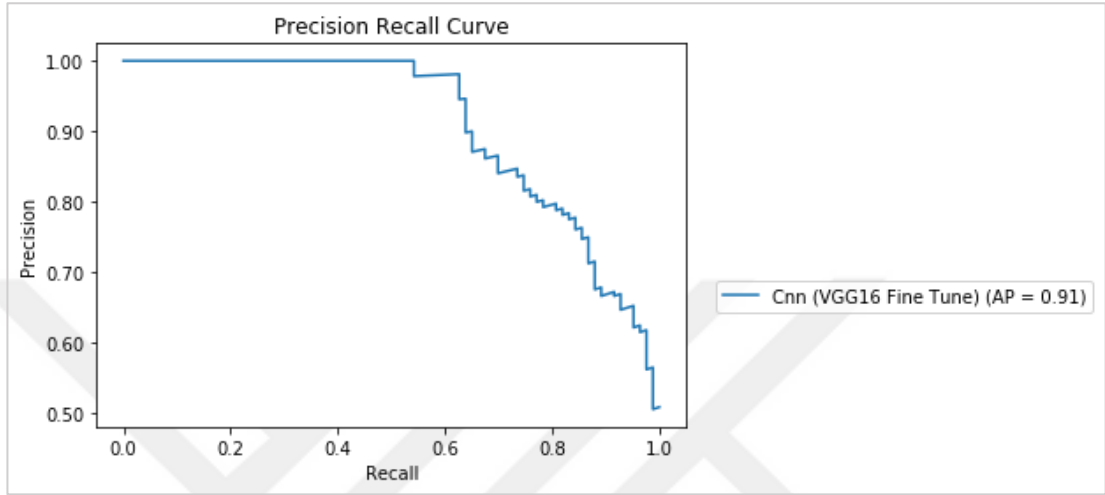


Şekil 5.4: Örnek alıcı çalışma karakteristiği eğrisi ve eğri altında kalan alan

5.4.3. Kesinlik Duyarlılık Eğrisi (Precision Recall Curve)

Alıcı çalışma karakteristiği eğrisi (ROC), herhangi bir eşik değerden bağımsız olarak bir sınıflandırıcının performansını değerlendirmede yardımcı olabilirse de farklı ölçümlerin gerekli olduğu durumlar da vardır. Örneğin, ilgili belgeleri arama (bilgi toplama) veya nadir olayları tanıma (anomali tespiti) söz konusu olduğunda, mevcut veriler genellikle negatif sınıf lehine dengesizdir. Bir sınıflandırıcı çok iyi bir AUC değerine rağmen kötü performans gösterebilir. Bu durumlarda, kesinliğe karşı duyarlılığı tüm eşiklerde çizen 'kesinlik duyarlılık eğrisi' (PRC), sınıflandırma performansına bakmanın daha doğal bir yoludur. Örneğin, duyarlılığı belirli bir

kesinlik seviyesine göre değerlendirmek veya PRC altındaki alanı ortalama kesinlik (AP) olarak hesaplamak için kullanılabilir (Brodersen, vd., 2010). Kesinlik duyarlılık eğrisinin altında kalan alana ortalama kesinlik (average precision) denir ve ikili tıbbi tanılama testlerinin son yıllarda sık kullanılan ölçütlerindendir. **Şekil 5.5**'de örnek olarak bir kesinlik duyarlılık eğrisi verilmektedir.



Şekil 5.5: Örnek kesinlik duyarlılık eğrisi ve ortalama kesinlik

Uygun olan karar kriteri, doğru sonuçlara atfedilen faydalara ve yanlış sonuçlara atfedilen maliyetlere de bağlıdır. Ortaya çıkmayan şiddetli bir fırtınanın tahmin edilmesi (yanlış pozitif) tipik olarak, meydana gelen bir fırtınayı tahmin etmeme maliyetine (yanlış negatif) göre küçük bir maliyete sahip olarak kabul edilir, bu durumda pozitif tanıya yatkın olan kriter daha makbuldür (Swets, 1988).

5.5.Araçlar

Makine öğrenmesi algoritmaları birçok programlama dilinde hayata geçirilmiştir. ve bu alanda birçok yardımcı yazılım bulunmaktadır. Bu çalışma makine öğrenmesi alanında çok kullanılan Python programlama dili ile temelde Tensorflow, Sklearn kütüphanelerini kullanarak Anaconda geliştirme ortamında tamamlanmıştır. Anaconda isimli yazılım, açık kaynak kodlu bir veri bilimi platformudur. Anaconda içerisinde birden fazla Python ortamı yönetilebilir olduğundan kütüphanelerin farklı versiyonları kullanılabilir. Böylece aynı veri kümesi üzerinde ve aynı kod ile farklı versiyonlarda elde edilecek sonuçları görmek ve karşılaştırmak mümkün

olabilmektedir. Aynı işlemi Anaconda olmadan Python ile yapmak da mümkün olmakla birlikte Anaconda bu özelliğe arayüz sağlamaktadır. (Anaconda, 2020). Anaconda üzerinden eriştiğimiz Jupyter, web tabanlı interaktif kod geliştirme ortamıdır. Jupyter, not defterleri olarak adlandırılan canlı kod, denklemler, görselleştirmeler ve anlatı metni içeren belgeler oluşturmanıza ve paylaşmanıza olanak tanıyan açık kaynaklı bir web uygulamasıdır. Veri temizleme, veri dönüştürme, sayısal simülasyon, istatistiksel modelleme, veri görselleştirme, makine öğrenmesi gibi alanlarda kullanılır (Jupyter Lab, 2020). Programlama dili olarak tercih ettiğimiz Python, son zamanlarda veri işleme ve analizi konusunda önde gelen programlama dillerinden birisi olarak öne çıkmaktadır. Özellikle makine öğrenmesi, yapay zeka ve derin öğrenme gibi başlıklarda defacto standart olduğu söylenebilir. Guido van Rossum tarafından oluşturulmuş ve ilk olarak 1991 yılında yayınlanmıştır. Nesne tabanlı, yorumlanan, yüksek seviyeli, dinamik bir programlama dilidir. Beyaz karakterlere duyarlıdır, kod blokları tablolar ya da boşluklarla belirlenmektedir. Çöp toplama mekanizması barındırmaktadır. Nesne tabanlı olmakla birlikte fonksiyonel programlama gibi diğer programlama paradigmasını da içeren özellikler barındırmaktadır (Python, 2020). Python dili ile ilgili bir kod parçasını örnek vermek gerekirse, Guido tarafından 2003 yılında yazılmış olan örnek bir kod bloğu şöyle görünmektedir (Artima, 2020):

```
"""Module docstring.

This serves as a long usage message.
"""
import sys
import getopt

def main():
    # parse command line options
    try:
        opts, args = getopt.getopt(sys.argv[1:], "h", ["help"])
    except getopt.error, msg:
        print msg
        print "for help use --help"
        sys.exit(2)
    # process options
    for o, a in opts:
        if o in ("-h", "--help"):
            print __doc__
            sys.exit(0)
    # process arguments
    for arg in args:
        process(arg) # process() is defined elsewhere

if __name__ == "__main__":
    main()
```

Python için internette birçok kütüphane bulunabilir. Bu kütüphaneler *pip* ya da *conda* komutları ile kurulabilmektedir. Bu çalışmada Tensorflow, Keras, Sklearn, Numpy, tqdm, matplotlib, pandas, glob, PIL gibi kütüphaneler kullanılmıştır. Bunlardan çalışmamız açısından en önemlisi olan Tensorflow, Abadi ve arkadaşları ve Google Brain takımı tarafından “TensorFlow: A system for large-scale machine learning” başlıklı makale ile tanıtılmış bir makine öğrenmesi platformudur (Abadi, vd., 2016). Hem çeşitli makine öğrenmesi algoritmalarını ifade etmek için bir uygulama programlama arayüzü hem de bu arayüzün uygulamasıdır. Tensorflow ile ifade edilen bir işlem mobil telefonlar, tabletler, çok sayıda bilgisayardan ya da çok sayıda ekran kartlarından oluşan dağıtık sistemler gibi çok çeşitli platformlarda çalıştırılabilir. Keras, Tensorflow gibi makine öğrenmesi kütüphaneleri ile çalışmak üzere tasarlanmış bir uygulama arayüzü kütüphanesidir. Keras, aslında kendisi bir makine öğrenmesi kütüphanesi değildir. Diğer kütüphanelere daha kolay erişim sağlamak ve benzer kodlar ile birden fazla kütüphane üzerinde çalışabilmek için bir arayüz kütüphanesidir. Sklearn kütüphanesi, sınıflandırma, kümeleme, regresyon, indirgeme gibi makine öğrenmesi alanlarını kapsayan bir kütüphanedir. Örneğin k komşu sınıflandırıcısı, vektör makinesi, k means kümeleyicisi ya da temel bileşen analizi indirgeyicisi gibi sınıfları içerir. Numpy kütüphanesi Python ile bilimsel hesaplamalar yapmak üzere hazırlanmış defacto standart hesaplama kütüphanesidir. Numpy dizileri rahatlıkla dosyaya kaydedilip dosyadan okunabilir. Matplotlib ve pyplot, bu çalışmada kullanılan grafik çizim kütüphanesidir. Pandas, veri analizi ve veri işleme kütüphanesidir. PIL, resim işleme için, glob dosya listeleme için ve tqdm ise ilerleme çubuğu gösterimi için kullanılan diğer yardımcı kütüphanelerdir. Çalışmamız Nvidia 1660ti 6gb ekran kartı, 16GB Ram, i7-9750H 2.60GHz işlemcisi olan Acer Nitro marka ve modelinde bir dizüstü bilgisayar ile tamamlanmıştır.

5.6.Sonuç

Bu bölümde çalışmamızda kullanılan veri kümesi, yöntem, yazılım, donanım ve değerlendirme kriterleri gibi teknik konulara açıklık getirmeye çalıştık. İlk kısımda çalışmanın modeline açıklık getirdik. Kullandığımız makine öğrenmesi yöntemlerinin elde bulunan veri kümesi üzerinde nasıl uygulandığını izah ettik. Çalışmanın akış şemasına ve kırpma işleminin tablosuna yer verdik. İkinci kısımda ISIC veri kümesini

tanıttık. Üçüncü kısımda ise lezyon resimlerinin nasıl elde edilebileceğini açıkladık. Dördüncü kısımda elde edilen sonuçları değerlendirmek için kullanılan kriterleri izah ettik. Beşinci kısımda çalışmada kullanılan yazılım, donanım ve araçları da kısaca tanıttık. Böylece benzeri bir çalışmayı yapmak isteyen araştırmacıların takip edebileceği bir yol haritası çıkarmış olduk. Bu bölümde yer alan yöntemleri ve araçları kullanarak yapılan simülasyonların ayrıntılarını ve sonuçlarını ise bir sonraki bölümde açıklayacağız.



ALTINCI BÖLÜM

ARAŞTIRMA BULGULARININ DEĞERLENDİRİLMESİ

Bu bölümde çalışmamızda kullanılan makine öğrenmesi algoritmalarının nasıl ve hangi parametrelerle eğitildikleri açıklanacak ve sınıflandırma sonucunda elde edilen değerlere ait tablolara ve grafiklere yer verilerek sonuçlar değerlendirilecektir. Sonuçların değerlendirilmesinde doğruluk, eğrinin altında kalan alan, ortalama kesinlik, f1 değeri gibi değerler ile kesinlik hassasiyet eğrisi, alıcı karakteristiği eğrisi ve hata matrisi gibi tablolar modellerin birbirlerine göre ve lezyon sınırlarına göre karşılaştırmalı olarak yorumlanacaktır.

6.1. Simülasyon ayarları ve parametreleri

Çalışmamızda MSK veri kümesinden lezyon sınırları belirlenmiş olan 1652 resim 743'er adet benign ve malignant olmak üzere eğitim aşamasında ve 83'er adet benign ve malignant olmak üzere doğrulama aşamasında kullanılmış, hem lezyon sınırlarına göre kırılmadan hem de lezyon sınırlarına göre kırılarak ve 10 kat çapraz doğrulama ile eğitimler tamamlanmış, sonuçlar kayıt altına alınmıştır.

VGG16 modeli ile elde ettiğimiz öznelikleri sınıflandırmak için kullandığımız evrişimsel sinir ağı dört adet Convolution, Max Pooling ve Dropout katmanı kullanmaktadır. Bu katmanlardan Dropout katmanlarında dropout değeri olarak 0.1, Max Pooling katmanında pool size değeri olarak (2, 2), Convolution katmanlarında 'relu' aktivasyon fonksiyonu ile filters ve kernel size değerleri için de sırasıyla 128, (7, 7), 64, (5, 5), 64, (5, 5) ve 32, (3, 3) kullanılmıştır. Sınıflandırma için ise iki adet Fully Connected katman kullanılmıştır. Fully Connected katmanlardan ilki 128 birim ile 'relu' aktivasyon fonksiyonunu kullanırken ikincisi ise iki adet sınıfımız olduğu için 2 birim ve 'sigmoid' aktivasyon fonksiyonunu kullanmaktadır. Model, 0.0001 öğrenme oranı ile Adam optimizasyon algoritmasını ve 'binary crossentropy' kayıp fonksiyonunu kullanmaktadır. InceptionV3 modeli ile elde ettiğimiz öznelikleri sınıflandırmak için kullandığımız evrişimsel sinir ağı yukarıdakinden farklı olarak dropout değeri için 0.5, ikinci Fully Connected katmanda aktivasyon fonksiyonu olarak 'softmax', ve öğrenme oranı olarak da 0.00001 kullanmaktadır.

Resimlerin piksel özniteliklerinden faydalanarak öğrenme aktarımı olmadan sınıflandırma yapan evrimsel sinir ağıımız, VGG16 özniteliklerini sınıflandırandan farklı olarak üçer adet Convolution, Max Pooling ve Dropout katmanı kullanmaktadır. Dropout değeri olarak 0.1, pool size değeri olarak (3, 3), filters ve kernel size değerleri için sırasıyla (7, 7), 64, (5, 5), 64 ve 32, (3, 3) kullanılmıştır. Öğrenme değeri 0.00007 ve 0.0000014 decay değeri ile Adam optimizasyon algoritması kullanılmıştır. Fully Connected katmanlarda 'relu' ve 'sigmoid' fonksiyonları kullanılmıştır.

VGG16 ve InceptionV3 modelinden gelen ağırlıklarla öğrenme aktarımı yaparken kullandığımız modellerimizde dropout değeri 0.3'tür. VGG16 için öğrenme değeri 0.000007 ve decay değeri 0.00000014 iken InceptionV3 için öğrenme değeri 0.0005 ve decay değeri 0.00001 olarak kullanılmıştır. Bununla birlikte InceptionV3 ile öğrenme aktarımı yaparken bir adet Global Average Pooling katmanı kullanılmıştır. Fine Tune yaptığımız aşamada ise VGG16 modeli 4 katmana kadar eğitime açılırken InceptionV3 networkü ise 249 numaralı katmandan sonrası eğitime açılmıştır.

Gri değeri eş dizilim matrisi özniteliklerini sınıflandırmak için kullandığımız evrimsel sinir ağıımız sekizer adet Convolution, Max Pooling ve Dropout katmanı ve üç adet Fully Connected katmandan oluşmaktadır. Convolution katmanlarında 'relu' aktivasyon fonksiyonu ile filters ve kernel size değerleri için sırasıyla 512, (3, 2), 256, (3, 2), 128, (3, 2), 64, (3, 2), 64, (2, 2), 64, (2, 2) 32, (2, 2), 32, (3, 2) kullanılmıştır. Dropout katmanlarında dropout değeri 0.1 olurken Max Pooling katmanlarında pool size değeri olarak (2, 2) kullanılmıştır. Fully connected katmanların ilk ikisinde aktivasyon fonksiyonu 'relu' olurken son katmanda 'sigmoid' kullanılmıştır. Birim sayıları sırasıyla 128, 32 ve 2 olurken, öğrenme değeri ise 0.0001'dir.

