

T. C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**MEME KANSERİNİN HİSTOPATOLOJİK GÖRÜNTÜLER ÜZERİNDE DERİN
SİNİR AĞLARI KULLANILARAK BİLGİSAYAR DESTEKLİ OTOMATİK TESPİTİ**

YÜKSEK LİSANS TEZİ

ZAFER SERİN

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ EMRE DANDIL

BİLECİK, 2020

10352445

T. C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**MEME KANSERİNİN HİSTOPATOLOJİK GÖRÜNTÜLER ÜZERİNDE DERİN
SİNİR AĞLARI KULLANILARAK BİLGİSAYAR DESTEKLİ OTOMATİK TESPİTİ**

YÜKSEK LİSANS TEZİ

ZAFER SERİN

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ EMRE DANDIL

BİLECİK, 2020

10352445

T. C.
BILECIK SEYH EDEBALI UNIVERSITY
GRADUATE SCHOOL OF SCIENCE
DEPARTMENT OF COMPUTER ENGINEERING

**COMPUTER-AIDED AUTOMATIC DETECTION OF BREAST CANCER USING
DEEP NEURAL NETWORKS ON HISTOPATHOLOGICAL IMAGES**

MASTERS'S THESIS

ZAFER SERİN

THESIS ADVISOR
ASST. PROF. DR. EMRE DANDIL

BILECIK, 2020
10352445

BEYAN

“Meme Kanserinin Histopatolojik Görüntüler Üzerinde Derin Sinir Ağları Kullanılarak Bilgisayar Destekli Otomatik Tespiti” adlı yüksek lisans yeterlik tezi hazırlık ve yazımı sırasında bilimsel ahlak kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını beyan ederim.

Bu çalışmanın, Bilimsel Araştırmalar Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte beyan edilmelidir.		
DESTEK ALINMIŞTIR (X)		DESTEK ALINMAMIŞTIR
Destek alındı ise;		
Destekleyen Kurum: Bilecik Şeyh Edebali Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü		
Destegin Türü		Proje Numarası
1- BAP (Bilimsel Araştırma Projesi)	X	2019-01.BŞEÜ.25-02
2- TÜBİTAK		
Diğer;		

Zafer SERİN

3.9.2020

ÖN SÖZ

Çalışmalarımnda destek olan ve bu araştırmamın her bir aşamasında yardımlarını ve desteğini esirgemeyen danışman hocam sayın Dr. Öğr. Üyesi Emre DANDIL’a teşekkürlerimi sunarım

Bu çalışmada kullanılan verisetini temin ettiğimiz Fabio Alexandre Spanhol ve arkadaşlarına teşekkür ederim.

2019-01.BŞEÜ.25-02 proje numarası ile bu çalışmayı destekleyen Bilecik Şeyh Edebali Üniversitesi Bilimsel Araştırmalar Koordinatörlüğüne teşekkürlerimi sunarım.

Son olarak maddi manevi her türlü desteğini benden esirgemeyen aileme sonsuz teşekkürlerimi sunarım.

Zafer SERİN

3.9.2020

ÖZET

MEME KANSERİNİN HİSTOPATOLOJİK GÖRÜNTÜLER ÜZERİNDE DERİN SİNİR AĞLARI KULLANILARAK BİLGİSAYAR DESTEKLİ OTOMATİK TESPİTİ

Günümüzde kadınlar arasında en sık görülen kanser türü meme kanseridir ve akciğer kanserinden sonra oldukça yüksek bir ölüm oranına sahip olarak ikinci sırada yer alır. Geç tespit durumunda ise meme kanseri tedavisi oldukça zor bir duruma gelmektedir. Meme kanserinin tespiti için çeşitli yöntemler bulunmasına karşın halen yardımcı tespit ve tedavi yöntemlerine olan ihtiyaç önem arz etmektedir. Bu çalışmada meme kanserinin histopatolojik görüntülerde tespiti için derin sinir ağları kullanılarak bir model önerilmiştir. Kullanılan veriseti 40X, 100X, 200X ve 400X yakınlaştırma oranlarına sahip ve toplamda 7909 adet histopatolojik görüntü içeren BreakHis'tir. Önerilen derin sinir ağı modelinde DenseNet201, Inception V3, ResNet50 ve Xception olmak üzere dört farklı ön-eğitilmiş ağı kullanılarak daha başarılı sonuçlar elde edilmesi sağlanmıştır. Kullanılan ön-eğitilmiş ağların çalışma mimarileri incelenmiş ve başarılı ağların neden daha iyi oldukları saptanmıştır. Modellerin başarımlarını daha da artırmak amacıyla bırakma, veri artırma, test zamanı veri artırımı ve yığın normalizasyonu yöntemleri kullanılmıştır. Her bir ön-eğitilmiş ağı farklı yakınlaştırma oranlarında elde ettiği başarımlar farklı performans ölçütleri (doğruluk, F1-skor, eğri altındaki alan) ve grafiksel doğruluk değeri vasıtasıyla incelenmiştir. Ön-eğitilmiş ağların karmaşıklık matrisleri çıkarılmış ve verisinde bulunan görüntülere yaptıkları tahminler doğru veya yanlış olarak ayırt edilebilmiştir. Yapılan gözlem ve incelemeler neticesinde Xception ağı ile elde edilen sonuçların diğer ağlara oranla daha başarılı olduğu görülmüştür. Xception ağı ile 200X yakınlaştırma oranında gerçekleştirilen deneysel çalışmalarda, hem diğer ağlara göre hem de diğer yakınlaştırma oranlarına göre en başarılı sonuçlara ulaşılmış ve %98.01'lik bir doğruluk skoru, %98.21'lik bir hassasiyet değeri ve %98.92'lik bir hatırlama değeri elde edilmiştir. Xception ağının 200X yakınlaştırma oranındaki ROC (Receiver Operating Characteristic) eğrisi altındaki alan değeri ise 0.975 olarak hesaplanmıştır. Xception ağının rastgele seçilen 200X yakınlaştırma oranına sahip histopatolojik görüntüler üzerindeki tahminleri ve gerçek sonuçlar karşılaştırılmıştır. Sonuç olarak bu veriseti özelinde 100X yakınlaştırma oranında DenseNet201, 200X yakınlaştırma oranında InceptionV3, 200X ve 400X yakınlaştırma oranlarında ise Xception ağı daha başarılı sonuçlar ortaya koymuştur.

Anahtar Kelimeler:

Meme kanseri, Histopatolojik görüntü, Sınıflandırma, Derin sinir ağları, Xception, InceptionV3, ResNet, DenseNet, Ön-eğitilmiş ağlar

ABSTRACT

COMPUTER-AIDED AUTOMATIC DETECTION OF BREAST CANCER USING DEEP NEURAL NETWORKS ON HISTOPATHOLOGICAL IMAGES

Today, breast cancer is the most common type of cancer among women and ranks second after lung cancer with a very high mortality rate. In case of late detection, breast cancer treatment becomes very difficult. Although there are various methods for the detection of breast cancer, the need for additional detection and treatment methods/tools is still important. In this study, a model using deep neural networks is proposed for the detection of breast cancer on histopathological images. The used dataset is BreakHis, which has 40X, 100X, 200X and 400X magnification ratios and contains 7909 histopathological images in total. In the proposed deep neural network model, successful results were obtained using four different pre-trained networks such as DenseNet201, Inception V3, ResNet50 and Xception. The architectures of the used pre-trained networks were examined and it was determined why successful networks were better. Dropout, data augmentation, test time data augmentation and batch normalization methods were used to further increase the performance of the models. The performances of each pre-trained network at different magnification ratios were examined by different performance criteria (accuracy, F1 score, area under curve) and graphical accuracy value. The confusion matrices of the pre-trained networks were achieved and the predictions realized on the images in the dataset as true or false. As a result of experimental results, it was seen that the results obtained with the Xception network are more successful than the other networks. In the experimental studies performed with the Xception network at 200X magnification ratio, the most successful results were obtained compared to other networks and other magnification ratios, and an accuracy score of 98.01%, a sensitivity value of 98.21% and a recall value of 98.92% were obtained. The area value under the ROC (Receiver Operating Characteristic) curve at 200X magnification ratio of the Xception network was achieved as 0.975. The predictions and actual results of the Xception network on histopathological images with a randomly selected 200X magnification ratio were compared. As a result, it was denoted that more successful results were obtained in DenseNet201 at 100X magnification ratio, InceptionV3 at 200X magnification ratio, Xception network at 200X and 400X magnification ratios for this dataset.