Gri değeri eş dizilim matrisi öznitelikleri ile VGG16 ve InceptionV3 modellerinden elde ettiğimiz özniteliklerin bir arada sınıflandırıldığı modellerimizde gri değerlerinden öğrenen kolda ikişer adet Convolution, Max Pooling ve Dropout katmanı bulunurken bir adet Global Average Pooling katmanı bulunmaktadır. Convolution katmanlarında 'relu' aktivasyon fonksiyonu ile filters ve kernel size değerleri için sırasıyla 64, (6, 2), 32, (6, 2), Dropout katmanında dropout değeri olarak 0.1 ve Max Pooling katmanında pool size değeri olarak (2, 2) kullanılmıştır. Cnn özniteliklerini öğrenen kolda ise üçer adet Convolution, Max Pooling ve Dropout katmanı bulunurken bunların arkasında birer adet bir adet Convolution, Max Pooling katmanı daha bulunmaktadır. Bunlara ek olarak bir adet Global Average Pooling

katmanı da bulunmaktadır. Convolution katmanlarında 'relu' aktivasyon fonksiyonu ile filters ve kernel size değerleri için sırasıyla 128, (6, 6), 64, (6, 6), 64, (3, 3), 32, (3, 3) olurken dropout ve pool size değerleri yukardaki ile aynıdır. Bu iki koldan elde edilen öğrenme değerleri birleştirilmektedir. Üç katmandan oluşan Fully Connected katmanların birim sayıları sırasıyla 128, 64, 2 olurken aktivasyon fonksiyonları 'relu', 'relu' ve 'sigmoid'dir.

Bütün cnn sınıflandırıcıları 50 epoch boyunca eğitilmiş ve doğrulama aşamasında kayıp değeri, 5 eğitim aşaması boyunca iyileşmezse öğrenme değeri %20 oranında düşürülerek iyileştirilmiştir. 10 kat çapraz doğrulama sonucunda elde edilen değerler kayıt altına alınmıştır.

VGG16 modelinden elde ettiğimiz öznitelikleri sınıflandırırken öznitelik vektörünün boyutu ikiye düşürülmüştür. LSTM modelinin birim sayısı 1000, dropout değeri 0.5, recurrent dropout değeri 0.1, öğrenme değeri 0.00004 olarak ayarlanmıştır. InceptionV3 modelinden elde ettiğimiz öznitelikleri sınıflandırırken yine öznitelik vektörünün boyutu düşürülmüştür. LSTM modelinin birim sayısı 250, dropout değeri 0.2, recurrent dropout değeri 0.1 ve öğrenme değeri 0.0001 olarak ayarlanmıştır.

Gri değeri eş dizilim matrisi ile elde edilen öznitelikleri sınıflandırdığımız LSTM modelinde öznitelik vektörünün boyutu düşürüldükten sonra iki LSTM arka arkaya eklenmiştir. Bunların ikisinin de birim sayısı 100, dropout değeri 0.1 ve recurrent dropout değeri 0.1, öğrenme değeri 0.0001 olarak ayarlanmıştır.

Gri değeri eş dizilim matrisi ve cnn özniteliklerini birlikte kullandığımız LSTM modelinde öznitelik vektörlerinin boyutları düşürüldükten sonra her iki kol için de iki LSTM sınıflandırıcısı arka arkaya eklenerek kullanılmış ve sınıflandırma aşamasından önce bu iki kol birleştirilmiştir. Bunların her ikisinde de ilk LSTM'in birim sayısı 250, dropout değeri 0.2, recurrent dropout değeri 0.1 iken ikinci LSTM'in birim sayısı 100, dropout değeri 0.1 ve recurrent dropout değeri 0.1. Modelin öğrenme değeri 0.00001 olarak kullanılmıştır.

Resimlerin piksel değerlerinden elde edilen öznitelikleri sınıflandırırken kullandığımız LSTM sınıflandırıcısında yine arka arkaya iki LSTM kullanılmıştır. Bunların birim sayısı sırasıyla 250 ve 100 iken her ikisinin de dropout ve recurrent dropout değerleri 0.1 olarak ayarlanmıştır. Modelin öğrenme değeri 0.00007, decay değeri ise 0.0000014 olarak ayarlanmıştır.

Bütün modeller 50 epoch boyunca eğitilmiş ve sınıflandırma aşamasında aktivasyon fonksiyonu olarak 'sigmoid' kullanılmıştır. Doğrulama aşamasında kayıp değeri, 5 eğitim aşaması boyunca iyileşmezse öğrenme değeri %20 oranında düşürülerek iyileştirilmiştir. 10 kat çapraz doğrulama sonucunda elde edilen değerler kayıt altına alınmıştır.

VGG16 modelinden elde ettiğimiz öznitelikleri RNN ile sınıflandırırken birim sayısı 256, InceptionV3 modelinden elde ettiğimiz öznitelikleri sınıflandırırken ise birim sayısı 64, her ikisinde de öğrenme oranı 0.00006 olarak ayarlanmıştır. Gri değeri eş dizilim matrisinden elde ettiğimiz öznitelikleri sınıflandırırken kullandığımız RNN modelinde birim sayısı 100, öğrenme değeri 0.0001'dir. Cnn öznitelikleri ile gri değeri eş dizilim matrisi özniteliklerini bir arada kullanarak sınıflandırma yaptığımız modelde birim değeri 100 olan iki ayrı RNN sınıflandırma öncesinde bir birine eklenmiştir. Bu modelin öğrenme değeri 0.0001'dir. Resimlerin piksel değerlerinden elde ettiğimiz öznitelikleri sınıflandırdığımız modelde ise birim sayısı 100, öğrenme değeri 0.0001 ve decay değeri 0.000002'dir.

Bütün RNN modellerinin girdisi olan öznitelik vektörlerinin boyutları düşürülmüştür. Modeller 50 epoch boyunca eğitilmiş ve sınıflandırma aşamasında aktivasyon fonksiyonu olarak 'sigmoid' kullanılmıştır. Doğrulama aşamasında kayıp değeri, 5 eğitim aşaması boyunca iyileşmezse öğrenme değeri %20 oranında düşürülerek iyileştirilmiştir. 10 kat çapraz doğrulama sonucunda elde edilen değerler kayıt altına alınmıştır.

VGG16, InceptionV3, gri değeri eş dizilim matrisi veya bunların bir arada kullanıldığı sınıflandırmalar ve resimlerin pikselleri ile yapılan sınıflandırmaların tamamında kullanılan SVM'lerde Linear çekirdek fonksiyonu kullanılmış ve C değeri 15 olarak ayarlanmıştır. Öznitelik vektörlerinin boyutu düşürülmüştür. İki vektör bir arada kullanılmak istendiğinde vektörler birleştirilmiştir. 10 kat çapraz doğrulama sonucunda elde edilen değerler kayıt altına alınmıştır.

SVM'de yapıldığı gibi KNN'de de bütün sınıflandırmalarda aynı parametreler kullanılmıştır. Komşu sayısı 5, yaprak sayısı 5, metrik fonksiyonu 'euclidean', ağırlık parametresi 'distance' olarak ayarlanmıştır. 10 kat çapraz doğrulama sonucunda elde edilen değerler kayıt altına alınmıştır.

6.2.Sınıflandırma sonuçları

Buraya kadar çalışmamızda kullanılan modelleri ve kullanım amaçlarını açıklamaya çalıştık. Daha önceden açıklanan parametreler kullanılarak oluşturulmuş olan modeller ile yaptığımız sınıflandırma sonuçlarını bu başlıkta değerlendirip karşılaştıracamız.

6.2.1.InceptionV3 modelinden elde edilen özniteliklerin sınıflandırılması

Kaynak resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özniteliklerin sınıflandırılmasında en yüksek doğruluk ve en yüksek f1 puanı 0,73 olmak üzere ve en yüksek ortalama doğruluk 0,69 olmak üzere CNN ile elde edilirken, en yüksek AUC değeri 0,76 ile RNN ve CNN kullanılarak elde edilmiştir. En yüksek AP değeri ise 0,76 olmak üzere KNN ile elde edilmiştir. Kaynak resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırılmasında en yüksek doğruluk ve en yüksek f1 puanı 0,76 olmak üzere, en yüksek ortalama doğruluk 0,71 olmak üzere, en yüksek AUC 0,81 ve en yüksek AP 0,82 olmak üzere LSTM sınıflandırıcısı ile elde edilmiştir. LSTM sınıflandırıcısında kırma işlemi maksimum doğruluğu %5, ortalama doğruluğu ise %3 oranında yükseltmiştir. KNN ile sınıflandırma yapıldığında maksimum doğruluk %1 ortalama doğruluk %2 oranında yükselmiştir. RNN ile sınıflandırma işleminde maksimum doğruluk değişmemiş fakat ortalama doğruluk %2 oranında yükselmiştir. SVM ile sınıflandırma işleminde maksimum doğruluk %1 oranında azalmış, ortalama doğruluk ise %2 oranında artmıştır. CNN ile sınıflandırma işleminde maksimum doğruluk değişmemiş ve ortalama doğruluk %4 oranında azalmıştır.

Bu değerlerden anlaşıldığı kadarıyla InceptionV3 ile elde edilen öznitelikleri sınıflandırırken lezyon sınırları belirlenebiliyor ise LSTM sınıflandırıcı kullanmak avantaj sağlamaktadır. Aşağıdaki grafikleri incelediğimizde, lezyon sınırlarına riayet edilerek sınıflandırma sırasında LSTM kullanıldığında elde edilen confusion matrix'in daha dengeli olduğu görülmektedir. Validation loss ve validation accuracy grafikleri de LSTM sınıflandırıcısı kullanmanın daha verimli olduğunu düşündürmektedir. İlgili değerler **Tablo 6.2.1.1** ve **Tablo 6.2.1.2**'de verilmektedir.


Tablo 6.2.1.1: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçları

Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,73	0,69	0,02	0,76	0,74	0,73
KNN	0,68	0,62	0,04	0,72	0,76	0,68
LSTM	0,71	0,68	0,02	0,74	0,75	0,71
RNN	0,70	0,65	0,04	0,76	0,73	0,70
SVM	0,69	0,63	0,03	0,74	0,72	0,69

Tablo 6.2.1.2: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçları

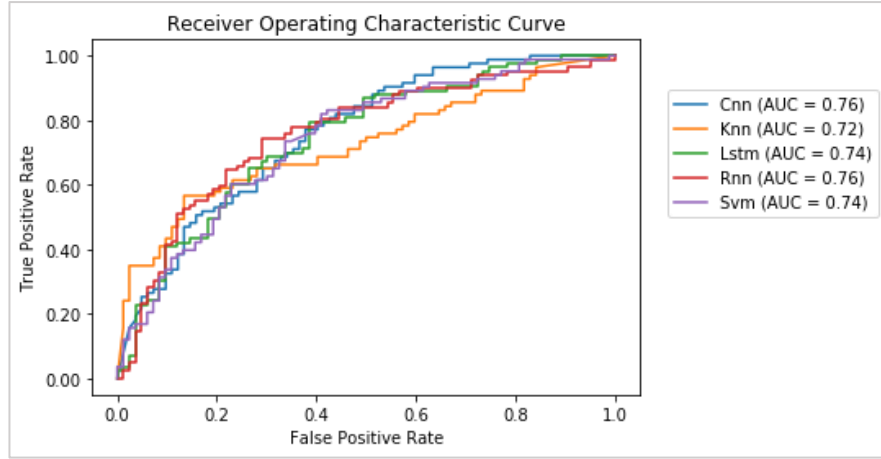
Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,73	0,65	0,05	0,77	0,78	0,72
KNN	0,69	0,64	0,04	0,75	0,74	0,69
LSTM	0,76	0,71	0,04	0,81	0,82	0,76
RNN	0,70	0,67	0,02	0,75	0,74	0,70
SVM	0,68	0,65	0,03	0,71	0,71	0,68

a) Resimler lezyon sınırlarına göre kırılmadan yapılan işlemlerin grafikleri




Şekil 6.1: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri

Şekil 6.1'den bazı kesim noktalarında RNN ve SVM daha düşük sonuç elde ettiği için AP değeri diğerlerine göre daha az olduğu anlaşılıyor. KNN ise en yüksek AP değerine sahip ve eğrisi de bu yüzden en yukarıda bulunuyor.




Şekil 6.2: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

Şekil 6.2’den bütün modellerin benzer ROC performansı gösterdiği ve eşik değerlerine göre sapma olmadığı anlaşılırken KNN’in daha altta kaldığı görülebiliyor.




Şekil 6.3: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Eğitim aşamasında her devirde benzer bir iyileşme olduğu fakat LSTM modelinin daha iyi öğrendiği Şekil 6.3’den anlaşılıyor. Bir aşamadan sonra RNN’in öğrenmeyi bıraktığı, CNN’in ise öğrenmeye devam etmesine rağmen LSTM kadar iyi öğrenemediği görülüyor.




Şekil 6.4: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri

Doğrulama aşamasında en yüksek değeri CNN'in elde ettiği, RNN ve LSTM'in doğrulama aşamasında yeterince başarılı olmadığı **Şekil 6.4**'te görülebiliyor.




Şekil 6.5: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model eğitim kayıp eğrileri

Eğitim aşamasında LSTM ve CNN'in kayıp değerini azaltmaya devam ederken RNN'in ise belli bir devirden sonra kayıp değerini azaltmadığı **Şekil 6.5**'den anlaşılıyor.



Şekil 6.6: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model sağlama kayıp eğrileri

Şekil 6.6'ya göre doğrulama aşamasında kayıp fonksiyonunun LSTM'de daha tutarlı olduğu görülüyor. CNN'de devir ilerledikçe modelin ezberlediği, RNN'de ise kayıp değerinin iyileşmediği görülüyor.




Şekil 6.7: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının hata matrisleri

Şekil 6.7'deki hata matrislerinden en dengeli tanıma işleminin LSTM ile yapılabildiği, CNN ve SVM'in sağlıklı örnekleri hasta olarak sınıflandırmaya yatkın olduğu, KNN


ve RNN'in ise hasta olan örnekleri sağlıklı olarak sınıflandırmaya yatkın olduğu anlaşılıyor.

b) Resimler lezyon sınırlarına göre kırılarak yapılan işlemlerin grafikleri




Şekil 6.8: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri

SVM eğrisinin altta LSTM eğrisinin üstte kaldığı **Şekil 6.8**'den anlaşılıyor. Bazı kesim noktalarında CNN modeli LSTM'den daha iyi AP değeri elde etmesine rağmen genel olarak LSTM daha üstte yer alıyor.




Şekil 6.9: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

Şekil 6.9'a göre bütün modellerin birbirine benzer şekilde bir eğri çizmesi benzer sonuçlar almalarını sağlarken LSTM modelinin en üstte kalması en iyi sonucu verdiğini gösteriyor.




Şekil 6.10: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Eğitim aşamasında RNN ve LSTM benzer bir doğruluk değerini yakalarken CNN'in performansının düşük olduğu Şekil 6.10'dan anlaşılıyor.




Şekil 6.11: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri

Şekil 6.11'e göre doğrulama aşamasında belli bir devirden sonra RNN iyileşme göstermezken LSTM ve CNN daha iyi bir performans gösteriyor ve LSTM'in daha iyi olduğu daha üstte bir eğri çizmesinden anlaşılıyor.



Şekil 6.12: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model eğitim kayıp eğrileri


Şekil 6.12'ye göre kayıp değeri, LSTM ve RNN'de benzer şekilde iyileşirken CNN'de daha düz bir çizgide olması öğrenmenin ilerleyen devirlerde iyileşmediğini yani modelin öğrenemediğini gösteriyor.



Şekil 6.13: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model sağlama kayıp eğrileri

Doğrulama aşamasında LSTM ve RNN belirli bir devirden sonra kayıp değerini düşüremezken CNN daha kararlı görünüyor fakat kayıp değerini yeterli derecede

azaltmadığı için eğri düze yakın görünüyor. En düşük kayıp değerini LSTM'in yakaladığı Şekil 6.13'ten anlaşılıyor.



Şekil 6.14: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının hata matrisleri

Şekil 6.14'teki hata matrislerinden en dengeli modelin LSTM olduğu, CNN, KNN ve RNN'in hasta örnekleri sağlıklı olarak, SVM'in ise sağlıklı örnekleri hasta olarak sınıflandırmaya daha yatkın olduğu görülebiliyor.

6.2.2.VGG16 modelinden elde edilen özniteliklerin sınıflandırılması

Kaynak resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırılmasında en yüksek doğruluk ve en yüksek f1 puanı 0.83, en yüksek ortalama doğruluk 0.73, en yüksek AUC değeri 0.87, en yüksek AP değer ise 0.89 olmak üzere SVM ile elde edilmiştir. Kaynak resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırılmasında ise en yüksek doğruluk ve en yüksek f1 puanı 0.84 ve en yüksek AUC değeri 0.89 olmak üzere SVM ile elde edilirken, en yüksek ortalama doğruluk değeri 0,77 olmak üzere CNN ile, en yüksek AP değeri ise 0.88 olmak üzere LSTM ile elde edilmiştir. Kırpma işlemi SVM sınıflandırıcısı kullanıldığında en yüksek doğruluğu ve f1 puanını %1 yükseltirken ortalama doğruluğu etkilememiş ve en yüksek AP değerini ise %2

azaltmıştır. Kırpma işlemi, RNN sınıflandırıcı kullanıldığında maksimum doğruluğu ve f1 puanını %5, ortalama doğruluğu %2, AUC değerini %4, AP değerini ise %7 düşürmüştür. LSTM sınıflandırıcısı kullanıldığında en yüksek doğruluk ve f1 puanını %1, ortalama doğruluğu %6, AUC ve AP değerlerini ise %4 yükseltmiştir. KNN sınıflandırıcısı kullanıldığında en yüksek doğruluk ve f1 puanı %3, ortalama doğruluk %2 ve AUC değeri %1 düşerken AP değeri ise %2 artmıştır. CNN sınıflandırıcısı kullanıldığında ise en yüksek doğruluk ve f1 puanı %5 artarken, ortalama doğruluk %7, AUC değeri %4 ve AP değeri ise %1 artmıştır.

Bu değerlerden anlaşıldığı kadarıyla kırpma işlemi ile birlikte VGG16 modelinden elde edilen özneliklerin sınıflandırılmasında SVM sınıflandırıcısı diğerlerine göre daha iyi sonuç vermektedir. Fakat AP ve AUC değerleri dikkate alındığında bu şartlar altında LSTM sınıflandırıcısının da kullanılabilir olduğu söylenebilir. Kırpma işlemi uygulanmayacak ise SVM sınıflandırıcısı diğer sınıflandırıcılara göre en iyi sonucu vermektedir. İlgili değerler **Tablo 6.2.2.1** ve **Tablo 6.2.2.2**'te verilmektedir.


Tablo 6.2.2.1: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneliklerin sınıflandırma sonuçları

Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,76	0,70	0,02	0,82	0,86	0,76
KNN	0,70	0,65	0,04	0,79	0,78	0,70
LSTM	0,79	0,70	0,06	0,84	0,84	0,79
RNN	0,75	0,67	0,05	0,80	0,83	0,75
SVM	0,83	0,73	0,04	0,87	0,89	0,83

Tablo 6.2.2.2: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin sınıflandırma sonuçları


Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,81	0,77	0,02	0,86	0,87	0,81
KNN	0,67	0,63	0,03	0,78	0,80	0,67
LSTM	0,80	0,76	0,03	0,88	0,88	0,80
RNN	0,70	0,65	0,04	0,76	0,76	0,70
SVM	0,84	0,73	0,06	0,89	0,87	0,84

a) Resimler lezyon sınırlarına göre kırılmadan yapılan işlemlerin grafikleri




Şekil 6.15: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri

Şekil 6.15'te SVM'in çizdiği eğrinin en üstte kalarak başarılı bir değer elde ettiği KNN'in ise bazı eşik değerleri için diğerlerinden çok daha altta kaldığı görülüyor. Diğer modeller birbirine benzer eğriler çiziyor.




Şekil 6.16: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

Diğer modeller birbirine yakın eğriler çizerken SVM'in bazı eşik değerlerde onlardan uzaklaşmasının daha yüksek bir AUC değerini yakalamasını sağlamış olduğu Şekil 6.16'dan anlaşılıyor.




Şekil 6.17: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneteliklerin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Şekil 6.17'ye göre eğitim aşamasında RNN gayet düzgün bir doğruluk eğrisi çizerken CNN ve LSTM kararlı bir iyileşme gösteriyor.




Şekil 6.18: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneteliklerin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri

Şekil 6.18'e göre doğrulama aşamasında LSTM daha iyi bir eğri çizerken bir devirden sonra RNN iyileşmeyi durduruyor, CNN ise kararlı bir iyileşme göstermesine rağmen LSTM'deki doğruluk değerini yakalayamıyor.




Şekil 6.19: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneteliklerin sınıflandırma sonuçlarının model eğitim kayıp eğrileri

Şekil 6.19'a göre eğitim aşamasında RNN, beklendiği gibi doğruluk eğrisine benzer bir kayıp eğrisi çiziyor. CNN'in ise yetersiz bir kayıp eğrisi çizdiği yani yeterince öğrenemediği, LSTM'in ise belli bir eğimle öğrenmeye devam ettiği görülüyor.



Şekil 6.20: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneteliklerin sınıflandırma sonuçlarının model sağlama kayıp eğrileri


Doğrulama aşamasında LSTM'in çizdiği kayıp eğrisi ilerleyen devirlerde öğrenmeye devam ettiği, CNN'in öğrenmeyi azalttığı, RNN'in ise verileri ezberlemeye yatkınlaştığı Şekil 6.20'den anlaşılıyor.



Şekil 6.21: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının hata matrisleri


Şekil 6.21'deki hata matrislerine bakıldığında CNN'in daha kararlı bir model olduğu fakat SVM'in daha fazla doğru tahminde bulunduğu anlaşılıyor. KNN hasta örnekleri sağlıklı olarak sınıflandırmaya yatkınlaştığı, LSTM ve RNN'in ise sağlıklı örnekleri hasta olarak sınıflandırmaya yatkınlaştığı görülüyor.

b) Resimler lezyon sınırlarına göre kırılarak yapılan işlemlerin grafikleri




Şekil 6.22: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri

KNN ve RNN'in daha düşük bir performans sergilediği LSTM, CNN ve SVM'in daha üstte kalan bir eğri çizdiği Şekil 6.22'den anlaşılıyor. Bazı eşik değerler için CNN ve LSTM daha iyi sonuç verirken diğer bazı eşik değerler içinse SVM daha iyi sonuç vermiş ve neticede benzer AP değerlerine ulaşmış durumdadır.




Şekil 6.23: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

SVM'in daha iyi bir performans sergilediği Şekil 6.23'ten anlaşılabilir. Genel olarak CNN'in benzer bir performans sergilediği ve LSTM'in sadece bazı eşik değerlerinde SVM'i geçebildiği görülüyor. KNN ve RNN ise karşılaştırılmayacak kadar alta kalıyorlar.




Şekil 6.24: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Eđitim ařamasında LSTM kararlı bir řekilde yükselirken CNN'in bir müddet sonra öğrenmeyi durdurduđu RNN'in ise en yüksek öğrenme deđerine ulařtıđı ve orada sabitlendiđi **řekil 6.24**'ten anlařılıyor.



řekil 6.25: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri


řekil 6.25'e göre doğrulama ařamasında LSTM ve CNN benzer bir eğri çizerken RNN ise daha aşağıda kalıyor ve eğitim ařamasındaki başarıyı gösteremiyor. Buradan RNN'in aslında eğitim ařamasında doğru bir öğrenme yapmadıđı anlařılıyor.



řekil 6.26: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özniteliklerin sınıflandırma sonuçlarının model eğitim kayıp eğrileri


řekil 6.26'da eğitim ařamasındaki kayıp deđeri eğrilerinden RNN'in eğitim ařamasında tam doğruluđa ulaşmasının etkisiyle kayıp deđeri düşüremediđi ve bir

müddet sonra öğrenmeyi durdurduğu görülüyor. CNN dik bir iniş sergilerken LSTM daha düzgün bir eğri çiziyor.



Şekil 6.27: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının model sağlama kayıp eğrileri

Şekil 6.27’de doğrulama aşamasındaki kayıp değeri eğrilerinden RNN ve CNN’in daha çok ezbere yatkınlaştığı LSTM’in ise daha doğru öğrendiği anlaşılıyor.



Şekil 6.28: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin sınıflandırma sonuçlarının hata matrisleri

Şekil 6.28’deki hata matrislerinden en kararlı ve doğru sonucu veren modelin SVM olduğu anlaşılıyor. LSTM, CNN ve RNN’in hasta örnekleri sağlıklı olarak tanımaya

yatkınlaştığı görülüyor. KNN de bu oran çok fazla olduğu için modelin doğru tanımladığı sağlıklı örneklerle de şüphe ile yaklaşmak gerekiyor.

6.2.3.Gri seviyesi eş dizilim matrisi özneliklerinin sınıflandırılması

Gri seviyesi eş dizilim matrisinden elde edilen özneliklerin lezyon sınırlarına göre kırpma işlemi yapmadan sınıflandırılmasında en yüksek doğruluk 0.70, en yüksek f1 puanı 0.70, en yüksek ortalama doğruluk 0.65, en yüksek AUC değeri 0.77 ve en yüksek AP değeri 0.75 ile SVM sınıflandırıcı kullanılarak elde edilmiştir. Bu durumda dermoskopik resimlerin lezyon sınırlarına göre kırılmadan gri değeri eş dizilim matrisine göre sınıflandırılması istendiğinde SVM kullanmanın diğer modellere göre daha faydalı olduğunu söylemek mümkündür. Kaynak resimlere lezyon sınırlarına göre kırpma işlemi uygulanarak yapılan sınıflandırmada ise en yüksek doğruluk ve en yüksek f1 puanı 0.69 olmak üzere RNN ile, en yüksek ortalama doğruluk 0.62, en yüksek AUC ve en yüksek AP değeri 0.72 olmak üzere SVM ile elde edilmiştir. Kırpma işlemi CNN kullanıldığında en yüksek doğruluk değeri, ortalama doğruluk değeri ve f1 puanını %1 düşürmüştür, AUC ve AP değerleri etkilenmemiştir. KNN kullanıldığında ortalama doğruluk %1 artarken en yüksek doğruluk %1, f1 puanı %1, AUC değeri %6 ve AP değeri %4 düşmüştür. LSTM kullanıldığında en yüksek doğruluk ve f1 puanı %6, ortalama doğruluk %2, AUC değeri %9 ve AP değeri ise %7 düşmüştür. RNN kullanıldığında en yüksek doğruluk, f1 puanı ve AUC değeri %3 artarken ortalama doğruluk %2 ve AP değeri %7 düşmüştür. SVM kullanıldığında ise en yüksek doğruluk ve f1 puanı %2, ortalama doğruluk ve AP değeri %3 ve AUC değeri %5 düşmüştür. Bu değerlere göre RNN en yüksek doğruluk değerini vermiş olduğu ve kırpma işlemi sonucunda bazı değerlerin iyileştiği görülmüş olduğu için ve fakat SVM ile elde edilen en yüksek doğruluk değeri 0.68 RNN'den sadece %1 az olduğu ve en yüksek ortalama doğruluk gibi diğer değerlendirme kriterlerinde SVM daha iyi sonuç elde ettiği için dermoskopik resimlerin lezyon sınırlarına göre kırılarak gri değeri eş dizilim matrisine göre sınıflandırılması istendiğinde de SVM veya RNN kullanmak benzer derecede faydalıdır denilebilir. İlgili değerler **Tablo 6.2.3.1** ve **Tablo 6.2.3.2**'da verilmektedir.


Tablo 6.2.3.1: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçları

Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,66	0,61	0,04	0,67	0,66	0,66
KNN	0,63	0,55	0,04	0,66	0,68	0,63
LSTM	0,69	0,62	0,04	0,72	0,69	0,69
RNN	0,66	0,63	0,02	0,67	0,73	0,66
SVM	0,70	0,65	0,03	0,77	0,75	0,70

Tablo 6.2.3.2: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçları


Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,65	0,60	0,03	0,67	0,66	0,65
KNN	0,62	0,56	0,04	0,60	0,62	0,62
LSTM	0,63	0,60	0,02	0,63	0,62	0,63
RNN	0,69	0,61	0,04	0,70	0,66	0,69
SVM	0,68	0,62	0,05	0,72	0,72	0,68

a) Resimler lezyon sınırlarına göre kırılmadan yapılan işlemlerin grafikleri



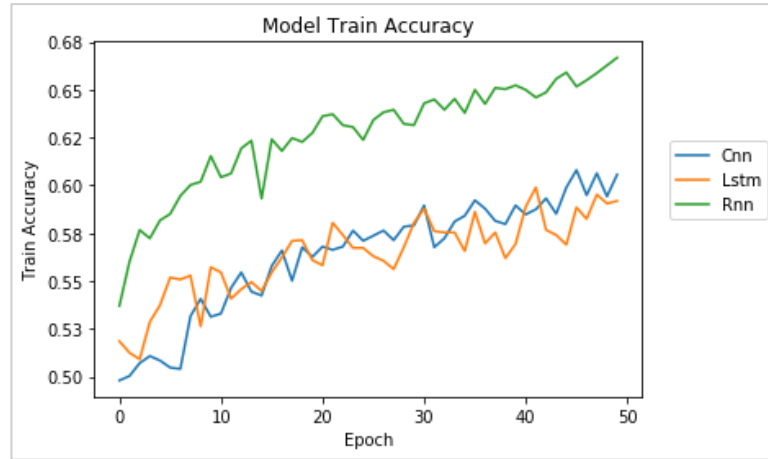
Şekil 6.29: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri

Şekil 6.29’da bazı eşik değerler için CNN ve LSTM diğerlerinden daha kötü bir performans gösterirken bazı eşik değerler için RNN’in ve bazı eşik değerler için ise SVM’in daha iyi bir eğri çizdiği fakat SVM’in daha yüksek bir puan elde ettiği görülüyor.




Şekil 6.30: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özneliklerinin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

Şekil 6.30'da SVM'in genel olarak daha üstte bir eğri çizdiği ve CNN, KNN ve RNN'in ise daha altta örtüşen eğriler çizdikleri görülüyor.




Şekil 6.31: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özneliklerinin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Şekil 6.31'e göre eğitim aşamasında RNN daha üstte bir doğruluk değeri eğrisi çiziyor fakat eğrilerin birbirine paralel olması ve bir düzen içerisinde yükselmesi üç modelinde bu öznelikleri öğrenebildiğini gösteriyor.




Şekil 6.32: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri

Doğrulama aşamasında LSTM modelinin daha iyi öğrendiği Şekil 6.32'den anlaşılıyor. CNN ve RNN öğrenmeye devam etmelerine rağmen yeterli iyileşmeyi gösteremiyorlar.




Şekil 6.33: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının model eğitim kayıp eğrileri

Şekil 6.33'te eğitim aşamasında üç modelin de kayıp değerlerini azaltmaya devam ettiği görülüyor. RNN'in daha iyi eğitim aşamasında diğerlerinden daha iyi öğrendiğini söylemek mümkün.



Şekil 6.34: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özneliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri


Şekil 6.34'te doğrulama aşamasında LSTM'in kayıp değerini daha iyi düşürebildiği RNN'in ise daha düz bir eğri çizdiği görülebiliyor, CNN ise önce kayıp değerini düşürmeyi başarırken ilerleyen devirlerde çizdiği eğri düzleşiyor. Buradan LSTM'in daha iyi öğrendiği anlaşılıyor.



Şekil 6.35: Resimler lezyon sınırlarına göre kırılmadan elde edilen Gri Değeri Eş Dizilim Matrisi özneliklerinin sınıflandırma sonuçlarının hata matrisleri


Şekil 6.35'teki hata matrislerinden SVM ve LSTM modellerinin daha kararlı olduğu görülüyor. CNN ve KNN sağlıklı örnekleri hasta olarak sınıflandırmaya yatkınlaşırken RNN ise hasta örnekleri sağlıklı olarak sınıflandırmaya yatkınlık gösteriyor.

b) Resimler lezyon sınırlarına göre kırılarak yapılan işlemlerin grafikleri




Şekil 6.36: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri

Bazı eşik değerler için SVM dışındaki modellerin iyi sonuçlar elde edemediği ve bunun dışında kalan değerler için benzer bir eğri çizdikleri fakat SVM'in üstte kalarak en yüksek puanı aldığı Şekil 6.36'dan anlaşılıyor




Şekil 6.37: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özniteliklerinin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

Bütün modellerin benzer bir eğri çizdiği Şekil 6.37’de görülebiliyor. SVM bariz şekilde üstte olmamasına rağmen diğerlerinden daha iyi bir puan aldığı lejan’ta görülebiliyor. Bu grafiğe bakarak bu veri kümesinin bu yöntem ve bu öznelilikler modelden bağımsız olarak sonuç vermektedir denilebilir.




Şekil 6.38: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özneliliklerinin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Eğitim aşamasında üç modelin de düzgün bir eğri çizerek öğrenmeye devam ettikleri, RNN’in daha üstte kaldığı ve daha yüksek bir doğruluk değerine ulaştığı Şekil 6.38’de görülebiliyor.




Şekil 6.39: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özneliliklerinin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri

Şekil 6.39'a göre doğrulama aşamasında LSTM ve CNN ilerleyen devirlerde iyileşme gösteremezken RNN'in sağladığı doğruluk oranı kararsız olsa da artarak yükseliyor ve eğitim aşamasında olduğu gibi en yüksek değeri elde ediyor.




Şekil 6.40: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özneliklerinin sınıflandırma sonuçlarının model eğitim kayıp eğrileri

Şekil 6.40'dan eğitim aşamasında kayıp değeri eğrilerinin üç modelde de düzgün şekilde aşağı yönde ilerlediği ve öğrenmenin devam ettiği anlaşılıyor. RNN'in diğerlerinden daha dik bir iniş göstermesi ve daha aşağıda bir eğri çizmesi daha iyi öğrendiğini gösteriyor.