Keywords:Breast cancer, Histopathological image, Classification, Deep neural network, Xception, InceptionV3, ResNet, DenseNet, Pre-trained networks

İÇİNDEKİLER

	Sayfa N
ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
SİMGELER VE KISALTMALAR.....	vi
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	ix
1. GİRİŞ	1
1.1. Literatür Araştırması	5
1.2. Tezin Amacı	9
1.3. Hipotez ve Araştırma Sorusu	9
2. MATERYAL VE YÖNTEM.....	10
2.1. Meme Kanseri Veriseti	11
2.2. Evrişimsel Sinir Ağı (ESA)	13
2.3. Konvolüsyon (Evrişim)	14
2.4. Yeniden Boyutlandırma İşlemi	15
2.5. Veri Artırma İşlemi.....	16
2.6. Havuzlama ve Küresel Ortalama Havuzlama İşlemleri.....	17
2.7. Ekranda Görüntülenen Görüntü ve Piksel İşlemleri.....	20
2.8. Dolgu İşlemi	22
2.9. Bırakma İşlemi	23
2.10. Yığın Normalizasyonu	24
2.11. Dense (Yoğun - Tam bağlı) Katman	25
2.12. Sınıflandırma.....	26
2.13. Ön Eğitilmiş Ağlar.....	26
2.13.1. Residual Neural Network (ResNet)	27
2.13.2. Dense Convolutional Network (DenseNet).....	27
2.13.3. Ağ İçinde Ağlar.....	28
2.13.3.1. Inception V1.....	29
2.13.3.2. Inception V2.....	31
2.13.3.3. Inception V3.....	33

2.13.4. Xception.....	33
3. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	37
4. SONUÇLAR	52
KAYNAKÇA	54
TEZDEN YAPILAN YAYINLAR VE KONFERANSLAR.....	63
ÖZGEÇMİŞ	64

SİMGELER VE KISALTMALAR

Kısaltmalar:

CIFAR	: Canadian Institute For Advanced Research (Kanada İleri Araştırma Enstitüsü)
ESA	: Evrişimsel Sinir Ağı
GPU	: Graphics Processing Unit (Grafik İşlemci Birimi)
LSTM	: Long Short Term Memory (Uzun Kısa Süreli Hafıza)
MLP	: Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)
ReLU	: Düzleştirilmiş Doğrusal Birim Katmanı
MR	: Manyetik Rezonans
PNN	: Probabilistic Neural Networks (Olasılıksal Sinir Ağları)
RBF	: Radial Basis Function (Radyal Taban Fonksiyonu)
H&E	: Hematoksilin ve Eosin
CMT	: Meme Tümörü
DBN - NN	: Deep Belief Network Path (Derin Fikir Ağı Yolu)
DCNN	: Deep Convolutional Neural Network (Derin Evrişimsel Sinir Ağı)
SDLM	: Structured Deep Learning Model (Yapılandırılmış Derin Öğrenme Modeli)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
VLAD	: Vector of Locally Aggregated Descriptors (Yerel Olarak Toplanmış Tanımlayıcıların Vektörü)
TTA	: Test Time Augmentation (Test Zamanı Artırması)
MNIST	: Modified National Institute of Standards and Technology Database (Değiştirilmiş Ulusal Standartlar ve Teknoloji Veritabanı Enstitüsü)
SVHN	: The Street View House Numbers (Sokak Görünümü Ev Numaraları)
AUC	: Area Under Curve (Eğri Altındaki Alan)
ROC	: Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
WSI	: Whole Slide Image (Tam Slayt Görüntü)
YOLO	: You Look Only Once (Sadece Bir Kere Bakarsın)
BiCNN	: Breast Cancer Histopathological Image Classification Method Based On Deep Convolutional Neural Networks (Derin Evrişimsel Sinir Ağlarına Dayalı Histopatolojik Görüntülerde Meme Kanseri Sınıflandırması)
MIAS	: Mammographic Image Analysis Society (Mamografik Görüntü Analizi Topluluğu)

ICIAR	: International Conference on Image Analysis and Recognition (Uluslararası Görüntü Analizi ve Tanıma Konferansı)
VGG	: Visual Geometry Group (Görsel Geometri Grubu)
ResNet	: Residual Network (Artık Ağ)
DenseNet	: Densely Connected Convolutional Network (Yoğun Bağlı Evrişimsel Ağ)
Yak.D.	: Yakınlaştırma Değeri
D.S.	: Doğruluk Skoru
Has. D.	: Hassasiyet Değeri
Hat.D.	: Hatırlama Değeri
M.O.	: Makro Ortalama
A.O.	: Ağırlıklandırılmış Ortalama
DP	: Doğru Pozitif
YP	: Yanlış Pozitif
YN	: Yanlış Negatif
DN	: Doğru Negatif
MR	: Magnetic Resonance (Manyetik Rezonans)
WHO	: World Health Organization (Dünya Sağlık Örgütü)

Simgeler:

B	: $x_1 \dots x_m$ (Mini yığın üzerindeki x değerleri - Giriş)
γ, β	: Yığın normalizasyonunda öğrenilecek parametreler
y_i	: $YN_{\gamma, \beta}(x_i)$ (Çıkış - Ölçeklendirme ve kaydırma)
μ_B	: Mini yığın ortalaması
σ_B^2	: Mini yığın varyansı
$\hat{x}_i$	: Normalleştirme
$F(x)$	: ResNet mimarisinde tanımlanmış doğrusal olmayan (nonlinear) fonksiyon

TABLÖLER LİSTESİ

Tablo 2.1. BreakHis verisetindeki yakınlaştırma oranları ve görüntü sayıları	12
Tablo 2.2. Yığın normalizasyonu algoritmasının sözde kodları.....	25
Tablo 3.1. Ölçüm metriklerinde kullanılan karmaşıklık matrisi parametreleri	37
Tablo 3.2. Bütün ağların göstermiş olduğu performans metrikleri (Yak.D.: Yakınlaştırma Değeri D.S.: Doğruluk Skoru, Has. D.: Hassasiyet Değeri, Hat.D.: Hatırlama Değeri, M.O.: Makro Ortalama, A.O.: Ağırlıklandırılmış Ortalama)	45
Tablo 3.3. Literatürde BreakHis veriseti kullanılan benzer çalışmaların karşılaştırılması.....	51

ŞEKİLLER LİSTESİ

Şekil 2.1. Histopatolojik görüntülerde meme kanserinin tespiti ve sınıflandırılması için önerilen derin sinir ağları tabanlı modelin blok diyagramı	11
Şekil 2.2. BreakHis verisetinden iyi huylu ve kötü huylu örnek histopatolojik görüntüler.....	12
Şekil 2.3. Evrişimsel sinir ağı yapısı	14
Şekil 2.4. Xception ağı vasıtasıyla çıkarılan örnek özellik haritası	14
Şekil 2.5. 700x460 çözünürlüğe sahip 200X yakınlaştırma oranındaki kötü huylu görüntünün yeniden boyutlandırma işlemi vasıtasıyla 224x224 ve 299x299 olarak görüntülenmesi	16
Şekil 2.6. Örnek bir histopatolojik görüntüye veri artırma işlemlerinin uygulanması	17
Şekil 2.7. 3x3 filtre ve 3 adım büyüklüğü ile maksimum, minimum ve ortalama havuzlama yöntemlerinin uygulanması	18
Şekil 2.8. Maksimum havuzlama, minimum havuzlama ve ortalama havuzlama işlemlerinin meydana getirdiği görüntüler	19
Şekil 2.9. 3 kanallı (derinlik) bir matrise uygulanan küresel ortalama havuzlama işlemi ve sonrasında hesaplanan değerler	20
Şekil 2.10. Kırmızı, yeşil ve mavi renklerinin karışımları sonucu oluşan renkler (Her bir renk için tam değeri (255) kullanılmıştır)	21
Şekil 2.11. Kırmızı, yeşil ve mavi kanallara sahip görüntünün bu 3 kanalın birleşimi ile ekranda görüntülenen hale gelmesi	22
Şekil 2.12. 700x460 çözünürlüğe sahip görüntünün ve yine aynı görüntünün yeniden boyutlandırma ile 224x224 çözünürlüğe getirilmesiyle oluşturulan görüntünün histogram grafikleri	22
Şekil 2.13. Dolgu işleminin uygulama yöntemini ve kullanım amacı	23
Şekil 2.14. Bırakma işlemi uygulanan bir ağın görüntüsü (1-> Bırakma işleminden önce, 2-> Bırakma işleminden sonra)	24
Şekil 2.15. ResNet'te her iki katmanda bir eklenen değer için örnek bir blok üzerinde gösterilmesi (He vd., 2016: 771)	27
Şekil 2.16. DenseNet ağının yapısı	28
Şekil 2.17. Doğrusal evrişim katmanı ve mlpconv katmanının karşılaştırılması. Doğrusal evrişim katmanı doğrusal bir filtre içerirken Mlpconv katmanı bir mikro ağ içerir (Lin vd., 2013: 1-4)	28