Şekil 6.41: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özneliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri

Doğrulama aşamasında RNN'in düzgün bir iniş göstererek öğrenmeyi sürdürürken CNN ve LSTM'in ise ilerleyen devirlerde düz bir çizgiye doğru evrildiği ve öğrenmeyi durdurduğu Şekil 6.41'den anlaşılıyor.



Şekil 6.42: Resimler lezyon sınırlarına göre kırılarak elde edilen Gri Değeri Eş Dizilim Matrisi özneliklerinin sınıflandırma sonuçlarının hata matrisleri

Şekil 6.42'deki hata matrislerinden LSTM'in en kararlı model olduğu, RNN'in en yüksek doğruluk oranını verdiği ve SVM'in onun hemen arkasında olduğu, SVM'in hasta örnekleri sağlıklı olarak göstermeye yatkınlığı olduğu, RNN'in ise sağlıklı örnekleri hasta olarak tanımaya yatkınlaştığı, CNN'in de LSTM'e benzer bir kararlılıkta olduğu, KNN'in ise hem kararsız hem de hasta örnekleri sağlıklı olarak tanımaya yatkın olduğu anlaşılıyor.

6.2.4.InceptionV3 modelinden elde edilen özneliklerin gri değeri eş dizilim matrisi öznelikleri ile birlikte sınıflandırılması

InceptionV3 modelinden ve gri seviyesi eş dizilim matrisinden elde edilen özneliklerin birlikte lezyon sınırlarına göre kırma işlemi yapmadan sınıflandırılmasında en yüksek doğruluk ve en yüksek f1 puanı 0.75, en yüksek ortalama doğruluk 0.71, en yüksek AUC değeri 0.85 ve en yüksek AP değeri 0.86 olmak üzere LSTM ile elde edilmiştir. Bu durumda bu iki öznelik bir arada

kullanıldığında LSTM modelini kullanmak faydalıdır denilebilir. Bu değerler yukarıda da belirtilmiş olan InceptionV3 özneliklerinin ve gri değeri eş dizilim matrisi özneliklerinin ayrı ayrı sınıflandırılmasından elde edilen değerlere göre daha yüksek olduğu için bu iki özneliğin bir arada kullanılması da daha faydalıdır denilebilir. Zira bu iki öznelik bir arada kullanıldığında InceptionV3 modeline göre en yüksek doğruluk ve f1 puanı %2, en yüksek ortalama doğruluk %3, AUC değeri %9 ve AP değeri %12 artış gösterirken, gri değeri eş dizilim matrisine göre ise en yüksek doğruluk %5, en yüksek ortalama doğruluk %6, AUC değeri %8 ve AP değeri %11 yükselmiştir. Kaynak resimler lezyon sınırlarına göre kırılarak yapılan sınıflandırmada ise en yüksek doğruluk ve f1 puanı 0.76, en yüksek AUC ve AP değerleri 0.79 olmak üzere LSTM tarafından elde edilirken en yüksek ortalama doğruluk değeri 0.69 ile LSTM, CNN ve RNN tarafından elde edilmiştir. Kırma işlemi LSTM modelinde en yüksek doğruluğu ve en yüksek f1 puanını %1 yükseltirken en yüksek ortalama doğruluğu %2, en yüksek AUC ve AP değerini %5 düşürmüştür. RNN kullanıldığında kırma işlemi en yüksek doğruluğu ve f1 puanını %8, en yüksek ortalama doğruluğu ve en yüksek AUC değerini %4, en yüksek AP değerini ise %5 yükseltmiştir. SVM kullanıldığında en yüksek doğruluk %4, en yüksek f1 puanı %3, en yüksek AUC değeri %5 ve en yüksek AP değeri %2 düşerken ortalama doğruluk değeri değişmemiştir. KNN ile en yüksek doğruluk ve f1 puanı %4, ortalama doğruluk %1, en yüksek AUC değeri %3 ve en yüksek AP değeri %2 yükselmiştir. CNN kullanıldığında ise en yüksek doğruluk ve f1 puanı %2, ortalama doğruluk, en yüksek AUC değeri ve en yüksek AP değeri %1 yükselmiştir. Bu verilere bakılarak bu iki öznelik bir arada kullanıldığında kırma işlemi yapılacaksa RNN veya CNN kullanılmasının değerlendirilmesinin uygun olacağı fakat her iki durumda da LSTM'in daha iyi sonuç verdiği söylenebilir. Kırma işlemi KNN sınıflandırıcısında da olumlu etki göstermesine rağmen alınan sonuç tatmin edici değildir. SVM ise kırma işleminden olumsuz etkilenmiştir. İlgili değerler **Tablo 6.2.4.1** ve **Tablo 6.2.4.2**'de verilmektedir.


Tablo 6.2.4.1: Resimler lezyon sınırlarına göre kırpılmadan InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçları

Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,72	0,68	0,03	0,76	0,76	0,72
KNN	0,65	0,63	0,02	0,71	0,72	0,65
LSTM	0,75	0,71	0,03	0,85	0,86	0,75
RNN	0,67	0,65	0,02	0,75	0,74	0,67
SVM	0,72	0,65	0,04	0,75	0,72	0,71

Tablo 6.2.4.2: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçları


Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,74	0,69	0,03	0,77	0,77	0,74
KNN	0,69	0,64	0,03	0,74	0,74	0,69
LSTM	0,76	0,69	0,03	0,80	0,81	0,76
RNN	0,75	0,69	0,03	0,79	0,79	0,75
SVM	0,68	0,65	0,03	0,70	0,70	0,68

a) Resimler lezyon sınırlarına göre kırılmadan yapılan işlemlerin grafikleri




Şekil 6.43: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri

Bazı eşik değerler için SVM ve RNN'in daha başarısız olduğu, LSTM'in ise genel olarak diğer modellerden çok daha üstte kalarak en iyi sonucu elde ettiği Şekil 6.43'ten anlaşılıyor.




Şekil 6.44: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

Şekil 6.44'ten bütün modellerin benzer bir eğri çizdiği fakat LSTM'in en iyi eğriyi çizerek en üstte kaldığı anlaşılıyor.




Şekil 6.45: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Eğitim aşamasında LSTM ve CNN benzer şekilde yükselen bir eğri çizirken RNN ise erkenden tepe noktaya ulaşarak eğitimi durdurduğu Şekil 6.45'ten anlaşılıyor.



Şekil 6.46: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model sağlama doğruluk eğrileri


Şekil 6.46'ya göre doğrulama aşamasında RNN ve CNN birbiriyle örtüşen ve ilerleyen devirlerde düzleşen bir eğri çizerken LSTM daha üstte kalan ve yükselmeye devam eden bir eğri çiziyor. CNN ve RNN eğitim aşamasında gösterdikleri başarıyı doğrulama aşamasında göstermezken LSTM doğrulama aşamasında da başarılı oluyor. Buradan LSTM modelinin bu öznelikleri daha iyi öğrendiği anlaşılıyor.



Şekil 6.47: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model eğitim kayıp eğrileri


Şekil 6.47'ye göre eğitim aşamasında RNN kayıp değerini azaltmaya devam edemiyor CNN ve LSTM ise düzenli şekilde kayıp değerini azaltmaya devam ediyor. Buradan

RNN için daha farklı kayıp değeri parametreleri ve kayıp fonksiyonları denenebileceği anlaşılabilir.



Şekil 6.48: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model sağlama kayıp eğrileri


Şekil 6.48'e göre doğrulama aşamasında CNN ve RNN kayıp değerlerini düşüremezken LSTM kayıp değerini dik şekilde azaltmaya devam edebiliyor. Bu durumda LSTM modelinin daha uzun devirler eğitilebileceği anlaşılabilir.




Şekil 6.49: Resimler lezyon sınırlarına göre kırılmadan InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının hata matrisleri

Şekil 6.49'daki hata matrislerinden bu özniteliklere göre en kararlı modelin KNN, en yararlı modelin ise LSTM olduğu anlaşılabilir. CNN de LSTM'e benzer rakamlar elde etse de toplam doğru değeri düşük kalıyor. SVM ve RNN'in sağlıklı örnekleri hasta olarak tanımaya yatkın olduğu görülebiliyor.

b) Resimler lezyon sınırlarına göre kırılarak yapılan işlemlerin grafikleri




Şekil 6.50: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri



Şekil 6.51: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri


Bazı eşik değerler için SVM ve RNN kötü sonuç elde ederken RNN diğer eşik değerlerinde iyi sonuçlar alarak farkı kapatmış ve en yüksek AP değerini elde eden

LSTM'e yaklaşmıştır. SVM ve KNN'in en altta kaldığı da **Şekil 6.50**'de görülebilmektedir. Bütün modeller benzer bir eğri çizmelerine rağmen LSTM modelinin daha üstte olduğu **Şekil 6.51**'den ve şekildeki lejanttan anlaşılabilir.




Şekil 6.52: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Eğitim aşamasında RNN tepe noktaya ulaşip öğrenmeyi durdururken LSTM ve CNN'in öğrenmeye devam ettiği **Şekil 6.52**'den anlaşılmaktadır.




Şekil 6.53: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model sağlama doğruluk eğrileri

Şekil 6.53'te doğrulama aşamasında RNN ve CNN'in belli bir devirden sonra öğrenmeyi durdurduğu LSTM'in ise öğrenmeye devam ettiği görülmektedir. En yüksek doğruluk değerine LSTM'in ulaştığı da grafikten okunabilmektedir.



Şekil 6.54: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model eğitim kayıp eğrileri

Eğitim aşamasında RNN kayıp değerini iyileştiremezken CNN ve LSTM'in kayıp değerini iyileştirmeye devam ettiği Şekil 6.54'ten anlaşılıyor.



Şekil 6.55: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model sağlama kayıp eğrileri

Şekil 6.55'e göre doğrulama aşamasında CNN'in kayıp değeri, önce düşüp sonra yükselerek örnekleri ezberlemeye yatkınlaştığını göstermiştir. LSTM ve RNN ise

kayıp değerini bir noktaya kadar iyileştirmeye devam etmiş ve sonrasında öğrenmeyi durdurmuşlardır.



Şekil 6.56: Resimler lezyon sınırlarına göre kırılarak InceptionV3 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının hata matrisleri

Şekil 6.56'daki hata matrislerinden en kararlı modelin CNN olduğu fakat LSTM'in ise daha çok doğru tahminde bulunduğu, KNN ve SVM hasta örnekleri sağlıklı olarak sınıflandırmaya yatkınlaştığı, RNN'in ise kararsız olmasına rağmen yüksek doğruluk payına sahip olduğu anlaşılıyor.

6.2.5.VGG16 modelinden elde edilen özneliklerin gri değeri eş dizilim matrisi öznelikleri ile birlikte sınıflandırılması

VGG16 modelinden ve gri seviyesi eş dizilim matrisinden elde edilen özneliklerin birlikte lezyon sınırlarına göre kırma işlemi yapmadan sınıflandırılmasında en yüksek doğruluk ve f1 puanı 0.82, en yüksek AUC değeri 0.87 ve en yüksek AP değeri 0.88 olmak üzere LSTM sınıflandırıcısı ile elde edilirken en yüksek ortalama doğruluk değeri 0.76 olmak üzere LSTM ve CNN ile elde edilmiştir. Bu durumda bu iki öznelik bir arada kullanıldığında LSTM modelini kullanmak faydalıdır denilebilir. Bu değerler VGG16 modelinden elde edilen özneliklerin sınıflandırmasında elde edilen en yüksek değerlerden daha yüksek olmadığından lezyon sınırlarına göre

kırpma işlemi yapmadan sınıflandırma yapıldığında bu iki özneliği bir arada kullanmak sadece VGG16 özneliklerini kullanmaktan daha faydalıdır denilemez. Kaynak resimler lezyon sınırlarına göre kırılarak yapılan sınıflandırmada ise en yüksek doğruluk ve f1 puanı 0.80, en yüksek ortalama doğruluk 0.77, en yüksek AUC değeri 0.87 ve en yüksek AP değeri 0.89 olmak üzere CNN sınıflandırıcısı ile elde edilmiştir. Kırpma işlemi CNN kullanıldığında en yüksek doğruluk ve f1 puanını %1 düşürürken ortalama doğruluğu %1, AUC ve AP değerini ise %2 artırmıştır. KNN kullanıldığında ise en yüksek doğruluk ve f1 puanını %1, ortalama doğruluğu ve AUC değerini %2 düşürürken AP değerine etki etmemiştir. LSTM kullanıldığında kırpma işlemi en yüksek doğruluk ve f1 puanını %6, ortalama doğruluğu %2, AUC ve AP değerlerini ise %4 düşürmüştür. RNN kullanıldığında ise en yüksek doğruluk ve f1 puanını %2, ortalama doğruluğu %3, AUC ve AP değerini ise %4 yükseltmiştir. SVM kullanıldığında ise kırpma işlemi en yüksek doğruluğu etkilemezken ortalama doğruluğu ve AP değerini %1 artırmış ve AUC değerini %1 azaltmıştır. Bu veriler ışığında bu öznelikler kullanıldığında kırpma işleminin faydalı olduğunu söylemek mümkün değildir. Bu iki öznelik bir arada kullanılacaksa kırpma işlemi yapılması tavsiye edilemez ancak kırpma işlemi yapmadan bir arada kullanılmalarının CNN ve LSTM sınıflandırıcılarının sonuçlarında iyileştirme yaptığı söylenebilir. İlgili değerler **Tablo 6.2.5.1** ve **Tablo 6.2.5.2**'da verilmektedir.

Tablo 6.2.5.1: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçları


Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,81	0,76	0,03	0,85	0,87	0,81
KNN	0,69	0,66	0,03	0,79	0,78	0,69
LSTM	0,82	0,76	0,03	0,87	0,88	0,82
RNN	0,73	0,67	0,04	0,78	0,79	0,73
SVM	0,76	0,72	0,03	0,85	0,85	0,76

Tablo 6.2.5.2: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçları

Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,80	0,77	0,02	0,87	0,89	0,80
KNN	0,68	0,64	0,03	0,77	0,78	0,68


LSTM	0,76	0,74	0,02	0,83	0,84	0,76
RNN	0,75	0,70	0,04	0,82	0,83	0,75
SVM	0,76	0,73	0,03	0,84	0,86	0,76

a) Resimler lezyon sınırlarına göre kırılmadan yapılan işlemlerin grafikleri




Şekil 6.57: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri

Şekil 6.57’de RNN ve KNN eğrilerinin diğerlerinin çok altında kaldığı CNN, SVM ve LSTM’in ise üstte bir eğri çizdikleri görülebiliyor. LSTM’in daha yüksek bir AP değerine ulaştığı lejjanttan anlaşılıyor.




Şekil 6.58: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

CNN, LSTM ve SVM'in benzer bir eğri çizdiği **Şekil 6.58**'de görülüyor ve aynı AUC değerine ulaştığı lejanttan anlaşılıyor. RNN ve KNN ise daha altta kalan bir eğri çiziyor. Grafikten ve lejanttan LSTM'in daha iyi bir sonuç elde ettiği görülebiliyor.




Şekil 6.59: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Şekil 6.59'a göre eğitim aşamasında LSTM ve RNN benzer bir eğri çizerken CNN önce düz daha sonra yükselen bir eğri çiziyor. RNN ve CNN öğrenmeye devam ederken LSTM tepe noktaya erkenden ulaşarak öğrenmeyi durduruyor.




Şekil 6.60: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özniteliklerin Gri Değeri Eş Dizilim Matrisi öznitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama doğruluk eğrileri

Doğrulama aşamasında LSTM ve RNN belli bir devirden sonra öğrenmeyi durdururken CNN öğrenmeye devam ediyor. LSTM'in benzer bir doğruluğa CNN'den önce ulaştığı RNN'in ise bu ikisine yetişemediği **Şekil 6.60**'dan anlaşılıyor.



Şekil 6.61: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen öz niteliklerin Gri Değeri Eş Dizilim Matrisi öz nitelikleri ile birlikte sınıflandırma sonuçlarının model eğitim kayıp eğrileri


Şekil 6.61'e göre eğitim aşamasında LSTM ve RNN belli bir devirden sonra kayıp değerini azaltamıyor fakat CNN kayıp değerini dik bir eğri çizerek azaltmaya devam ediyor. Buradan üç model için de daha yüksek kayıp değeri ile eğitim yapılabileceği ayrıca CNN için daha uzun süre eğitim yapılabileceği anlaşılabilir.



Şekil 6.62: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen öz niteliklerin Gri Değeri Eş Dizilim Matrisi öz nitelikleri ile birlikte sınıflandırma sonuçlarının model sağlama kayıp eğrileri

Şekil 6.62'e göre doğrulama aşamasında kayıp değeri eğrisi LSTM modelinin veri kümesini ezberlediğine dair işaret verirken RNN eğitim aşamasında olduğu gibi kayıp değerini azaltmayı erkenden bırakıyor. CNN ise düzgün bir kayıp değeri eğrisi çiziyor.


Şekil 6.63'teki hata matrislerinden en kararlı modelin RNN olduğu anlaşılıyor. Diğer modellerin hasta örnekleri sağlıklı olarak tanımaya yatkınlaştığı görülüyor. Buna rağmen LSTM ve CNN modellerinin yanlış negatif sayısı RNN'den az olduğu için yine de tercih edilebilirler. LSTM modelinin veri modelini ezberlemeye yatkın olması da göz önüne alındığında bu özelliklerle CNN kullanılması da düşünülebilir.




Şekil 6.63: Resimler lezyon sınırlarına göre kırılmadan VGG16 modelinden elde edilen özelliklerin Gri Değeri Eş Dizilim Matrisi özellikleri ile birlikte sınıflandırma sonuçlarının hata matrisleri

b) Resimler lezyon sınırlarına göre kırılarak yapılan işlemlerin grafikleri


Şekil 6.64'ten bütün modellerin benzer bir eğri çizdiği fakat CNN'in daha üstte olduğu KNN'in ise diğerlerinden altta kaldığı görülebiliyor. Şekil 6.65'de ise KNN en altta eğri çizerken CNN'in diğer modellerden daha iyi ve üstte kalan eğriyi çizdiği görülebiliyor. Diğer modeller birbirleriyle örtüşen bir eğri çiziyorlar.



Şekil 6.64: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri




Şekil 6.65: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri




Şekil 6.66: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Eđitim ařamasında RNN'in daha dűzgűn bir eđri izdiđi fakat CNN ve LSTM'in de yűkselmeye devam eden bir eđri izdiđi ve ű modelin de đrenmeye devam ettiđi Őekil 6.66'dan anlařılıyor.




Őekil 6.67: Resimler lezyon sınırlarına gre kırılarak VGG16 modelinden elde edilen zniteliklerin Gri Deđeri Eř Dizilim Matrisi znitelikleri ile birlikte sınıflandırma sonularının model sađlama dođruluk eđrileri

Dođrulama ařamasında LSTM'in belirli bir devirden sonra đrenmeyi durdurduđu RNN ve CNN'in đrenmeye devam ettiđi Őekil 6.67'den anlařılıyor.




Őekil 6.68: Resimler lezyon sınırlarına gre kırılarak VGG16 modelinden elde edilen zniteliklerin Gri Deđeri Eř Dizilim Matrisi znitelikleri ile birlikte sınıflandırma sonularının model eđitim kayıp eđrileri

Eđitim ařamasında RNN daha dűzgűn bir kayıp deđeri eđrisi izerken ű modelin de kayıp deđerini azaltmaya devam ettiđi Őekil 6.68'den anlařılıyor.



Şekil 6.69: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının model sağlama kayıp eğrileri

Şekil 6.69'a göre doğrulama aşamasında RNN kayıp değerini azaltmayı durdururken LSTM ve CNN kayıp değerini azaltmaya devam ediyor.



Şekil 6.70: Resimler lezyon sınırlarına göre kırılarak VGG16 modelinden elde edilen özneliklerin Gri Değeri Eş Dizilim Matrisi öznelikleri ile birlikte sınıflandırma sonuçlarının hata matrisleri

Şekil 6.70'deki hata matrislerinden en kararlı modelin RNN olduğu diğer modellerin hasta örnekleri sağlıklı olarak tanımaya yatkınlaştığı anlaşılıyor. CNN modelinin daha fazla örneği doğru tanıdığı yanlış negatif değerinin RNN'den az olduğu görülebiliyor.

Bu durumda bu öznelikleri sınıflandırma için CNN tercih edilebileceği gibi RNN kullanılması da düşünülebilir demek yanlış olmaz. KNN modelinin hasta örnekleri sağlıklı olarak tanımayaya yatkınlığı çok fazla olduğu için elde ettiği doğruluk payına da şüpheyile yaklaşmak gerekiyor.

6.2.6.Resim piksel özneliklerinin sınıflandırılması

Resim piksel özneliklerinin lezyon sınırlarına göre kırpma işlemi yapmadan sınıflandırılmasında en yüksek doğruluk ve f1 puanı 0.82, en yüksek ortalama doğruluk 0.77, en yüksek AUC değeri 0.87 ve en yüksek AP değeri 0.88 olmak üzere VGG16 sınıflandırıcısının ‘fine tune’ metodu ile kullanılması sonucu elde edilmiştir.

Kaynak resimler lezyon sınırlarına göre kırılarak yapılan sınıflandırmada ise en yüksek doğruluk ve f1 puanı 0.84, en yüksek ortalama doğruluk 0.80, en yüksek AUC değeri 0.89 ve en yüksek AP değeri 0.91 olmak üzere yine VGG16 sınıflandırıcısının ‘fine tune’ metodu ile kullanılması sonucu elde edilmiştir. Bu durumda VGG16 sınıflandırıcısı ‘fine tune’ metodu ile kullanıldığında lezyon sınırlarına göre kırpma işlemi en yüksek doğruluğu ve f1 puanını %2, en yüksek ortalama doğruluğu %3, en yüksek AUC değerini %2 ve en yüksek AP değerini %3 artırdığı için lezyon sınırlarına göre kırpma işlemi resim piksel özneliklerinin sınıflandırılmasında VGG16 sınıflandırıcısı ‘fine tune’ metodu ile kullanıldığında faydalıdır denilebilir. Kırpma işlemi CNN kullanıldığında en yüksek doğruluğu %4 ve f1 puanını %3 düşürürken ortalama doğruluk, en yüksek AUC ve en yüksek AP değerlerini %1 yükseltmiştir. VGG16 sınıflandırıcısının ‘transfer’ metodu ile kullanılmasında ise kırpma işlemi en yüksek doğruluk ve f1 puanını %3, ortalama doğruluk, en yüksek AUC ve en yüksek AP değerlerini %1 yükseltmiştir. InceptionV3 sınıflandırıcısı ‘transfer’ metodu ile kullanıldığında kırpma işlemi en yüksek doğruluğu ve f1 puanını %3, en yüksek AUC değerini %1 ve en yüksek AP değerini %2 düşürürken ortalama doğruluğu %1 yükseltmiştir. InceptionV3 sınıflandırıcısı ‘fine tune’ metodu ile kullanıldığında kırpma işlemi en yüksek doğruluğu ve f1 puanını %7, ortalama doğruluğu %2, en yüksek AP değerini ise %1 düşürürken en yüksek AUC değerini değiştirmemiştir. KNN sınıflandırıcısı kullanıldığında en yüksek doğruluk %3, f1 puanı %2 ve en yüksek AUC değeri %2 artarken ortalama doğruluk %1 azalmış ve en yüksek AP değeri değişmemiştir. LSTM sınıflandırıcısı kullanıldığında en yüksek doğruluk ve f1

puanı %5, ortalama doğruluk ve en yüksek AP değeri %2, en yüksek AUC değeri ise %4 yükselmiştir. RNN kullanıldığında en yüksek doğruluk ve f1 puanı %1 düşerken ortalama doğruluk %1 ve en yüksek AP değeri ise %3 artmış en yüksek AUC değeri ise değişmemiştir. SVM kullanıldığında ise en yüksek doğruluk, f1 puanı ve en yüksek AUC değeri %2 ve en yüksek AP değeri %1 artarken ortalama doğruluk değişmemiştir. Bu veriler ışığında lezyon resimlerinin sınıflandırılmasında resim piksel öznitelikleri kullanılıyorsa kırpma işlemi uygulayarak VGG16 sınıflandırıcısının ‘fine tune’ metodu ile kullanılması tavsiye edilebilir. İlgili değerler **Tablo 6.2.6.1** ve **Tablo 6.2.6.2**’de verilmektedir.


Tablo 6.2.6.1: Resimler lezyon sınırlarına göre kırpılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçları

Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,80	0,70	0,04	0,82	0,81	0,79
CNN VGG16 Transfer	0,79	0,75	0,02	0,84	0,84	0,79
CNN VGG16 Fine Tune	0,82	0,77	0,03	0,87	0,88	0,82
CNN InceptionV3 Transfer	0,76	0,66	0,06	0,78	0,76	0,76
CNN InceptionV3 Fine Tune	0,77	0,69	0,05	0,78	0,79	0,76
KNN	0,65	0,62	0,03	0,71	0,74	0,65
LSTM	0,69	0,64	0,04	0,75	0,74	0,69
RNN	0,66	0,60	0,04	0,67	0,67	0,66
SVM	0,63	0,59	0,03	0,68	0,70	0,63

Tablo 6.2.6.2: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçları


Classifier	Max Acc	Mean Acc	Std	Auc	Ap	F1 Score
CNN	0,76	0,71	0,03	0,83	0,82	0,76
CNN VGG16 Transfer	0,82	0,76	0,04	0,85	0,85	0,82
CNN VGG16 Fine Tune	0,84	0,80	0,03	0,89	0,91	0,84
CNN InceptionV3 Transfer	0,73	0,67	0,03	0,77	0,74	0,73
CNN InceptionV3 Fine Tune	0,70	0,67	0,02	0,78	0,78	0,69
KNN	0,68	0,61	0,04	0,73	0,74	0,67
LSTM	0,74	0,66	0,03	0,79	0,76	0,74
RNN	0,65	0,61	0,04	0,67	0,70	0,65
SVM	0,65	0,59	0,05	0,70	0,71	0,65

a) Resimler lezyon sınırlarına göre kırılmadan yapılan işlemlerin grafikleri



Şekil 6.71: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel öz niteliklerinin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri


Bazı eşik değerler için VGG16 Transfer modeli başarılı olamadığı için VGG16 Fine Tune modelinin altında kaldığı, VGG16 Fine Tune modelinin en iyi sonucu elde ettiği, diğer modellerin ise benzer eğriler çizerken SVM ve RNN'in en düşük sonucu elde ettiği Şekil 6.71'den anlaşılıyor.



Şekil 6.72: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel öz niteliklerinin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri


Şekil 6.72'de VGG16 Fine Tune modelinin iyi sonucu elde ettiği, bazı eşik değerlerde VGG16 Transfer modelinin daha iyi sonuç elde etmesine rağmen genel olarak VGG16 Fine Tune modelinin daha üstte olduğu görülüyor. VGG16 Fine Tune modelinin

grafığın sol altında ve sağ üstünde en sınır noktaya yaslanmış olması ve düz bir çizgi çizmesi yüksek oranda başarılı olduğunun da bir göstergesi.



Şekil 6.73: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri


Eğitim aşamasında RNN dışındaki bütün modellerin öğrenmeye devam ettikleri, CNN Scratch modelinin eğitim aşamasında daha başarılı olduğu InceptionV3 Fine Tune ve VGG16 Fine Tune modellerinin onu takip ettikleri **Şekil 6.73**'ten anlaşılıyor.



Şekil 6.74: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri


Doğrulama aşamasında VGG16 Fine Tune ve VGG16 Transfer modellerinin daha başarılı olduğu fakat belirli bir devirden sonra öğrenmeyi azalttıkları **Şekil 6.74**'ten anlaşılıyor. InceptionV3 modelleri eğitim aşamasında gösterdikleri başarıyı doğrulama aşamasında gösteremedikleri ve eğitim aşamasında doğru bir öğrenme

işlemi yapmadıkları anlaşılıyor. RNN ve LSTM belirli bir devirden sonra öğrenmeyi durdururken diğer modellerin öğrenmeye devam ettikleri görülüyor.



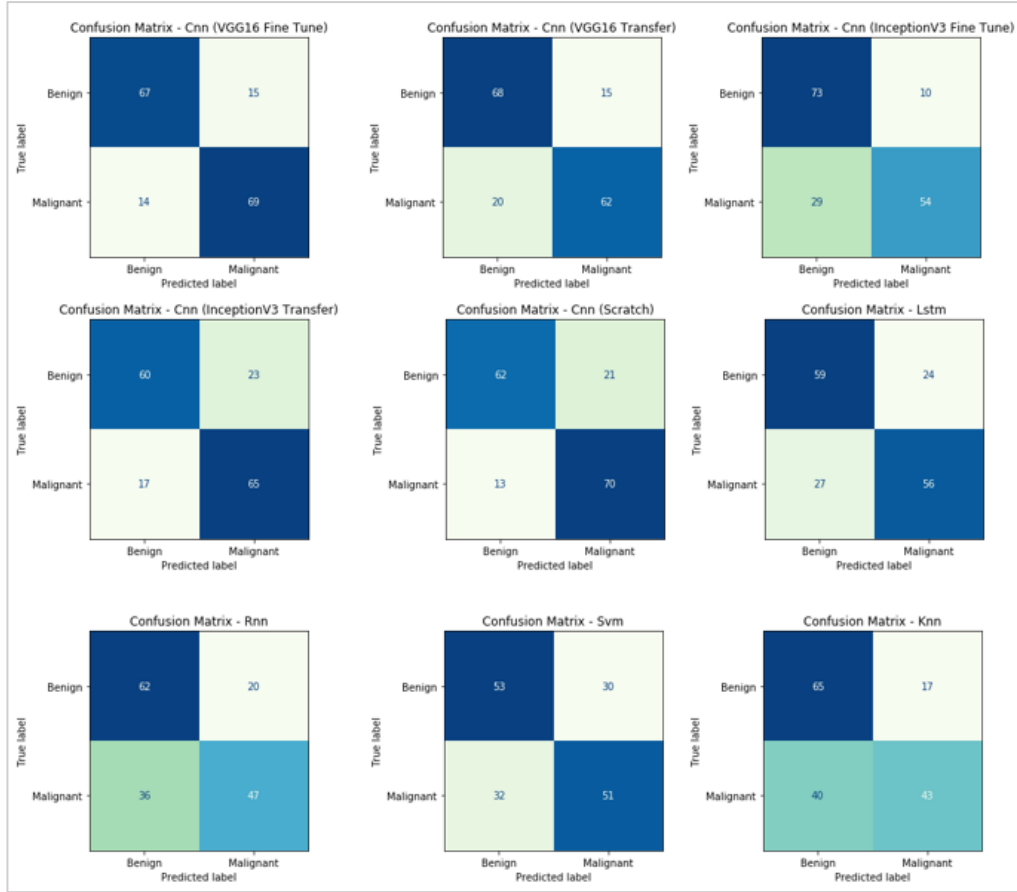
Şekil 6.75: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özelliklerinin sınıflandırma sonuçlarının model eğitim kayıp eğrileri. Bu grafikteki aykırı değerler diğerlerinin daha iyi anlaşılması için yok sayılmıştır.

Şekil 6.75’den RNN ve LSTM dışındaki modellerin kayıp değerini azaltmaya devam ettiği CNN Scratch, VGG16 Fine Tune ve InceptionV3 Fine Tune modellerinin eğitim aşamasında kayıp değerini daha iyi azalttıkları anlaşılıyor.



Şekil 6.76: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özelliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri

Doğrulama aşamasında VGG16 Fine Tune modelinin kayıp değerini diğer modellere göre daha iyi azalttığı Şekil 6.76’dan anlaşılıyor. InceptionV3 Fine Tune modeli eğitim aşamasındaki başarısını doğrulama aşamasında gösteremiyor.




Şekil 6.77: Resimler lezyon sınırlarına göre kırılmadan ham resim piksel özneliklerinin sınıflandırma sonuçlarının hata matrisleri


Şekil 6.77'deki hata matrislerinden en kararlı modelin VGG16 Fine Tune olduğu anlaşılıyor. SVM ve LSTM modellerinin de kararlı olduğu fakat doğru sayısının daha az olduğu görülüyor. InceptionV3 Fine Tune, VGG16 Transfer, RNN ve KNN modellerinin hasta örnekleri sağlıklı olarak tanımaya yatkın olduğu CNN Scratch ve InceptionV3 Transfer modellerinin ise sağlıklı örnekleri hasta olarak sınıflandırmaya yatkınlaştığı anlaşılıyor. Bu durumda lezyon resimlerinin kırpma işlemine tabi tutulmadan sınıflandırılmasında VGG16 sınıflandırıcısının Fine Tune metodu ile kullanılması uygundur denilebilir.

b) Resimler lezyon sınırlarına göre kırılarak yapılan işlemlerin grafikleri

Şekil 6.78'den VGG16 Fine Tune modelinin en üstte düz bir çizgi çizerek iyi bir performans sergilediği diğer modellerin onun altında kaldığı görülebiliyor. VGG16 Transfer modelinin de diğer modellerden üstte bir eğri çizdiği grafikten anlaşılıyor.