Şekil 2.18. Ağ içinde ağ modelinin genel yapısını gösterir şekil. Ağ içinde ağ modelini literatüre kazandıran makale de üç mlpconv katmanı ve bir küresel ortalama havuzlama katmanı kullanılmıştır (Lin vd., 2013: 1-4).....	29
Şekil 2.19. Naif Inception modülü (Szegedy vd., 2015: 1-4)	30
Şekil 2.20. Boyut düşürme işlemleri eklendikten sonra ki Inception modülü (Szegedy vd., 2015: 1-4)	30
Şekil 2.21. 2 boyutlu matrislerde yapılan 1x1 evrişim işlemi.....	31
Şekil 2.22. Klasik modüldeki 5x5 evrişim işleminin 2 adet 3x3 evrişim işlemi ile gerçekleştirilmesi (Szegedy vd., 2016: 2818-2823).....	32
Şekil 2.23. 3x3 evrişim katmanlarının alt katmanlara ayrıldıktan sonraki Inception modülünün görüntüsü (Szegedy vd., 2016: 2818-2823)	32
Şekil 2.24. Xception kullanılarak oluşturulan mimarinin genel yapısı.	34
Şekil 2.25. Basitleştirilmiş Inception modülü (Chollet, 2017: 1251-1258).....	34
Şekil 2.26. Inception modülünün extreme (aşırı) versiyonu, 1x1 evrişimlerin çıkış kanallarının her birisi için evrişim kullanması (Chollet, 2017: 1251-1258)	35
Şekil 2.27. Ara aktivasyon kullanılmadığı durumda Xception ağının daha yüksek doğruluk değerlerine ulaşması (Chollet, 2017: 1251-1258)	35
Şekil 2.28. Xception ağının tüm yapısı gösterir şekil (stride: Adım büyüklüğü, +: Filtre birleştirme işlemi, SeperableConv: Değiştirilmiş derinlikle ayrılabilir evrişim) (Chollet, 2017: 1251-1258).	36
Şekil 3.1. DenseNet201, InceptionV3, ResNet50 ve Xception önceden eğitilmiş ağlarının 200X yakınlaştırma oranındaki başarımların grafikleri.....	39
Şekil 3.2. Xception ağının bırakma ve veri artırma işlemlerine verdiği tepkiler.....	40
Şekil 3.3. 200X yakınlaştırma oranındaki görüntülerde ön-eğitilmiş ağların TTA'lı ve TTA'sız karmaşıklık matrisleri	41
Şekil 3.4. Hassasiyet ve Hatırlama değerlerinin farkı.....	44
Şekil 3.5. Xception ağının tüm yakınlaştırma oranlarındaki AİK eğrileri ve EAA değerleri..	47
Şekil 3.6. Ağların tüm yakınlaştırma oranlarındaki AİK eğrileri ve EAA değerleri	48
Şekil 3.7. Xception ağının 200X yakınlaştırma oranındaki rastgele seçilen 8 görüntünün gerçek değerini doğru olarak tahmin etmesi	50
Şekil 3.8. Xception ağının 200X yakınlaştırma oranındaki rastgele seçilen 4 görüntünün gerçek değerini yanlış olarak tahmin etmesi	50

1. GİRİŞ

Kanser, nüfusu nispeten fazla bir ülke olan ABD’de kalp hastalıklarından sonra ikinci sırada ölümlerin nedeni olarak gösterilmiş ve kısa süre içerisinde birinci sırada yer alması beklenen bir hastalıktır (Siegel vd., 2015: 5). Meme kanseri ABD’de bulunan kadınlar arasında cilt kanseri hariç olmak üzere en yaygın olarak tespit edilen kanser türüdür. Dünya Sağlık Örgütü (WHO) raporuna göre; dünya çapında kadınlar arasında en yaygın olarak görülen kanser %25.2’lik oran ile meme kanseridir. Meme kanserinin hastalıklılık (Morbidity) oranı ise %14.7 olup son yıllarda kanser ölümcüllüğü (Mortality) bakımından akciğer kanserinden sonra ikinci sırada yer almaktadır (Han vd., 2017: 1). Yine bu araştırmaya göre, yaklaşık yarım milyon meme kanseri hastası hayatını kaybetmiş ve her yıl 1.7 milyon yeni vaka ortaya çıkmaktadır. Bu vaka sayılarının giderek artması beklenmektedir. 2019 yılında yapılan bir çalışmaya göre toplamda 271.270 yeni meme kanseri vakası ve aynı çalışmaya göre toplamda 42.260 meme kanseri nedeniyle ölüm beklendiği öngörülmüştür. Yaş ile doğru orantılı olarak meme kanserine yakalanma oranı ve meme kanseri dolayısı ile hayatını kaybetme oranlarının arttığı bilinmektedir. Yapılan araştırmalara göre her 8 kadından 1’i meme kanserine yakalanmakta ve her 39 kadından 1’i meme kanseri nedeniyle hayatını kaybetmektedir. Bunlara ek olarak 70’lerinde bulunan kadınlarda meme kanserine yakalanma oranı (%4.1) en yüksek iken 80’lerinde bulunan kadınların meme kanseri nedeniyle ölüm oranı (%3) en yüksektir. Elde edilen bu sayılar oldukça yüksektir. Buna karşın 1 Ocak 2019 tarihi itibarı ile ABD’de 3,8 milyondan fazla kadının meme kanserinden kurtulduğu bilinmektedir. Bu sayı 150.000’den fazla metastatik hastalıkla yaşayan kadını da kapsamaktadır (Siegel vd., 2019: 10) (DeSantis vd., 2019: 440).

Meme kanseri Mamografi, Ultrason, MR (Manyetik Rezonans) ve biyopsi gibi çeşitli testler vasıtasıyla tespit edilebilir. Mamografi memenin röntgen (X-ray) filminin çekilmesidir. Belirgin bir semptomu bulunmayan kadınlarda meme kanserini tespit etmek için rutin tarama mamografileri yapılırken, yapılan bu tarama mamografilerinin sonuçlarından şüphelenilmesi ve doktorun dokuyu kontrol etmesi sonrası tanısal mamografiler kullanılır. Tanısal mamografiler tarama mamografilerine göre daha uzun sürer çünkü daha fazla röntgen filmi çekilir ve memenin birden fazla açıdan görüntülenmesi sağlanır. Ayrıca testi uygulayan radyolog anormallik şüphesi olan belirli bölgelere yakınlaştırma gibi işlemler gerçekleştirebilir. Mamografinin meme kanserini saptama yeteneği tümörün boyutuna, meme dokusunun yoğunluğuna ve radyoloğun mamografiyi uygulama ve okuma becerisine bağlıdır. Mamografinin 50 yaşın altındaki kadınlarda bulunan meme kanserini tespit etme yeteneği

daha düşüktür. Bunun sebebi 50 yaş altındaki kadınlarda mamografide beyaz görünen daha yoğun meme dokusu bulunması olabilir. Benzer şekilde bir tümör mamografide beyaz görünerek tespiti zorlaştırabilir. Kendi kendine meme muayenesi veya tarama mamografisi sonrası doktorun şüphe duyması halinde doktor tarafından meme dokusunun ultrason görüntüsü istenebilir. Meme ultrasonu dokuyu etkilemeyen veya zarar vermeyen ve insanlar tarafından duyulamayan ses dalgalarını kullanan bir taramadır. Meme dokusu, bir bilgisayarın meme dokusunda ki durumu anlamak için kullandığı ekolara neden olan bu dalgaları saptırır. Böylece sıvı kütle katı kütleden farklı olarak ortaya çıkar. Ultrason tarafından oluşturulan ayrıntılı resme “Sonogram” adı verilir. Bir yumru (lump) kolayca hissedilebilecek kadar büyük olduğunda ultrason yararlıdır. Meme ultrasonu yumrunun katı bir kitlemi, sıvıyla dolu bir kist mi yoksa ikisinin bir kombinasyonunu olduğuna dair kanıt sağlayabilir. Kistler tipik olarak kanserli olmamakla birlikte, katı bir yumru kanserli bir tümör olabilir. Yine şüphelenilmesi durumunda doktor tarafından MR görüntüsü istenebilir. Meme MR taraması sırasında bilgisayara bağlı bir mıknatıs, meme dokusundan manyetik enerji ve radyo dalgaları iletir. Dokuyu tarar, meme içindeki bölgelerin detaylı görüntülerini çıkartır. Bu görüntüler tıp ekibinin normal ve hastalıklı dokuyu ayırt etmesinde yardımcı olur. Meme biyopsisi şüpheli bölgeden doku veya bazen sıvıyı alan bir testtir. Çıkarılan hücreler bir mikroskop altında incelenir ve ayrıca meme kanserinin varlığını kontrol etmek için test edilir. Biyopsi, şüpheli bölgenin kanserli olup olmadığını kesin olarak belirleyebilen tek tanı prosedürüdür. Doktorlar meme kanseri tespiti konulan bir hastanın prognozuna (bir hastalığın seyri hakkında tahmini ve iyileşme şansı olup olmadığı anlamında kullanılan terim) yardımcı olmak için ek laboratuvar testleri isteyebilir (National Breast Cancer Foundation, 2019: 1).

Genel olarak tıp dünyası da meme kanserinin pek çok aşamasında olduğu gibi teknolojiye oldukça fazla faydalanmaktadır. MR (Manyetik Rezonans), ultrason, işitme testleri, diyaliz vb. pek çok cihaz tıp dünyasında hastalık tespit ve tedavi yöntemleri olarak kullanılmaktadır. Elbette donanımsal gelişmelere karşın bunları destekleyecek bir yazılımsal gelişmeye de ihtiyaç duyulmaktadır. Yazılımsal olarak geline nokta ise pek çok farklı programlama dili ve uygulama geliştirme çatısı (framework) önceden çok daha uzun ve bazı kısıtlara sahip olarak yapılan işlemleri bu dezavantajlarından arındırmış ve daha hatasız donanım kontrolleri sağlamıştır. Ayrıca sadece teknolojik olarak değil keşfedilen yeni ilaçlar, rehabilitasyon teknikleri ve psikolojik gelişmeler de tıp dünyasının gelişmesine katkıda bulunmuştur. Yaşanan bunca gelişmeye karşın halen bazı hastalıkların tespit ve tedavi yöntemlerinde eksiklikler bulunmaktadır. Bunlar hastalık hakkında yeterince bilgi olmaması

veya çok az kişide görülmesi gibi sebeplere dayanabilmektedir. Buna karşın bazı hastalıklar çok fazla görülebilmesi, aşırı ölümcül olması ve hakkında pek çok bilgiye sahip olunmasına karşın elde bulunan bilgiler ile tam bir çözüme kavuşturulamamaktadır. Bu tür hastalıklara kanser ve kanserin bir alt türü olan meme kanseri örnek olarak verilebilir (Dogan vd., 2010: 1160).

Patoloji tıbbi bilimlerde kesin hastalık tanıları koymakla görevlendirilmiş bir bölümdür (Robbin vd., 1999: 4-5). Patologlar bir hastalık için standart, doğru ve tekrarlanabilir bazı nitelikler belirlemeye çalışmaktadır. Bu nitelikler 19. Yüzyılın ortalarından beridir mikroskoplar yardımıyla yapılmaktadır. Patologlar biyopsi ile kesin hastalık tanıları koymaktadır ancak bir hastalığın mikroskop yardımıyla detaylı bir şekilde incelenmesi çok uzun süreler alabilmektedir. Ayrıca kimi durumlarda insan kaynaklı (yorgun olma veya deneyimsizlik gibi) hatalar oluşabilmekte ve her zaman doğru sonuca ulaşmak mümkün olmamaktadır. Son yıllarda bu nedenlerden ötürü patoloji alanında makine öğrenmesi, derin öğrenme ve görüntü işleme gibi teknolojilerden faydalanılmaktadır (Wang vd., 2016: 1). Patologlar meme kanseri tespiti için dokusal özellikleri, meme parankiminin normal yapılarındaki farklılıkları tespit ederek Hematoksilin ve Eosin (H&E) ile boyanmış dokuları mikroskop ile inceler ve buna göre bir sonuca varmaya çalışır. Uygun tedavi yönteminin seçilmesi için dokunun iyi huylu veya kötü huylu olduğunun zamanında tespit edilmesi gereklidir. Yapay zeka, makine öğrenmesi ve derin öğrenme gibi teknolojiler kanser tespitinde daha hızlı ve tek bir uzmana göre daha başarılı sonuçlar ortaya koymasından ötürü bu alanlarda daha sık kullanılmaya başlamıştır. Ayrıca bu yöntemlerin kullanılması sınıflandırma doğruluğunu arttırmakta ve uzmanlar arasındaki görüş farklılıklarını azaltmaktadır (Kumar vd., 2020: 406).

Derin öğrenme alanındaki gelişmeler meme kanseri tespit yöntemi olarak kullanılmaya oldukça uygundur. Bunun sebebi derin öğrenmenin görüntü işleme ve görüntü üzerindeki özellikleri öğrenme niteliğine dayanmaktadır. Meme kanseri bilindiği üzere en genel olarak iyi huylu ve kötü huylu olarak sınıflandırılmaktadır. Doktorlar elde bulunan histopatolojik görüntüleri mikroskop yardımıyla ve çeşitli teknikler vasıtasıyla inceleyerek iyi huylu veya kötü huylu ayrımını yapmaktadırlar. Buradaki en önemli nokta kötü huylu görüntülerde bulunan hücrelerin ve dokunun farklılığıdır. Yapılacak bu sınıflandırma derin öğrenme için oldukça uygun bir problem olarak ortaya çıkmakta ve uygulanabilirliği oldukça yüksektir ki zaten derin öğrenme küresel bir öğrenme yöntemidir (Alom vd., 2018: 3). ESA (Evrişimsel Sinir Ağları) bir derin öğrenme modeli olarak tanımlanabilmekte ve daha çok

görüntülerin analizinde ve sınıflandırılmasında kullanılmaktadır (Ertam & Aydın, 2017: 755). Bunlara ek olarak derin öğrenme de kullanılan gizli katmanlar ESA yapısında evrimsel katmanlar olarak adlandırılmakta ve bunların birden çok olması nedeniyle daha başarılı öğrenmeler sağlanabilmektedir; ancak şu noktaya değinmek gerekir ki çok fazla gizli katman her zaman en iyi öğrenme anlamına gelmez (Yu & Deng, 2012: 554). Bunların yanı sıra daha önce benzer veya farklı problemler üzerinde test edilerek belirli öğrenme aşamalarına zaten ulaşan ön-eğitilmiş ağırlar elde bulunan başarıyı daha da artıracak niteliktedir. Literatür taraması bölümünde değinilen çalışmalar da kanıtlamaktadır ki derin öğrenme, ESA ve ön-eğitilmiş ağırlar sınıflandırma problemlerinde oldukça önemli başarılarla imza atmayı başarmıştır. Bu gibi nedenlerden ötürü daha çok kadınları etkileyen meme kanserinin histopatolojik görüntüleri kullanılarak bunların sınıflandırılması ve doktorların meme kanseri tespitinde destekleyici bir görev alması açısından bu çalışma önerilmiştir.