Şekil 6.78: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının kesinlik duyarlılık eğrileri




Şekil 6.79: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının alıcı çalışma karakteristiği eğrileri

VGG16 Fine Tune modelinin en üstte kalan bir eğri çizerek diğerlerinden daha iyi bir AUC değeri elde ettiği **Şekil 6.79**'dan anlaşılıyor. RNN'in en altta kaldığı da grafikten görülebiliyor. VGG16 Transfer modeli de iyi bir eğri çizerken diğer modeller birbirlerine yakın bir eğri ile vasat AUC değerlerine ulaşıyorlar.




Şekil 6.80: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model eğitim doğruluk eğrileri

Şekil 6.80’de eğitim aşamasında VGG16 Fine Tune modelinin en iyi öğrenme eğrisine sahip olduğu görülüyor. RNN ve InceptionV3 Fine Tune modelleri öğrenmeyi durdururken diğer modeller öğrenmeye devam ediyorlar.




Şekil 6.81: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model sağlama doğruluk eğrileri

Şekil 6.81’ye göre doğrulama aşamasında VGG16 modelleri iyi bir performans sergilerken RNN modeli belli bir devirden sonra öğrenmeyi durduruyor. InceptionV3 modellerinin çizdikleri eğrilerden doğru bir öğrenme yapmadıkları anlaşılıyor.



Şekil 6.82: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model eğitim kayıp eğrileri¹

Şekil 6.82'ye göre eğitim aşamasında RNN ve InceptionV3 modelleri belli bir devirden sonra kayıp değerini azaltamazken diğer modeller kayıp değerini azaltmaya devam ediyor.




Şekil 6.83: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri (InceptionV3 Fine Tune)

Şekil 6.83 ve Şekil 6.84'teki grafiklerden doğrulama aşamasında InceptionV3 Fine Tune modelinin düzgün bir kayıp değeri eğrisi çizmediği görülüyor. Bu da InceptionV3 Fine Tune modelinin bu veri kümesini bu kayıp fonksiyonu ile doğru şekilde öğrenemediğini gösteriyor. RNN modelinin kayıp değerini azaltmadığı diğer modellerden VGG16 Transfer, CNN Scratch ve LSTM modellerinin veri kümesini

¹ Bu grafikteki aykırı değerler diğerlerinin daha iyi anlaşılması için yok sayılmıştır.

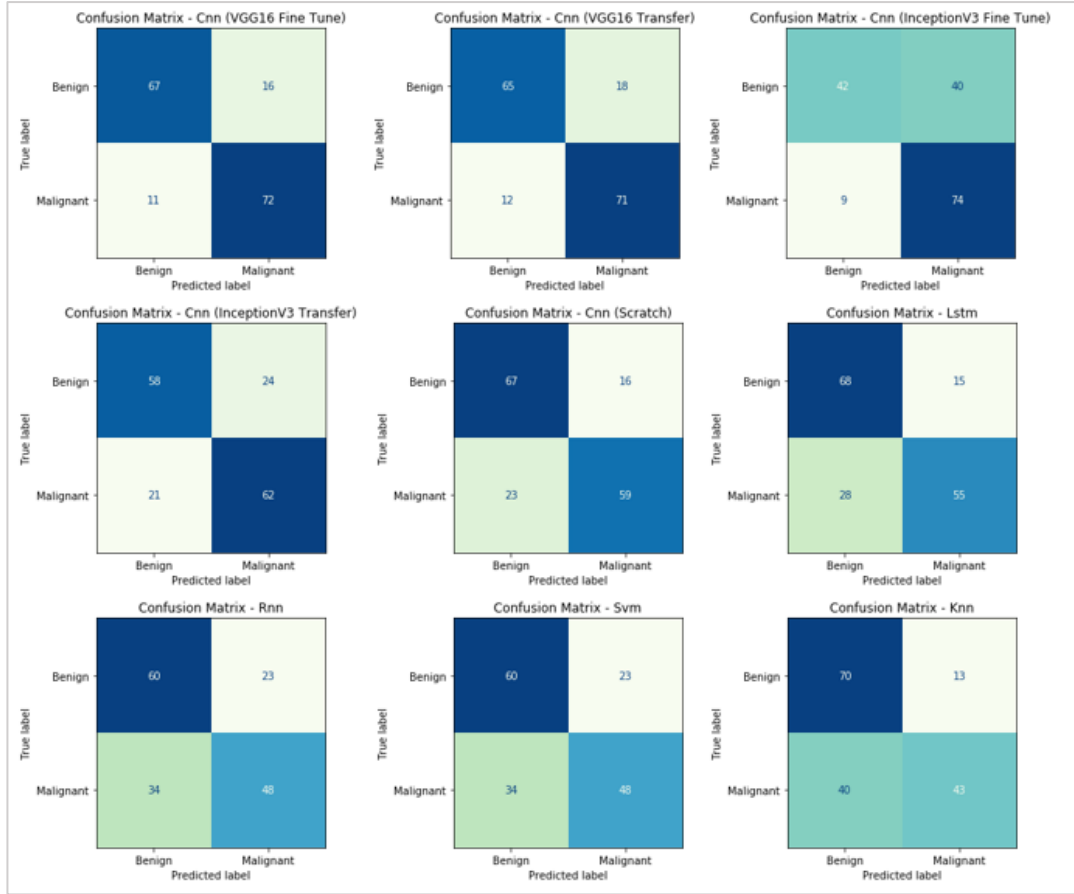
ezberlemeye yatkınlaştığı anlaşılıyor. InceptionV3 Transfer modeli ile VGG16 Fine Tune modelinin öğrenmeye devam ettiği görülüyor. VGG16 Fine Tune modelinin çizdiği eğrinin aşağı yönde dik bir açıyla eğri çizmesi aslında daha iyi öğrenebilecek olduğunu gösteriyor. Bu durumda bu veri kümesi ile kırma işlemi yapılarak tanıma işleminde en VGG16 sınıflandırıcısı Fine Tune metodu ile kullanılabilir ve kullanılırken daha iyi kayıp değeri parametreleri bulmak için çaba sarf edilebilir diyebiliriz.



Şekil 6.84: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özelliklerinin sınıflandırma sonuçlarının model sağlama kayıp eğrileri (Diğerleri) ¹

Şekil 6.85'deki hata matrislerinden en yüksek doğruluk değerini VGG16 Fine Tune modelinin verdiği fakat bununla birlikte en kararlı modelin InceptionV3 Transfer modeli olduğu anlaşılıyor. InceptionV3 Fine Tune modelinin ise sağlıklı örnekleri hasta olarak sınıflandırmaya yatkınlığının modeli kullanılmaz kılacak kadar yüksek olduğu görülüyor. Bu iki model arasındaki tek farkın modelin alt katmanlarını eğitime açmak olduğunu düşünecek olursak ya doğru katmanları eğitmiyoruz ya da bu modelin ağırlıkları veri kümesinden olumsuz etkileniyor denilebilir. Diğer modellerden VGG16 Transfer modelinin sağlıklı örnekleri hasta olarak sınıflandırmaya az da olsa yatkınlığı olduğu, CNN Scratch, LSTM, RNN, SVM ve özellikle KNN'in ise hasta örnekleri sağlıklı olarak sınıflandırmaya yatkınlığı olduğu grafiklerden görülüyor. Bu durumda kırma işlemi ile bu veri kümesinin sınıflandırılmasında VGG16 modelini tercih etmek doğru olur denilebilir.


¹ InceptionV3 Fine Tune eğrisi diğerlerinin görünürlüğünü azalttığı için ayrı çizilmiştir.




Şekil 6.85: Resimler lezyon sınırlarına göre kırılarak ham resim piksel özniteliklerinin sınıflandırma sonuçlarının hata matrisleri

6.2.7.Örnek model ile yapılan test sonucu


Çalışmamızda kullanılmış olan modellerin eğitim ve doğrulama aşamalarında doğal olarak aynı veri kümesi kullanıldığından elde edilen modelin test edilmesi için resimlerin lezyon sınırlarına göre kırılarak piksel özniteliklerine göre VGG16 Fine Tune modeli ile sınıflandırılması ile elde edilen model, bu çalışmada eğitim ve doğrulama aşamalarında hiç kullanılmamış olan PH² (Mendonça, vd., 2013) veri seti üzerinde uygulanmış ve doğruluk 0.87, f1 puanı 0.88, AUC değeri 0.94 ve AP değeri ise 0.83 olarak elde edilmiştir. Test sonuçlarının kesinlik duyarlılık eğrisi **Şekil 6.86**'da, alıcı çalışma karakteristiği eğrisi **Şekil 6.87**'de, hata matrisi ise **Şekil 6.88**'de gösterilmektedir.



Şekil 6.86: Örnek model ile yapılan test sonucunun kesinlik duyarlılık eğrisi



Şekil 6.87: Örnek model ile yapılan test sonucunun alıcı çalışma karakteristiği eğrisi



Şekil 6.88: Örnek model ile yapılan test sonucunun hata matrisi

Görüldüğü üzere modelimiz yüksek bir doğruluk, eğri altında kalan alan ve ortalama kesinlik değeri elde etmeyi başarmıştır. Bu grafiklerden ve değerlerden yapılan çalışmada elde edilen en iyi öznelik-model eşleşmelerinden birisi olan lezyon sınırlarına göre kırpma işlemi uygulanarak VGG16 Fine Tune modeli ile sınıflandırma işleminin, çalışmada kaynak olarak kullanılmayan veri kümelerinde de başarılı olduğu dolayısıyla çalışma yönteminin ve uygulamasının doğru olduğu anlaşılmaktadır.

6.3.Sonuç

Bu bölümde araştırma sonucunda elde edilen bulgulara ve grafiklere ayrıntılı olarak yer vererek mümkün olduğunca yorumladık. Elde ettiğimiz modellerden sadece bir tanesi ile test gerçekleştirerek çalışmanın doğruluğunu ve kullanılabilirliğini bu bölümde göstermeye çalıştık. Elde edilen sonuçlara göre ham piksel özneliklerinin VGG16 Fine Tune ile öğrenme aktarımı yaparak sınıflandırılması modelinin öne çıkarak daha başarılı olduğunu gördük. Lezyon sınırlarına göre kırpma işleminin bütün modelleri etkilediğini ve öne çıkan model sonuçlarında bir fark oluşturduğunu gördük. Elde edilen modellerin sahada kullanılması aşamasında modele girilen örneğin de kırılması gerekeceğinden kırpma işlemi yapılmadan elde edilen modelin doktorların kullanması açısından daha faydalı olabileceğini söyleyebiliriz. Çalışmayı değerlendirerek sonuçları yorumlamaya bir sonraki bölümde ayrıntılı olarak yer vereceğiz.

YEDİNCİ BÖLÜM

TARTIŞMA VE DEĞERLENDİRME

Bir önceki bölümde çalışmamızda yaptığımız sınıflandırma işlemlerine ait değerleri ve grafikleri teker teker ele alarak yorumlamaya çalıştık. Bu bölümde çalışmamıza ilişkin sonuçlara ele alınarak tartışılmış ve elde edilen bulgulara göre bazı öneriler sunulmuştur.

Malin melanom cilt kanseri her yıl dünya çapında binlerce hayata mal olmaktadır. Bu hastalığın teşhis edilmesi dermatologlar tarafından önce göz veya dermoskop vasıtasıyla yapılmaktadır. Kesin teşhisin konulması laboratuvar sonuçlarına göre belirlenmektedir. Bu çalışmada cilt lezyonlarının malin melanom veya nevüs olarak teşhis edilmesi için uzman doktorlara yardımcı olmak amacıyla otomatik bir tanıma sisteminde kullanılabilir modellerin sistemli olarak karşılaştırılması yapılmış ve elde edilen sonuç, çalışma dışı veri kümesi üzerinde uygulanmıştır. Ayrıca elde edilen modellerden örnek bir model internet üzerinden akademik kullanıma açılmıştır. Çalışmamızda son yıllarda en çok kullanılan derin öğrenme yöntemlerinden olan CNN, LSTM, RNN ve daha önceki yıllarda da birçok alanda başarılı olarak tanınmış olan makine öğrenmesi yöntemlerinden SVM ve KNN modelleri uygulanmış ve elde edilen sonuçlar sistemli olarak karşılaştırılmıştır.

7.1.Genel Değerlendirme ve Tartışma

Çalışmamızda kullanılan lezyon resimleri, daha önceden bahsettiğimiz veri kümesi içinden uzman doktorlar tarafından lezyon sınırları belirlenmiş olan dermoskopik resimler arasından seçilmiştir. Lezyon seçiminde Ly vd. (2018)'nin çalışmalarında yaptıkları gibi benin ve malin sınıfların dengeli olması açısından bazı benin lezyonlar rasgele seçilerek çalışma dışında bırakılmıştır. Resimler önce lezyon sınırlarına riayet etmeden daha sonra ise lezyon sınırlarına riayet ederek öznelikleri çıkarılmış ve sınıflandırılmıştır. Burada lezyon sınırlarına riayet ederek öznelik çıkarmak, resmin lezyonun sınırlarına göre kırılması anlamına gelirken lezyon maskesinin resim üzerine uygulanması anlamına gelmemektedir. Bazı çalışmalarda lezyon maskesi resmin üzerine uygulanmakta ve resimde lezyon dışındaki deri dokusu yerine siyah renk yer almaktadır. Bu iki yöntem arasındaki fark da araştırmaya değer bir başlıktır.

Çalışmada öznitelik olarak InceptionV3 ve VGG16 CNN öznitelikleri ayrı ayrı olmak üzere, gri seviyesi eş dizilim matrisi öznitelikleri ve ham piksel öznitelikleri ve ayrıca cnn öznitelikleri ile gri seviyesi eş dizilim matrisi öznitelikleri birleştirilerek kullanılmıştır. Sınıflandırma aşamasında modellerin hiper parametrelerinin bulunmasında grid search gibi algoritmalarından faydalanıldıysa da esasen hiper parametreler deneme yanılma yöntemiyle bulunmuştur.

Sonuçlara ilk bakıldığında edindiğimiz izlenim cilt lezyonlarını sınıflandırma işleminde CNN, LSTM ve SVM modellerinin KNN ve RNN modellerine göre daha başarılı olduğudur. En yüksek değerleri elde eden modelimiz resimlerin lezyon sınırlarına göre kırılarak elde edilen piksel özniteliklerinin VGG16 evrişimsel sinir ağı ile fine tune öğrenme aktarımı metodunu kullanan modelimiz olmuştur. Ne var ki bu durumda modelin kullanılabilirliği azalmaktadır çünkü modele ‘tahmin’ etme amaçlı verilen dermoskopik resimlerin de lezyon sınırlarına göre kırılması gerekmektedir. Doğruluk değeri açısından bakıldığında kırma işlemi yapılmaması %2 lik bir düşüşe sebep olduğu görülmektedir. Bu durumda lezyon sınırlarını belirleyecek kişinin uzman doktorlar olacağı düşünüldüğünde hangi modelin kullanılacağı uygulama alanında bulunan imkanlara göre değerlendirilmelidir. Lezyon sınırlarına göre kırma işlemi yapmadan elde ettiğimiz sonucun Menegola vd. (2017) tarafından elde edilen sonuçtan daha iyi olduğu görülmektedir. Bu durumda yöntemler benzer olmasına rağmen AUC değerindeki farkın veri kümesi ya da evrişimsel sinir ağı hiper parametreleri sebebiyle olabileceğini düşünmekteyiz. Bununla birlikte Yıldız’ın (2019) çalışmasından daha düşük değerler elde ettiğimizde görülmektedir. İlgili çalışmada seçilen veri kümesinin ve 10 kat çapraz doğrulama işleminde veri kümesinin her aşamada 2 ayrı parça yerine 10 ayrı parça şeklinde ele alınmasının etkisi olabileceği gibi daha iyi hiper parametreler seçilmiş olması da mümkündür. Lezyon sınırlarına göre kırma işlemi yaparak elde ettiğimiz VGG16 fine tune öğrenme aktarımı yöntemi kullanarak elde ettiğimiz modelimizin PH² veri kümesi üzerinde test edilerek elde ettiğimiz AUC değeri, Han vd. (2018) tarafından Resnet tabanlı bir model ile 12 sınıflı lezyon tanınması yaptıkları çalışmada melanom sınıfında Asan veri kümesi üzerinde test ederek elde ettikleri AUC değerinin %2 altında fakat Edinburgh veri kümesi üzerinde test ederek elde ettikleri AUC değerinin %6 üstünde kalmaktadır. İlgili çalışmayla bizim çalışmamız arasında kullanılan veri kümesi, kullanılan CNN modeli, çalışılan sınıf sayısı ve test kümesinin aynı olmaması, ilgili çalışmada veri çoklama yapılmış

olması gibi farklar olmasına rağmen kırpma işlemi uygulanması ile elde edilen sonuç benzerlik göstermektedir.