Patoloji ve onkoloji alanlarında kullanılan derin öğrenme modelleri histopatolojik görüntüdeki tümörün iyi huylu veya kötü huylu olduğunun sınıflandırılmasını sağlamaktadır. Tümör sadece bir kitle olarak tanımlanabilir ve bu tanıma göre her tümör insanlar için bir tehlike arz etmez ve bazı tümörler iyi huylu olabilir. Kanser dediğimiz hastalık hücrelerin kontrolsüz bir şekilde bölündüğü ve yayıldığı durumları ifade etmektedir (Öztürk & Akdemir, 2019: 299). Derin öğrenme algoritmalarında kullanılan modeller eğitim aşamasında kendisine gösterilen onlarca örneğin özellik çıkartmasını (hücre büyüklüğü, rengi ve şekli gibi) yapar ve daha önce görmediği bir takım görüntüler üzerinde test edilerek modelin başarılı olup olmadığı gösterilir. Kullanılan modeller çok fazla piksel ve matris işlemleri yapması nedeniyle güçlü donanımlara sahip bir bilgisayara ihtiyaç duyar. Yapılan eğitimler kimi durumlarda günler sürebilmektedir. Modeller bu kadar çok gereksinime ve zamana ihtiyaç duymalarına karşın kimi durumlarda yanlış tahminlerde bulunabilmekte ve hatalar yapabilmektedir. Hatalı sonuçlar elde edilmesinin en büyük sebepleri: tümörlü hücrenin arka plandan ve diğer dokulardan ayırt edilmesinde zorluk çekilmesi, görüntüye uygulanan bazı işlemlerin özellik kaybına neden olması vb.dir. Modelleri bu eksikliklerinden kurtarmak ve hatta daha iyi sonuçlar elde etmek için ön-eğitilmiş modeller (pre-trained) ortaya çıkmıştır (Rakhlin vd., 2018: 739). Bu gelişmeler neticesinde derin öğrenme, ESA ve ön-eğitilmiş ağırların meme kanseri tespitinde kullanılması oldukça uygun görülmektedir.

Literatürde önerilen çalışmalar incelendiğinde, derin öğrenme ve ön-eğitilmiş ağırların tıbbi alanlarda hastalık tespiti ve özellikle kanser tespitinde klasik yöntemlere oranla daha başarılı sonuçlar ortaya koydukları görülmektedir. Bu tez çalışmasında ise, histopatolojik

görüntüler kullanılarak meme kanserinin tespiti ve sınıflandırılması için ön-eğitilmiş ağlarla desteklenen derin öğrenme modeli önerilmiştir. Bu tez çalışmasında diğer çalışmalara göre veri artırma ve bırakma gibi eklemeler yapılmış, başarıyı kanıtlanmış ön-eğitilmiş ağlar kendi arasında karşılaştırılmış, test aşamasında veri artırma işleminin etkileri gözlemlenmiş ve bunların hepsinin sentezi bir arada sunulmuştur. Tez çalışmasının sonraki kısımları şu şekilde organize edilmiştir. İkinci bölüm materyal ve yöntem bölümünden oluşmakta olup, kullanılan veriseti, ESA yapısı, konvolüsyon, yeniden boyutlandırma, veri artırma, havuzlama, dolgu, bırakma, yığın normalizasyonu ve ön-eğitilmiş ağlardan bahsedilmiştir. Üçüncü bölüm ise araştırma sonuçları ve tartışma bölümüdür. Bu bölümde elde edilen sonuçlar açık bir şekilde paylaşılmış, ağlar grafiksel ve matematiksel olarak karşılaştırılmış ve bir sonuca bağlanmıştır. Son bölümde ise çalışma ile ulaşılan sonuçlar, çalışmanın kısıtları ve gelecekte yürütülmesi planlanan çalışmalar sunulmuştur.

1.1. Literatür Araştırması

Literatürde meme kanserinin tespitinde farklı çalışmalar bulunmaktadır. 2013 yılında yapılan bir araştırmada meme kanseri sınıflandırması için Olasılıksal Sinir Ağları (OSA - Probabilistic Neural Networks), Çok Katmanlı Algılayıcı (Multi Layer Perceptron) ve Radyal Taban Fonksiyonu (Radial Basis Function) modelleri ile bir çalışma yapılmıştır. Yürütülen deneysel çalışmalarda, OSA ile daha başarılı sonuçların elde edildiği görülmüştür (Azar & El-Said, 2013: 1737).

2016 yılında yapılan bir çalışma BreakHis veriseti üzerinde görüntüleri yakınlaştırma oranlarından bağımsız olarak sınıflandırmayı amaçlayan bir model önermiştir. İki adet mimari yapı bulunan bu çalışma da mimarilerden birisi kanserli dokuyu tahmin ederken bir diğeri hem kanserli dokuyu hem de görüntü yakınlaştırma seviyesini aynı anda tahmin etmek için kullanılmıştır (Bayramoglu vd., 2016: 2440).

Bir başka çalışmada, meme kanserinin tespiti için global veriseti üzerinde geri yayılım ağı ve Liebenberg Marquardt öğrenme fonksiyonunun kullanıldığı, ayrıca ağırlıkların Derin Fikir Ağı Yolu (Deep Belief Network Path) ile başlatıldığı bir model ile yüksek bir doğruluk oranı elde edilmiştir (Abdel-Zaher & Eldeib, 2016: 141).

2017 yılında yapılan bir çalışma da meme kanseri için ikili sınıflandırmadan farklı olarak çoklu sınıflandırma yöntemi ile bir derin sinir ağı önerilmiştir. Meme kanseri ikili sınıflandırma da iyi huylu veya kötü huylu olarak sınıflandırılmakta ancak bu çalışmada

sınıflar iyi huylu veya kötü huylu olarak değil meme kanserinin alt türleri (duktal karsinom, fibroadenom, lobüler karsinom vb.) olarak tanımlanmıştır. (Han vd., 2017: 1).

2018 yılında yapılan bir çalışma da BreakHis veriseti kullanılarak meme kanseri sınıflandırması yapılmıştır. Bu çalışma da ESA ve Uzun Kısa Süreli Hafıza'nın (Long Short Term Memory) bir kombinasyonu kullanılmıştır. Karar katmanında Softmax ve Destek Vektör Makineleri (Support Vector Machine) kullanılan model 200X'lik yakınlaştırma oranında en başarılı doğruluk değerini ve 40X yakınlaştırma oranında en başarılı hassasiyet değerini vermiştir (Nahid vd., 2018a: 1).

Bir diğer çalışmada, 72'si tümörlü ve 184'ü tümörsüz görüntüden oluşan toplam 184 meme ultrason görüntüsü içeren verisetinde memede bulunan kitlelerin tespiti yapılmıştır. Çalışmada çoklu fraktal boyut özellikleri de kullanılmıştır (Mohammed vd., 2018: 871).

Charan ve arkadaşları tarafından 2018 yılında yapılan çalışmada 189'u normal, 133'ü anormal olmak üzere toplamda 322 mamogram görüntüsü içeren Mamografik Görüntü Analizi Topluluğu (Mammographic Image Analysis Society) veriseti kullanılmıştır. Bu çalışma da ön-eğitilmiş ağlardan da faydalanılmıştır (Charan vd., 2018: 1).

2018 yılında yapılan bir diğer çalışma da BACH 2018 yarışması için meme kanserini normal, iyi huylu, insitu karsinomu ve invaziv karsinom olarak 4 sınıfa ayıran bir ESA önerilmiştir. Google'ın InceptionV3'ü ve ResNet50 gibi ön-eğitilmiş ağların da kullanıldığı bu yapı sınıflandırma doğruluğunu 3 kat çapraz validasyon (3-fold cross validation) ile değerlendirmiştir. Yapılan analizler sonucunda Inception V3 ağı ResNet50'den daha başarılı olduğunu göstermiştir (Vesal vd., 2018: 812).

Meme kanserini normal doku, iyi huylu tümör, insitu karsinomu ve invaziv karsinom olarak dört sınıfa ayırarak kullanılan verisetinde bir otomatik tespit sistemi kullanılmıştır. Derin sinir ağlarını ve transfer öğrenmesini kullanan bu sistem de öncelikle eklenen üst katmanlar eğitilmekte ve önceden değişmez-dondurulmuş (frozen) bazı özellik çıkarma katmanlarında ikinci bir inceleme yapılmaktadır. Kullanılan ağ Inception ResNet V2'dir. Veri artırma işlemi de uygulanan bu çalışma ICIAR 2018 BACH-Challenge için teste tabi tutulmuş ve başarılı bir sonuç elde etmiştir (Ferreira vd., 2018: 763).

Ön eğitilmiş ağlardan VGG16, VGG19 ve ResNet50'nin kullanıldığı 2018 yılında yapılan çalışma da yakınlaştırma oranı bağımsız olarak bir meme kanseri sınıflandırması ele alınmıştır. Bu 3 ön-eğitilmiş ağın karşılaştırması sonucu Mantıksal Regresyon (Logistic Regression) sınıflandırıcısı kullanan VGG16 en başarılı sonuçları elde etmiştir. Bu çalışma da

kullanılan veriseti %90 eğitim ve %10 test için kullanılmak üzere ayrılmıştır (Mehra, 2018: 248).