Çalışmamızda lezyon resimleri lezyon sınırlarına göre kırılarak VGG16 evrimsel sinir ağından elde edilen özniteliklerin SVM ile sınıflandırılmasıyla elde edilen en yüksek doğruluk, en yüksek F1 puanı ve en yüksek AUC değerlerinin VGG16 fine tune öğrenme aktarımı metodu uygulanarak elde edilen sonuç ile aynı olması bize VGG16 modelinin linear olarak rahatlıkla sınıflandırılabilen öznitelikler çıkarabildiğini düşündürmektedir. Resimler lezyon sınırlarına göre kırılmadan VGG16 evrimsel sinir ağından elde edilen öznitelikler SVM ile sınıflandırıldığında elde edilen en yüksek doğruluk, en yüksek F1 puanı ve en yüksek AP değerinin VGG16 fine tune öğrenme aktarımı ile resim piksellerinin sınıflandırılması ile elde edilen değerden daha yüksek olması da not edilmeye değer bir sonuçtur. Öte yandan InceptionV3 ile elde edilen öznitelikleri, gri değeri eş dizilim matrisinden elde edilen öznitelikleri ya da resim piksel özniteliklerini SVM ile sınıflandırılırken aynı başarı elde edilememektedir.

Lezyon resimlerini kırpmadan InceptionV3 modelini kullanarak oluşturduğumuz öğrenme aktarımı ve fine tune öğrenme aktarımı modellerimiz Esteva vd. (2017) tarafından elde edilen %72'lik doğruluk değerini geçmeyi başarmıştır fakat ilgili çalışmada elde edilen sonuç üç sınıflı bir sınıflandırıcı ile elde edilmiş ve InceptionV3'ün bütün katmanları eğitime açılmıştır ayrıca herhangi bir ek katmanla desteklenmemiştir. Bir CNN modelinde çok fazla ya da az sayıda katmanın eğitime açılmasının olumlu ya da olumsuz farklar doğurabileceği ve öğrenme aktarma yönteminde bir modele oluşturulduğu sınıflardan farklı sınıflar öğretilirken birkaç ek katmanla desteklenmesi gerektiği literatürde yer almaktadır. Bizim modelimizin daha başarılı olmasının belli sayıda katmanı eğitime açmamız ve melanom sınıflandırmasını öğrenmesi için modele katmanlar eklememiz sayesinde olduğunu düşünmekteyiz.

Resimlerin piksel özniteliklerine göre sınıflandırılmasında sıfırdan oluşturulan görece daha basit CNN modelimiz kırpma işlemi olmadan VGG16 fine tune ile öğrenme aktarımı modelinin dışındaki diğer modellerden daha iyi bir sonuç elde ederken kırpma işlemi uygulandığında ise VGG16 öğrenme aktarımı ve VGG16 fine tune ile öğrenme aktarımı modellerinin dışındaki diğer modelleri geçmeyi başarmıştır. Bu Buradan anlaşıldığı kadarıyla öğrenme aktarımının faydası elimizdeki modele ve probleme göre değişkenlik göstermektedir. Öte yandan sıfırdan oluşturulan modelin diğer

sınıflandırıcılara göre daha yüksek sonuç alması CNN'lerin resim sınıflandırmadaki başarısını da ayrıca göstermektedir. Sıfırdan oluşturduğumuz modelimiz Menegola vd. (2017)'nin çalışmasındaki sıfırdan oluşturulmuş modelin AUC değerinden %6 civarında daha yüksek AUC değerine sahiptir. Bu farkın oluşturulan modelin hiper parametrelerinden ve veri kümesinden kaynaklanması mümkündür. Bunların dışında resimlerin piksel özniteliklerine göre sınıflandırılmasında LSTM, RNN, KNN ve SVM modellerinden KNN ve LSTM'in RNN ve SVM'den daha başarılı olduğunu söyleyebiliriz.

InceptionV3 ile kaynak resimler lezyon sınırlarına göre kırpmadan elde edilen özniteliklerin sınıflandırılmasında CNN modeli ön plana çıkmaktadır. Aynı modelin kaynak resimler kırıldığında da başarılı olduğu görülmektedir. Bu işlem aslında resimlerin piksel özniteliklerine göre fine tune yapılmadan InceptionV3 ile öğrenme aktarımı yapılması ile aynı olmasına rağmen elde edilen sonuçlarda küçük farklar bulunmaktadır. Bunun sebebi derin öğrenme işleminin doğası gereği katmanlara rasgele ağırlıklar atamasından kaynaklandığını düşünmekteyiz. InceptionV3 ile kaynak resimler lezyon sınırlarına göre kırılarak elde edilen özniteliklerin sınıflandırılmasında ise LSTM modelinin ön plana çıktığını görmekteyiz. LSTM modelinin başarısı kurulan modeldeki hiper parametrelerden ve zaman ekseninin seçiminden etkilendiği için daha farklı parametre ve zaman eksenini kombinasyonları araştırılabilir.

VGG16 ile elde edilen özniteliklerin sınıflandırılmasında SVM daha başarılı olurken onu LSTM modeli izlemektedir. Aynı özniteliklerin CNN ile sınıflandırılması bu ikisinden sonra yer almaktadır. Yukarıda bahsettiğimiz öğrenme aktarımı metodu ile örtüşme bu modelde de bulunmaktadır. Yukarıdaki model ile bu modelde ortak olan nokta, elde edilen özniteliklerin sınıflandırılmasında kırma işlemi yapıldığında elde edilen değerler ile öğrenme aktarımındaki değerlere daha fazla yaklaşıldığıdır. Yani kırma işlemi yapılmadığında resim piksel özniteliklerine göre sınıflandırma yapılması ile özniteliklerin önce elde edilip sonra CNN ile sınıflandırılması arasında diğer duruma göre daha fazla fark oluşmaktadır. Halbuki bu durumda aradaki farkın benzer olması beklenirdi. Bu durum araştırmaya değerdir diye düşünüyoruz. SVM modelinin bu öznitelikler üzerindeki başarısından yukarıda da söz etmiştik. Bu durum bize VGG16 ile elde edilen özniteliklerin linear olarak ayrılabilir kadar iyi olduğunu düşündürmektedir.

Gri değeri eş dizilim matrisi özniteliklerinin sınıflandırılmasında SVM modeli daha başarılı olurken, LSTM ve RNN de yakın sonuçlar elde etmektedir. Önceki bir çalışmada Yıldız (2019), SVM ile gri değeri eş dizilim matrisi özniteliklerini sınıflandırarak %93'ün üzerinde doğruluk elde ederken bizim yaptığımız çalışmada bu değer %70'lerde kalmaktadır. Bu öznitelikleri sınıflandırırken yukarıda bahsi geçen InceptionV3 özniteliklerini ve VGG16 özniteliklerini sınıflandıran SVM ile aynı hiper parametreleri kullandığımız için ve önceki bir çalışmada çok farklı bir doğruluk oranına ulaşıldığı için gri değeri eş dizilim matrisi sınıflandırılmasında farklı hiper parametreleri aramak gerekli olabilir diyebiliriz. Gri değeri eş dizilim matrisi genel olarak literatürde sıkça kullanılıyor olmasına rağmen bizim çalışmamızda bu öznitelige göre yaptığımız sınıflandırma işleminde maalesef çok iyi sonuçlar elde edemedik. Bunun sebebinin seçilen veri kümesi ile ilgili olduğunu düşünüyoruz. Bazen de doğru hiper parametreleri bulamamış olmak bu gibi farklı sonuçlara sebep olabilmektedir. Bu durumda çalışmamızın ilerleyen aşamasında gri değeri eş dizilim matrisi ile InceptionV3 özniteliklerini ve VGG16 özniteliklerini birleştirerek sınıflandırma yaparak gri değeri eş dizilim matrisinin bu özniteliklere katkı sağlayıp sağlamadığını araştırdık. Gri değeri eş dizilim matrisinin her iki öznitelik grubunda da bazı modellerde fayda sağladığını tespit ettik. Gri değeri eş dizilim matrisi özniteliklerinin cnn öznitelikleri ile birleştirilerek sınıflandırılması literatürde pek rastlamadığımız ve bu çalışmada yer alan bir özellik olarak öne çıkmaktadır.

Gri değeri eş dizilim matrisi öznitelikleri ile InceptionV3 özniteliklerinin birlikte sınıflandırılmasında LSTM modeli ön plana çıkmaktadır. Kırpma işlemi yapılmadan elde edilen InceptionV3 öznitelikleri LSTM ile sınıflandırıldığında doğruluk değeri %71, gri değeri eş dizilim matrisi sınıflandırıldığında doğruluk değeri %69 olurken iki öznitelik birleştirilerek elde edilen doğruluk değeri %75 olmaktadır. Kırpma işlemi uygulandığında ise bu fark kalmamakta ve InceptionV3 özniteliklerinin tek başına sınıflandırılması ile benzerlik göstermektedir. Gri değeri eş dizilim matrisi özniteliklerini VGG16 öznitelikleri ile birleştirdiğimizde ise kırpma işlemi olmadan elde edilen sonuçlara göre en başarılı model LSTM olurken LSTM ve CNN sınıflandırıcıları özniteliklerin birleştirilmesiyle iyileşme göstermektedirler. Kırpma işlemi uygulandığında ise birleştirme işleminin faydası ortadan kalkmaktadır. Bu durumda lezyon sınırlarına göre kırpma işlemi yapılmadığında gri değeri eş dizilim

matrisi özniteliklerini sınıflandırılacak diğer özniteliklere eklemek faydalıdır denilebilir.

Çalışmamızda kırpma işleminin etkisi araştırılırken kullanılan her bir modelde kırpma işlemi yapılmadan elde edilen hiper parametreler kullanılarak sınıflandırma yapılmıştır. Bu sayede aynı şartlar altında kırpma işleminin etkisi ortaya çıkarılmış olmaktadır. Bununla birlikte kırpma işlemi uygulanmış resimleri daha iyi sınıflandıracak hiper parametreler bulunabileceği göz önünde bulundurularak kırpma işleminin en yüksek doğruluk değerine etkisi %-7 ile %8 arasında olurken ortalama doğruluğa etkisi %-4 ile %8 arasında değişkenlik göstermektedir. Standart sapma değeri %-3 ile %3 arasında değişmektedir. AUC değerindeki değişim %-9 ile %7 arasında olurken AP değerindeki değişim %-7 ile %7 arasında olmaktadır. F1 puanındaki değişim ise %-7 ile %8 arasındadır. SVM, KNN ve CNN modelleri kırpma işleminden daha az etkilenirken RNN ve LSTM modellerinin daha fazla etkilendiği görülmektedir. Daha önce de geçtiği üzere CNN tarafından çözülen problemlerle ilgili en önemli varsayım, mekânsal olarak bağımlı özelliklere sahip olmamalıdır denildiği için etkinin düşük olmasının beklenen bir sonuç olduğunu düşünmekteyiz. Ortaya çıkan farkın da resimler kırıldığında aynı özneliği ifade eden piksellerin sayısı değiştiği için ortaya çıktığını düşünmekteyiz. Yani kırpma işlemi ile lezyon büyüdüğü için CNN jargonunda pencere denilen alana giren pikseller değişmektedir. KNN ve SVM'in az etkilenmesinin sebebinin ise lineer olarak ayırt edici özniteliklerin derinin lezyon bulunmayan kısmında daha az olmasından kaynaklandığını düşünmekteyiz. Yani bu modeller de ilgi alanlarına girmeyen özniteliklerin farkına varabilmektedirler. RNN ve LSTM modelleri zaman bağımlılığı olan modeller olduğundan ve kullanılan modele öznitelik vektörlerinin bir eksenini zaman birimi olarak verildiğinden doğal olarak öznitelikler arasında bir bağ kurulmuş oluyor ve böylece ayırt edici olmayan öznitelikler sonucu etkiliyor diye düşünmekteyiz.

Bu bölümde çalışmamızın eksi ve artı yönlerini tartışarak önceki çalışmalarla karşılaştırmalı olarak öznitelikler, modeller ve kırpma işlemi bazında sonuçlarını ele almaya çalıştık. Bir sonraki bölümde çalışmanın genel olarak sonucunu ve gelecekte bu konuyla alakalı nasıl çalışmalar yapılabileceğine dair fikirlerimizi yazacağız.

SEKİZİNCİ BÖLÜM

SONUÇ VE GELECEKTEKİ ÇALIŞMALAR

Önceki bölümde çalışmanın genel olarak değerlendirilmesine yer vermiştik. Bu bölümde ise çalışmanın sonucunu ve gelecekte ne yönde geliştirilebileceğini ele alacağız.

8.1.Araştırmanın sonucu

Çalışmamızın ana amacı olarak ortaya koyduğumuz malin melanom ve benin nevüs ikili sınıflandırılmasında faydalı bir model bulunması ve lezyon sınırlarına göre kırpma işlemi ile modelin daha etkili hale getirilip getirilemeyeceğinin araştırılması neticesinde elde ettiğimiz tablolara ve değerlere bakıldığında lezyon sınırlarına göre kırılarak elde edilen resim piksel özneliklerinin VGG16 CNN’i temel alınan fine tune ile öğrenme aktarımı yöntemi kullanılan bir model ile sınıflandırılması, en etkili yöntem olarak ön plana çıkmaktadır. Bu model uygulama aşamasında tahmin edilecek resmin de kırılmasını gerektireceği için alternatif olarak aynı modelin resimlere kırpma işlemi yapılmadan eğitilmiş olan versiyonu kullanılabilir. Bunların dışında çalışmamızdaki diğer modellerin pratikte kullanılmasının anlamlı olmadığını ve doğruluk, eğri altında kalan alan, ortalama kesinlik gibi kriterlerde iyileşme sağlayana kadar araştırmaya devam edilmesinin gerekli olduğunu düşünüyoruz.

8.2.Gelecekteki yapılabilecek çalışmalar

Çalışmamızda elde ettiğimiz modelin dışında üzerinde çalışmak üzere değerlendirilebilecek birçok konu ele alınmış bulunmaktadır. Çalışmamızın sonuna gelirken bunlara kısaca değinmek istiyoruz.

Bu çalışmada yer alan MSK isimli veri kümesinin benzerleri ile bu çalışma tekrar edilebilir. Örneğin ISIC veri kümesinin diğer alt kümeleri ile benzer sonuçlar alınıp alınamayacağı araştırılabilir. Kaynak resimlerin çoklanması (data augmentation) ve yabancı cisimlerin silinmesi (artifact removal) gibi ön işleme yöntemleri ile sonuçların iyileşip iyileşmediği araştırılabilir.

Çalışmamızda ön plana çıkan VGG16 modeli temelli fine tune ile öğrenme aktarımı modeli için daha iyi parametreler araştırılabilir. Benzeri bir çalışma VGG19 ile tekrar edilebilir. Bu çalışmada yer alan VGG16 ve InceptionV3'ten başka örneğin InceptionV4, VGG19, ResNet ailesi, MobileNet ailesi, DenseNet ailesi, EfficientNet ailesi gibi birçok CNN modeli bulunmaktadır. Bunların her birisi ile bu çalışma tekrar edilebilir. Ayrıca sıfırdan oluşturulan CNN modeli ile daha iyi sonuçlar elde etmeye de odaklanılabilir.

Çalışmamızda yer alan zaman bağımlı modellerden LSTM ve RNN'in girdi vektörlerinde zaman eksenini düzenlenerek daha iyi sonuçlar elde edilip edilmeyeceği araştırılabilir. Örneğin resmin x veya y ekseninin zaman eksenini olarak verilmesi yerine piksellerin spiral şekilde modele girdi olarak verilmesi denenebilir. Ayrıca LSTM ve RNN birim sayıları artırılarak daha iyi sonuç alınmayacağı araştırılabilir.

Bu çalışmada kullanılan diğer sınıflandırıcılardan olan SVM ve KNN için daha iyi hiper parametreler bulmaya çalışılabilir. Bunların dışında karar ağacı vb. gibi başka sınıflandırıcılar da kullanılabilir. Örneğin VGG16 özneliklerini SVM ile sınıflandırmada elde edilen sonuçtan daha iyi bir sonucu başka bir öznelik veya başka bir algoritma ile elde etmek mümkün olabilir.