2019 yılında yapılan bir çalışmada BreakHis veriseti üzerinde tüm örnekleri etiketlemeye gerek kalmadan histopatolojik görüntülerde sınıflandırma yapabilen bir derin öğrenme modeli önerilmiştir (Sudharshan vd., 2019: 103).

2019 yılında yapılan bir diğer çalışma da tam slayt histopatolojik görüntülerde (Whole Slide Image - WSI) kanserli alanları sınıflandıran bir ağ (HIC-net) önerilmiştir. Bu ağ modeli WSI'yi belirli bir düzleme bölerek penceresel olarak sınıflandırma yapmaktadır. HIC-net softmax fonksiyonu kullanılarak yapılan sınıflandırma sonuçlarına göre iyi bir doğruluk değerine ulaşmıştır (Öztürk & Akdemir, 2019: 299).

2020 yılında yapılan bir çalışma da CMT (Meme Tümörü) nin köpekler için de oldukça ölümcül olduğu ve insan meme kanseri çalışmaları için oldukça güzel örnekler oluşturduğu görülmüştür. Her iki tümör içinde hematoksilin ve eosin (H&E) ile boyanmış görüntüler kullanılan bu çalışma histopatolojik görüntüler üzerinde bir derin sinir ağı yöntemi önermiştir. Bu çalışma da VGGNet-16 ön-eğitilmiş ağı kullanılarak sınıflandırma yapılmıştır (Kumar vd., 2020: 406).

2020 yılında yapılan bir çalışma da önerilen model ağın başlangıç parametrelerini hesaplamak, daha hızlı geri yayılım öğrenimi ve model parametrelerini güncellemek için çeşitli algoritmalar (Stokastik Gradyan İnişi (Stochastic Gradient Descent), Nesterov Hızlandırılmış Gradyan (Nesterov Accelerated Gradient), Uyarlanabilir Gradyan (Adaptive Gradient), RMSprop, AdaDelta ve Adam) kullanmıştır. Elde edilen sonuçlar başarılı bulunmuştur (Burcak vd., 2020: 1).

Hamed ve arkadaşları tarafından yapılan çalışma deneyimli hekimlerin %79 doğrulukla, makine öğrenmesi tekniklerinin ise %91 doğrulukla doğru kanser tespiti yapabildiğini söylemektedir. Yapılan bu çalışma en yeni makine öğrenmesine dayalı meme kanseri tespit ve sınıflandırma modellerini karşılaştırmalı olarak analiz ederek sunmuştur. Ulaşılan sonuçlara göre YOLO (You Only Look Once - Sadece Bir Kere Bakarsın) ve RetinaNet ağları en başarılı sonuçları vermiştir (Hamed vd., 2020: 322).

Kızılötesi termografi maliyetinin düşük olması ve zararlı radyasyon yaymaması nedeniyle meme kanseri tespitinde ümit verici bir teknik olarak ortaya çıkmış ve genç kadınlara uygulanan sonuçlara göre iyi sonuçlar verdiği görülmüştür. Yapılan çalışma da 88 hastanın 440 kızılötesi termografi görüntüsünden oluşan bir verisetinde ESA kullanarak

görüntüler normal ve patolojik olmak üzere iki sınıfa ayrılmıştır. Yapılan bu çalışma transfer öğrenmesi kullanan ön-eğitilmiş ağlardan 5 tanesini kullanmıştır: AlexNet, GoogleNet, ResNet-18, VGG-16 ve VGG-19'dur. Bu çalışma meme kanseri tespitine yardımcı bir yöntem olması açısından kızılötesi termografi görüntüleri ile birlikte derin öğrenmenin kullanımının potansiyelini açık bir şekilde ortaya koymuştur (Chaves vd., 2020: E23).

2020 yılında yapılan bir diğer çalışma da ESA'ya dayalı olarak geliştirilen yeni bir derin öğrenme modeli önerilmiş ve buna BreastNet ismi verilmiştir. Bu modelin genel yapısı dikkat modülleri (attention modules) üzerine inşa edilmiş bir kalıntı-artık (residual) mimaridir. Bu yapıda her bir görüntü modele girdi olarak uygulanmadan önce artırma (augmentation) yöntemleriyle işlenir ve BreastNet'e aktarılır; ancak veri sayısında bir artış sağlanmaz. Daha sonra modele gelen her bir görüntü dikkat modülleri aracılığıyla görüntünün önemli ve anahtar bölge denilebilecek kısımlarının seçilmesi ve işlenmesi gerçekleştirilir. Ayrıca bir piksel üzerindeki tüm ESA birimlerinin aktivasyonlarının vektörü olan hiper sütun (hyper column) yöntemi kullanılarak verilerin daha kararlı ve doğru olarak sınıflandırılması sağlanmıştır. Bu modelin geri kalan bölümleri ise klasik olan evrimsel katman, havuzlama katmanı, artık katman ve tam bağlı katmandır. Elde edilen bu sonuç yine aynı veriseti üzerinde test edilen AlexNet, VGG-16 ve VGG-19 modellerine göre daha başarılı olmuştur. Bu çalışmada da BreakHis veriseti kullanılmıştır (Toğaçar vd., 2020: 2).

Yapılan çalışma da meme kanseri histopatolojik görüntü sınıflandırması için ResHist olarak adlandırılan ve artık öğrenmeye dayalı 152 katmanlı bir evrimsel sinir ağı önerilmiştir. Bu model histopatolojik görüntülerden ayırt edici özellikleri öğrenmeyi ve iyi huylu - kötü huylu ayrımını yapmayı sağlamıştır. Bunlara ek olarak modelin performansını iyileştirmek için leke normalleştirme (stain normalization), görüntü yamaları oluşturma (image patches generation) ve afin dönüşümünü (afin transformation) temel alan bir veri büyütme tekniği uygulanmıştır. Bu model BreakHis verisetinde test edilmiştir. Veri artırma işlemleri uygulandıktan sonra ise performans ölçütleri artmıştır. Bu çalışma da ulaşılan sonuçlara göre ResHist ağı AlexNet, VGG-16, VGG-19, GoogleNet, InceptionV3, ResNet50 ve ResNet152'ye göre daha başarılıdır (Gour vd., 2020: 1).

ESA modelini ve transfer öğrenmeye dayalı DenseNet121 ağını kullanan bir diğer çalışmada doğruluk ve hassasiyet değerlerini artırmak için hiper parametre düzenlemesi yapılmıştır (Chowkkar, 2020: 1).

Yapılan bir diğer çalışmada derin evrimsel sinir ağlarına dayalı olarak meme kanserinin patolojik görüntülerini sınıflandırmak için yeni bir sınıflandırma yöntemi olan

DeepBC önerilmiştir. DeepBC Inception, ResNet ve AlexNet ile entegre bir hale getirilmiş ve yüksek bir F1 Skor değerine ulaşarak oldukça başarılı olduğunu göstermiştir (Wenzhong vd., 2020: 1).

2020 yılında yapılan bir diğer çalışmada histopatolojik görüntülerde meme kanseri sınıflandırması için ResNet18, Inception-V3 ve ShuffleNet ağları kullanılmıştır. BreakHis veriseti kullanılan bu çalışmada ikili sınıflandırma için Shufflenet Inception V3'ten daha iyi bir değere ulaşmıştır. 8 kanser sınıfının çoklu sınıflandırma için elde edilen performans ölçütü değerlerine göre ise ResNet18 en başarılı ağ olmuştur (Aloyayri, 2020: iii).

1.2. Tezin Amacı


Bazı histopatolojik görüntülerdeki tümörün insan gözüyle tespit edilebilmesi oldukça zor olabilmektedir. Bu gibi durumlarda doktorlar kendi aralarında bir komisyon kurarak ortak bir kanıya varmaya çalışırlar. Bu tez çalışmasında, doktorların tek bir kişi ile veya bir komisyon vasıtasıyla uzun süreçler alabilen karar verme sürelerinin kısaltılmasını ve histopatolojik görüntüler üzerinde meme kanserinin tespitine yönelik ek bir yardımcı aracın geliştirilmesi ile tespit başarımının doğruluğunun artırılması amaçlanmıştır.