Gri değeri eş dizilim matrisinin bazı modellere sağladığı katkı daha iyi araştırılabilir. Ayrıca önceki çalışmalarda yer alan gri değeri eş dizilim matrisine göre sınıflandırma sonuçlarına göre bizim elde ettiğimiz sonuçların çok farklı yerde olması dikkat çekmektedir. Hangi çalışmadaki değerlerin gerçeğe daha yakın olduğu araştırılabilir. Gri değeri eş dizilim matrisinden başka literatürde geçen Hu moments, Fourier tanımlayıcıları gibi birçok istatistiksel öznelik bulunmaktadır. Bu gibi özneliklerle çalışma yapılabilir.

Bu çalışmada kırpma işlemi sırasında lezyon maskesinin resim üzerine uygulanmadığından sadece sınırları tespit etmek için kullanıldığından daha önce bahsetmiştik. Lezyon maskesi uygulanarak kırıldığında ve lezyon maskesi uygulanarak kırılmadığında nasıl sonuçlar alındığı ayrıca araştırılabilir.

KAYNAKÇA

- Abadi, M., vd. (2016, Kasım). TensorFlow: A system for large-scale machine learning. *12th USENIX Symposium on Operating Systems Design and Implementation, Savannah, ABD.*
- Acer, E. & Kaya Erdoğan, H. (2019). Sık Görülen Deri Kanserlerinin Epidemiyolojisi. *ESTÜDAM Halk Sağlığı Dergisi, Dermatoloji ve Halk Sağlığı Özel Sayısı: 52-60.*
- Albawi, S., Mohammed, T. A. ve Al-Zawi, S. (2017, Ağustos). Understanding of a Convolutional Neural Network. *The International Conference on Engineering and Technology.* Antalya, Türkiye.
- Anaconda. (2020). anaconda.com [3 Mart].
- Argenziano, G., vd. (1998). Epiluminescence microscopy for the diagnosis of doubtful melanocytic skin lesions. Comparison of the ABCD rule of dermatoscopy and a new 7-point checklist based on pattern analysis. *Archives of Dermatological Research, 134(12):1563-1570.*
- Argenziano, G., vd. (2003). Dermoscopy of pigmented skin lesions: Results of a consensus meeting via the Internet. *Journal of the American Academy of Dermatology, 48(5):679-93.*
- Artima. (2020). <https://www.artima.com/weblogs/viewpost.jsp?thread=4829> [10 Nisan].
- Asim, M. & Zakria, M. (2020). *Advanced kNN: A Mature Machine Learning Series.* arXiv preprint arXiv:2003.00415.
- Awad, M. & Khanna, R. (2015). *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers.* Berkeley: Apress.
- Azawi, R. M., vd. (2018). Brain Tumors Classification by Using Gray Level Co-occurrence Matrix, Genetic Algorithm and Probabilistic Neural Network. *Diyala Journal of Medicine, 14(2):138-151.*
- Boser, B. E., Guyon, I. ve Vapnik, V. N. (1992, Temmuz). A Training Algorithm for Optimal Margin Classifier. *COLT '92: Proceedings of the fifth annual workshop on Computational learning theory.*
- Brinker, T. J., vd. (2018). Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review. *Journal of Medical Internet Research, 20(10).*
- Brinker, T. J., vd. (2019). Deep learning outperformed 136 of 157 dermatologists in a head-to-head dermoscopic melanoma image classification task. *European Journal of Cancer, 113:47-54.*
- Brodersen, K. H., vd. (2010, Ağustos). The Binormal Assumption on Precision-Recall Curves. *International Conference on Pattern Recognition.*

- Chaturvedi, S., Gupta, K. ve Prasad, P. (2020). Skin Lesion Analyser: An Efficient Seven-Way Multi-class Skin Cancer Classification Using MobileNet. In A. Hassanien, R. Bhatnagar ve A. Darwish (Eds.), *Advanced Machine Learning Technologies and Applications, vol 1141*. Singapore: Springer, 165-176.
- Chen, M., Zhou, P., Wu, D., Hu, L., Hassan, M. M., & Alamri, A. (2020). AI-Skin : Skin Disease Recognition based on Self-learning and Wide Data Collection through a Closed Loop Framework. *Information Fusion*, 54: 1-9.
- Google AI Blog. (2020). <https://ai.googleblog.com/2016/08/improving-inception-and-image.html> [10 Temmuz]
- Codella, N. C., vd. (2018, Nisan). Skin Lesion Analysis Toward Melanoma Detection: A Challenge at the 2017 International Symposium on Biomedical Imaging (ISBI), Hosted by the International Skin Imaging Collaboration (ISIC), *IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, Washington, DC.
- Codella, N. C., vd. (2019, Şubat). Skin Lesion Analysis Toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (ISIC). arXiv preprint arXiv:1902.03368.
- Combalia, M. vd. (2019). BCN20000: Dermoscopic Lesions in the Wild. arXiv preprint arXiv:1908.02288.
- krebsliga.ch. (2010). <https://www.krebsliga.ch/ueber-krebs/krebsarten/hautkrebs-helle-hautkrebsarten/-dl-/fileadmin/downloads/sheets/deri-kanseri-bazal-spinal.pdf> [5 Mart]
- dermoscopia.org. (2020). https://dermoscopia.org/Seven_Point_Checklist [20 Nisan]
- Du, K.-L. & Swamy, M. (2013). *Neural Networks and Statistical Learning*. London: Springer.
- www.eba.gov.tr. (2020). <http://ogmmateryal.eba.gov.tr/panel/upload/etkilesimli/kitap/fenlisesibiyoloji/11/unite1/index.html#p=12> [4 Haziran]
- Eleyan, A. & Demirel, H. (2011). Co-occurrence matrix and its statistical features as a new approach for face recognition. *Turkish Journal Of Electrical Engineering & Computer Sciences*, 19(1): 97-107.
- Elgamal, M. (2013). Automatic Skin Cancer Images Classification. *International Journal of Advanced Computer Science and Applications(IJACSA)*, 4(3): 287-294.
- Esteva, A., vd. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542: 115-118.
- Fidan, U., Sarı, I. ve Kumrular, R. K. (2016, Ekim). Classification of Skin Lesions using ANN. *Medical Technologies National Congress (TIPTEKNO)*, Antalya, Türkiye.

- Fitzpatrick, J. E. & Aeling, J. L. (2000). *Dermatology Secrets in Color: Questions You Will Be Asked On Rounds, in the Clinic, on Oral Exams*, (2nd ed.). Philadelphia: Hanley & Belfus, Inc.
- Gavrilov, D., Shchelkunov, N. ve Melerzanov, A. (2019). Deep Learning Based Skin Lesion Diagnosis. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W12: 81-85.
- Haenssle, H. A., vd. (2018). Man against machine diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Annals of Oncology*, 29(8): 1836-1842.
- Hajabdollahi, M., vd. (2020). Multiple abnormality detection for automatic medical image diagnosis using bifurcated convolutional neural network. *Biomedical Signal Processing and Control*, 57: 101792.
- Hajian-Tilaki, K. (2013). Receiver Operating Characteristic (ROC) Curve Analysis for Medical Diagnostic Test Evaluation. *Caspian Journal of Internal Medicine*, 4(2): 627–635.
- Han, S. S., vd. (2018). Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm. *Journal of Investigative Dermatology*, 138(7): 1529-1538.
- Haralick, R. M., Shanmugam, K. ve Dinstein, I. (1973). Textural Features for Image Classification. *Studies in Media and Communication*, 3(6): 610-621.
- Haykin, S. (2009). *Neural Networks and Learning Machines*, (3rd ed.). New Jersey: Pearson Education, Inc.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8): 1735-1780.
- Hurwitz, J., & Kirsch, D. (2018). *Machine Learning IBM Limited Edition*. New Jersey: John Wiley & Sons, Inc.
- Jain, S., Jagtap, V., & Pise, N. (2015). Computer aided Melanoma skin cancer detection using Image Processing. *Procedia Computer Science*, 48: 735-740.
- Jupyter Lab. (2020). jupyter.org [3 Mart].
- Kelleher, J. D., Namee, B. M. ve D'Arcy, A. (2015). *Fundamentals Of Machine Learning For Predictive Data Analytics*. Cambridge: The MIT Press.
- Kiani, F., Kutlugün, M. A., & Çakır, M. Y. (2017, Kasım). Derin Sinir Ağları ile Konuşma Tespitve Cinsiyet Tahmini. 22. *Türkiye'de Internet Konferansı*. İstanbul, Türkiye.
- Kumar, G., & Bhatia, P. K. (2014, Şubat). A Detailed Review of Feature Extraction in Image Processing Systems. *Fourth International Conference on Advanced Computing & Communication Technologies*. Rohtak, Hindistan.

- Kumari, M., & Kaushik, M. L. (2018). Comprehensive Study to Decline the Burden of Skin Cancer. *International Journal of Pharmaceutical Sciences and Drug Research*, 10(3): 111-117.
- Kutlugün, M. A., Çakır, M. Y. ve Kiani, F. (2017, Kasım). Yapay Sinir Ağları ve K-En Yakın Komşu Algoritmalarının Birlikte Çalışma Tekniği (Ensemble) ile Metin Türü Tanıma. 22. *Türkiye'de İnternet Konferansı*. İstanbul, Türkiye.
- Küçük, Ö. & Kiani, F. (2018). Smart Advisor: An Intelligent Inventory Prediction based on Regression Model. *International Journal of Machine Learning and Networked Collaborative Engineering*, 2(3): 86-94.
- Lai, Z., & Deng, H. (2018). Medical Image Classification Based on Deep Features Extracted by Deep Model and Statistic Feature Fusion with Multilayer Perceptron. *Computational Intelligence and Neuroscience*, 2018:2061516.
- Le, X. H., vd. (2019). Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water*, 11(7): 1387.
- Liu, Q., & Wu, Y. (2012). Supervised Learning. In N. M. Seel (Eds.), *Encyclopedia of the Sciences of Learning*. ABD: Springer, 3243-3245.
- Lopez, A. R., vd. (2017, Şubat). Skin lesion classification from dermoscopic images using deep learning techniques. *13th IASTED International Conference on Biomedical Engineering*. Innsbruck, Austria.
- Lundervold, A. S., & Lundervold, A. (2019). An overview of deep learning in medical imaging focusing on MRI. *Zeitschrift für Medizinische Physik*, 29(2): 102-127.
- Ly, P., Bein, D. ve Verma, A. (2018, Kasım). New Compact Deep Learning Model for Skin Cancer Recognition. *9th IEEE Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)*. New York, ABD.
- Masood, A., Al-Jumaily, A. ve Anam, K. (2015, Nisan). Self-supervised learning model for skin cancer diagnosis. *7th Annual International IEEE EMBS Conference on Neural Engineering*, Montpellier, Fransa.
- Mendonça, T., vd. (2013, Temmuz). PH2 - A dermoscopic image database for research and benchmarking. *35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Osaka, Japonya.
- Menegola, A., vd. (2017, Nisan). Knowledge transfer for melanoma screening with deep learning. *IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*. Melbourne, Australia.
- Menzies, S. W., vd. (1996). Frequency and Morphologic Characteristics of Invasive Melanomas Lacking Specific Surface Microscopic Features. *Archives of Dermatological Research*, 132(10):1178-1182.

- Milton, M. A. (2019). Automated Skin Lesion Classification Using Ensemble of Deep Neural Networks in ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection Challenge, arXiv preprint arXiv:1901.10802.
- Mishra, S., Imaizumi, H. ve Yamasaki, T. (2019, Haziran). Interpreting Fine-Grained Dermatological Classification by Deep Learning. *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Long Beach, ABD.
- Mitchell, T. M. (1997). *Machine Learning*. New York: McGraw-Hill.
- Mustafa, S. & Kimura, A. (2018, Ocak). A SVM-Based Diagnosis of Melanoma using Only Useful Image Features. *International Workshop on Advanced Image Technology*, Chiang Mai, Tayland.
- Nachbar, F., vd. (1994). The ABCD rule of dermatoscopy. High prospective value in the diagnosis of doubtful melanocytic skin lesions. *Journal of the American Academy of Dermatology*, 30(4): 551-559.
- Nielsen, M. A. (2015). *Neural Networks and Deep Learning*. Determination Press.
- Nunnari, F. & Sonntag, D. (2019). A CNN toolbox for skin cancer classification. arXiv preprint arXiv:1908.08187.
- Oliveira, T. P., Barbar, J. S. ve Soares, A. S. (2016). Computer network traffic prediction: A comparison between traditional and deep learning neural networks. *International Journal of Big Data Intelligence*, 3(1): 28-37.
- Özdemir, F., vd. (2013). Deroskopik Terminolojinin Dilimize Uyarlanması: Türk Dermatoloji Derneği Deroskopi Çalışma Grubu Uzlaşısı. *Turkish Journal of Dermatology*, 7(4): 206-235.
- Pacheco, A. G. & Krohling, R. A. (2020). The impact of patient clinical information on automated skin cancer detection. *Computers in Biology and Medicine*, 116: 103545.
- Pradhan, A. (2012). Support vector machine-A survey. *International Journal of Emerging Technology and Advanced Engineering*, 2(8): 82-85.
- Python. (2020). python.org. [3 Mart]
- Saito, T., & Rehmsmeier, M. (2015). The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets. *PLOS One*, 10(3): e0118432 .
- Senan, E. M. & Jadhav, M. E. (2019). Classification of Dermoscopy Images for Early Detection of Skin Cancer - A Review. *International Journal of Computer Applications*, 178(17): 37-43.
- Seyyedabbasi, A., Candan, F., ve Kiani, F. (2018). A Method for Forecasting Weather Condition by using Artificial Neural Network Algorithm. *ICTACT Journal On Soft Computing*, 08(03): 1696-1700.

- Shalev-Shwartz, S. & Ben-David, S. (2014). *Understanding Machine Learning From Theory to Algorithms*. Cambridge: Cambridge University Press.
- Sharma, D. & Srivastava, S. (2016). Automatically Detection of Skin Cancer by Classification of Neural Network. *International Journal of Engineering and Technical Research (IJETR)*, 4(1): 15-18.
- Soyer, H. P., vd. (2004). Three-Point Checklist of Dermoscopy A New Screening Method for Early Detection of Melanoma. *Dermatology*, 208(1): 27-31.
- Stolz, W., Reimann, A. L. ve Cognetta, A. B. (1994). ABCD rule of dermatoscopy: a new practical method for early recognition of malignant melanoma. *European Journal of Dermatology*, 11(5): 483:498.
- Sutton, R. S. & Barto, A. G. (2018). *Reinforcement Learning: An Introduction*. Cambridge: MIT Press.
- Swets, J. A. (1988). Measuring the Accuracy of Diagnostic Systems. *Science, New Series*, 240(4857): 1285-1293.
- Torkamanian-Afshar, M., vd. (2020). RPINBASE: An online toolbox to extract features for predicting RNA-protein interactions. *Genomics*, 112(3): 2623-2632.
- Tschandl, P., vd. (2020). Human–computer collaboration for skin cancer recognition. *Nature Medicine*, 26: 1229-1234.
- Tschandl, P., Rosendahl, C. ve Kittler, H. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Sci data*, 5: 180161.
- Türk, E. & Kiani, F. (2019). Yapay Sinir Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlama Örneği. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(1): 30-37.
- Ucar, A. N., vd. (2018). Margin-Controlled, Staged Surgical Excision in the Treatment of High-Risk Basal Cell Carcinomas of the Head and Neck Region. *Journal of Cutaneous Medicine and Surgery*, 23(3): 258-264.
- who.int. (2020). [https://www.who.int/news-room/q-a-detail/radiation-ultraviolet-\(uv\)-radiation-and-skin-cancer](https://www.who.int/news-room/q-a-detail/radiation-ultraviolet-(uv)-radiation-and-skin-cancer). [29 Mayıs]
- Yalçın, H. (2015, Ekim). Characterization of melanomas using a variety of features. *TIPTEKNO'15 TIP TEKNOLOJİLERİ KONGRESİ*. Muğla, Türkiye.
- Yap, J., Yolland, W. ve Tschandl, P. (2018). Multimodal skin lesion classification using deep learning. *WILEY Experimental Dermatology*, 27(11): 1261-1267.
- Yıldız, O. (2019). Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(4): 2241-2260.

Zulpe, N., & Pawar, V. (2012). GLCM textural features for Brain Tumor Classification. *International Journal of Computer Science*, 9(3): 354-359.



ÖZGEÇMİŞ

Enver Ekrem Uçar

A. Eğitim

Lisans : Viyana Teknik Üniversitesi, Software&Information Engineering, 2007

B. Mesleki deneyim

2008-2011 Özel bir şirkette yazılım uzmanı

2012-2013 Özel bir şirkette yazılım uzmanı

2014-2015 Özel bir şirkette yazılım uzmanı

2016- Özel bir şirkette yazılım uzmanı