1.3. Hipotez ve Araştırma Sorusu

Literatür taramasında değinilen çalışmalar sınıflandırma problemlerinde derin öğrenmenin ve ESA yapısının başarımını ortaya koymaktadır. ESA yapısı ile birlikte kullanılan ön-eğitilmiş ağların ise sonucu olumlu olarak etkilediği görülmüştür. Bunlara ek olarak veri artırma ve bırakma işlemlerinin uygulanmasının performans ölçütlerini artırdığını gösteren çalışmalar da vardır. Meme kanserinin tespiti ise günümüz için oldukça büyük bir problem olarak ortaya çıkmaktadır. Buna göre Xception, DenseNet201, InceptionV3 ve ResNet50 ön-eğitilmiş ağları kullanılarak, meme dokusundan elde edilen histopatolojik görüntü verileriyle, iyi huylu ve kötü huylu meme dokusu ayrımının yüksek başarımla yapılabilmesi öngörülmektedir. Saptanan bu bulgulara göre meme kanserinin histopatolojik görüntülerinde ön-eğitilmiş ağlar, veri artırma, bırakma, toplu normalleştirme ve test zamanı artırması yöntemleri kullanılırsa nasıl bir sonuç elde edilir?

2. MATERYAL VE YÖNTEM

Bu çalışmada histopatolojik görüntüler üzerinde meme kanserinin tespiti için önerilen derin sinir ağlarına dayalı modelin genel blok diyagramı Şekil 2.1.'de gösterilmiştir. Önerilen modelde görüntü alındıktan sonra ilk olarak, derin sinir ağları için oldukça önem arz eden yeniden boyutlandırma işlemi gerçekleştirilmektedir. Burada derin sinir ağlarının aldığı girdilerin aynı boyutta olması gerekmektedir ve bu nedenle girdiler ESA mimarisine girmeden önce sabit bir boyuta getirilir. Bunun yanında yapılan çalışmaya göre yüksek çözünürlüğe sahip bir görüntü bellekte daha fazla yer kaplar ve daha büyük bir sinir ağı kullanılmasına da neden olur (Hashemi, 2019: 2). Yine aynı çalışmaya göre eğer görüntünün çözünürlüğü çok fazla küçültülürse detaylar ve görüntü de bulunan özellikler kaybolabilir. Ayrıca kullanılan ön eğitilmiş ağı gereksinimleri gereği belirli yeniden boyutlandırma oranları (224x224, 299x299 gibi) kullanılması gereklidir. Bu gibi sebeplerden ötürü bu çalışmada yeniden boyutlandırma işlemi yatayda ve düşeyde 224x224 ve 299x299 olarak uygulanmıştır. Bunun yanında, veri artırma ile veriseti daha fazla genişletilerek ağı daha fazla örnek sunulmuş ve ağı eğitimi yürütülmüştür. Sonraki aşamada görüntüye uygulanan özellik çıkartma ile ayırt edici özellikler belirlenmektedir. Havuzlama (Pooling) işlemi yapılarak sınıflandırmadaki görüntünün şekli herhangi bir şekilde değişse dahi, sistemin bunu tanıyabilmesi ve mevcut görüntünün özelliklerini kaybetmeden daha küçük boyutta bir matris elde edilmesi amaçlanmıştır (Tolias vd., 2015: 1). Ek olarak, ezberleme (Over-fitting) işleminden kaçınmak amacıyla bırakma (dropout) işlemi gerçekleştirilmiştir. Yığın normalizasyonu (batch normalization) derin sinir ağlarının hızını, performansını ve sürekliliğini arttıran bir yöntemdir (Ioffe & Szegedy, 2015: 3). Son olarak görüntüler sınıflandırılmak için tam bağlantılı katmandan geçer ve iyi huylu veya kötü huylu meme kanseri sınıflandırma işlemi tamamlanır (Talo: 393-394).




Şekil 2.1. Histopatolojik görüntülerde meme kanserinin tespiti ve sınıflandırılması için önerilen derin sinir ağı tabanlı modelin blok diyagramı

2.1. Meme Kanseri Veriseti

Bu çalışmada önerilen modelin performansını değerlendirmek amacıyla oldukça fazla ve kaliteli histopatolojik görüntü içeren BreakHis veriseti kullanılmıştır (Fabio A Spanhol vd., 2015: 2). Bu verisetinde 82 hastadan toplanan toplamda 7909 mikroskopik görüntü bulunmaktadır. 2480 iyi huylu ve 5429 kötü huylu görüntüden oluşan bu veriseti 700x460 çözünürlüğe ve 3 kanal RGB - 8 bit derinliğe sahip PNG formatındadır. Bu veriseti P&D laboratuvarı-Patolojik Anatomi ve Sitopatoloji tarafından Parana-Brezilya'da oluşturulmuştur. Veriseti Tablo 2.1.'de gösterildiği üzere 40X, 100X, 200X ve 400X yakınlaştırma oranlarına sahip görüntülerden oluşmaktadır. Bu yakınlaştırma oranları doğrudan verisetinde bulunan görüntüleri ifade etmektedir. Herhangi bir müdahale ile bu yakınlaştırma oranları elde edilmemiştir. Şekil 2.2.'de bu verisetinde bulunan iyi huylu ve kötü huylu görüntülerin 224x224 çözünürlükteki bazı örnekleri gösterilmiştir (Fabio Alexandre Spanhol vd., 2016: 2561) (Fabio A Spanhol vd., 2017: 1869).

Tablo 2.1. BreakHis verisetindeki yakınlaştırma oranları ve görüntü sayıları


Yakınlaştırma Oranı	İyi Huylu Görüntü Sayısı	Kötü Huylu Görüntü Sayısı	Toplam
40X Oranında	652	1370	1995
100X Oranında	644	1437	2081
200X Oranında	623	1390	2013
400X Oranında	588	1232	1820
Görüntü Toplamı	2480	5429	7909



Şekil 2.2. BreakHis verisetinden iyi huylu ve kötü huylu örnek histopatolojik görüntüler

2.2. Evrişimsel Sinir Ağı (ESA)


Derin öğrenmede ki temel amaç yüksek-boyutlu (high-dimensional) verilerden bazı özellikler çıkartmak ve girdiler ile çıktıları bu özellikler vasıtasıyla ilişkilendirerek bir sonuca varmaktır. Karmaşık özellikleri çıkartabilmek için derin öğrenme algoritmaları genelde çok katmanlı bir yapıya sahiptir. Evrişimsel Sinir Ağı (Convolutional Neural Network) yapısı ilk olarak 1988'de Fukuşima tarafından önerilmiştir (Fukushima, 1988: 119). Ancak ağı eğitimi için gereken donanımsal yük çok fazla olduğu için geniş bir kullanım alanına sahip olamamıştır. 1998 yılında LeCun ve arkadaşları ESA'lara gradyen tabanlı bir öğrenme algoritması uyarlamış ve el yazısı sınıflandırma problemi için oldukça başarılı sonuçlar elde etmiştir (LeCun vd., 1998: 2295). Bu başarımın da bir etkisiyle diğer araştırmacılar ESA'ları daha çok kullanmış, geliştirmiş ve tanımlama problemlerin de kullanmıştır. Şekil 2.3.'te gösterildiği üzere ESA'da öncelikle görüntüdeki pikseller evrişimsel katman vasıtasıyla özellik çıkartma (feature extraction) işlemine tabi tutulur. Özellik çıkartmada belirli bir filtre (maske) tüm görüntü üzerinde dolaştırılır ve gerçekten iyi huylu veya kötü huylu görüntünün pikseli ile oluşturulan yeni görüntü arasında belirli bir olasılıkta benzerlik kurulur. Daha sonra sisteme doğrusal olmayanlık (non linear - çıktıdaki değişimin girdinin değişimi ile orantılı olmadığı sistemler) gösterilir. Doğrusal olmayan katman aktivasyon katmanı olarak da anılır çünkü burada bir aktivasyon fonksiyonu kullanılır. Doğrusallığın problem olmasının nedeni basitçe tüm ağı tek bir algılayıcı (perceptron) gibi davranmasının önüne geçilmesidir. Havuzlama katmanında ağırlık sayısı azaltılır, uygunluk kontrol edilir. Havuzlama işlemindeki amaç mevcut resmin özelliklerini kaybetmeden daha küçük boyutta bir matris (görüntü) elde etmektir. Havuzlama işleminde de özellik çıkartmadakine benzer bir filtreleme uygulanır. Düzleştirme katmanında ise klasik sinir ağı yapısı için veriler hazırlanır ve sunulur. Bu katmandaki temel amaç verileri tam bağlı katman (fully connected layer) için hazırlamaktır. Sınıflandırma katmanı adı da verilen tam bağlı katman da ileri beslemeli sinir ağları daha iyi performansa sahip oldukları için kullanılmış ve böylece öğrenme sağlanmış olur (Krizhevsky vd., 2012: 1097) (Ide & Kurita, 2017: 2684) (Paasio & Dawidziuk, 1999: 87) (Kalchbrenner vd., 2014: 7) (Bottou, 2012: 423) (Rumelhart vd., 1986: 533) (Erhan vd., 2009: 153).



Şekil 2.3. Evrişimsel sinir ağı yapısı

2.3. Konvolüsyon (Evrişim)


Konvolüsyon (Convolution) ESA yapısındaki temel yapılardan birisidir. Konvolüsyon işlemi temel olarak önceki katmandan gelen görüntüler üzerinde belirli bir filtrenin (3x3, 5x5, 7x7 vb.) dolaştırılması, bu filtrenin karşılık geldiği değerler ile matris çarpımına tabi tutulup toplanmasını ifade eder. Filtrenin tüm görüntü üzerinde dolaştırılma işlemi tamamlandıktan sonra ortaya çıkan sonuçlara özellik haritası (feature maps) adı verilir. Özellik haritaları tüm filtrelerin kendine özgü özelliklerinin bulunduğu alanlardır. ESA eğitimi sırasında bu filtrelerin katsayıları öğrenme yinelemesiyle değişmektedir. Bu sayede ağ verideki hangi bölümlerin önem arz ettiği hakkında fikir sahibi olur. Bu çalışma da kullanılan görüntülerin 3 kanallı (RGB) olmasından dolayı filtre katsayılarının matris çarpımı ile çarpılıp toplanma işlemi her bir kanal için yapılır. 3 kanal içinde bu işlem tamamlandıktan sonra üçünün toplamı ile özellik haritası elde edilir (Özkan & Ülker, 2017: 89). Şekil 2.4.'te Xception ağı ile çıkarılan bir özellik haritası gösterilmiştir.



Şekil 2.4. Xception ağı vasıtasıyla çıkarılan örnek özellik haritası

2.4. Yeniden Boyutlandırma İşlemi


Yapılan bu çalışma da 24 bit derinliğe (RGB - her biri 8 bit) 700 piksel genişliğe ve 460 piksel yüksekliğe sahip görüntüler kullanılmıştır. Görüntüler kullanılacak ön-eğitilmiş ağı niteliğine göre 224 piksel genişlik ve 224 piksel yükseklik veya 299 piksel genişlik ve 299 piksel yükseklik olacak şekilde yeniden boyutlandırma (resizing) işlemine tabi tutulmuştur. Bu işlem eğitim hızını artırmakta ve bellekte tutulan veriyi azaltmaktadır; ancak burada asıl dikkat edilmesi gereken durum ön-eğitilmiş bir ağ kullanıldığı zaman giriş görüntülerinin ağı eğitildiği formatta yeniden boyutlandırma işlemine tabi tutulmasıdır. Örnek verilmek gerekirse ResNet50 ve DenseNet201 ağları önceden eğitildikleri veri setlerinde 224x224 görüntüler kullanmışlardır bu durumda önceden öğrendikleri bilginin efektif ve yararlı bir şekilde kullanılabilmesi için kullanılacakları çalışmalarda da 224x224 olarak yeniden boyutlandırılmış görüntüleri girdi olarak almaları gerekmektedir. Benzer şekilde Inception V3 ve Xception ağları ise 299x299 görüntüleri girdi olarak almalıdır. Burada anlaşılması gereken bunun bir zorunluluk olmadığı ancak bu şekilde kullanılmasının daha uygun olacağıdır. Nitekim Inception V3 ve Xception’da 224x224 görüntüleri girdi olarak alabilir. Buna karşın ön-eğitilmiş ağ kullanılmadığı durumda herhangi bir genişlik ve yükseklik değerine sahip görüntü girdi olarak kullanılabilir; ancak burada dikkat edilmesi gereken önemli bir nokta vardır. Giriş görüntüsü yeniden boyutlandırma işlemi vasıtasıyla çok fazla piksel düşürülmesine uğrarsa (örneğin 700x460’ tan 24x24 gibi aşırı azaltma durumları) görüntüde bulunan birçok detayın kaybolmasına neden olabilir. Bu da özellik çıkartma işlemlerinin oldukça yetersiz kalması ve öğrenmenin çok zor bir hal alması anlamına gelir. Bir diğer yaklaşım olarak hiç yeniden boyutlandırma işlemi uygulanmaz veya çok yüksek piksel değerlerine göre uygulanırsa bellekte tutulacak veri çok fazla artacak aşırı güçlü donanımlara olan ihtiyaç çoğalacak ve eğitim süresi de uzayacaktır. Görüldüğü üzere yeniden boyutlandırma işleminin dengeli bir şekilde yapılması oldukça önem arz etmektedir. Çözülmesi istenen probleme göre en optimum yeniden boyutlandırma oranı seçilmeli ve bahsettiğimiz durumlara dikkat edilmesi gerekmektedir. Şekil 2.5.’te 700x460 durumdan 224x224 ve 299x299 olarak yeniden boyutlandırılan görüntüler gösterilmiştir (Velasco vd.: 182).



Şekil 2.5. 700x460 çözünürlüğe sahip 200X yakınlaştırma oranındaki kötü huylu görüntünün yeniden boyutlandırma işlemi vasıtasıyla 224x224 ve 299x299 olarak görüntülenmesi

2.5. Veri Artırma İşlemi

Derin öğrenme ve makine öğrenmesi algoritmalarında karşılaşılan en büyük sorun ağı eğitecek yeterince veri olmamasıdır. Yeterince veri bulunmaması bu algoritmalarda sık sık ortaya çıkan ve büyük bir sorun olan ezberleme (over-fitting) problemini meydana getirir. Bu olay kısaca ağın gördüğü eğitim verilerini (görüntü, text vb.) ezberlemesi ve eğitim verileri dışında bir girdi ile karşılaştığında başarı gösterememesidir. Bu sorundan kurtulmanın en önemli yöntemlerinden birisi veri artırımı (data augmentation) yapılmasıdır. Bu yöntem eğitim setine uygulanır ve elde bulunan verilerin özellikleri değiştirilerek yapay (artificial) olarak daha fazla görüntü elde edilir. Bu çalışmada kullanılan verisetinde de veri artırımı yapılarak görüntüler yatay ve dikey olarak döndürülmüş, görüntülere rastgele yakınlaştırma değerleri uygulanmıştır (Perez & Wang, 2017: 3) (Taylor & Nitschke, 2017: 2). Şekil 2.6.'da uygulanan veri artırma işlemlerinden bazıları şekilsel olarak gösterilmiştir. Veri artırma işleminin test setine de uygulanması işlemine Test-zamanı-artırması (Test time augmentation - TTA) ismi verilmiştir (Moshkov vd., 2020: 1).




Şekil 2.6. Örnek bir histopatolojik görüntüye veri artırma işlemlerinin uygulanması

2.6. Havuzlama ve Küresel Ortalama Havuzlama İşlemleri


Havuzlama (Pooling) katmanı ESA yapısında bulunan bir diğer katmandır. Bu katmanın temel mantığı ağdaki parametre ve hesaplama miktarını azaltmak için aşamalı olarak boyut azaltması uygulamasıdır. Havuzlama katmanı her bir özellik haritasında bağımsız olarak çalışmaktadır. En sık kullanılan havuzlama işlemlerinden birisi Inception V3 ağında da kullanılan maksimum havuzlama yöntemidir. Şekil 2.7. (a) görüntüsünde maksimum havuzlama yöntemi gösterilmiştir. Bu yöntem genişlik ve yükseklik değerleri belirlenen bir filtrenin tüm görüntü üzerinde gezdirilmesi ve kapsadığı piksellerden en yüksek değere sahip olanı tespit etmesi mantığıyla çalışır. (a) görseli detaylı incelenecek olursa görüntünün sol üst kısmında bulunan 3x3 toplam 9 piksel sırasıyla (standart bir görüntüde pikseller soldan sağa doğru sıralanır ancak burada kastedilen açık kırmızı renkteki piksellerdir) 4,6,1,2,5,3,7,1 ve 6 olarak görülür. Maksimum havuzlama belirli bir filtre vasıtasıyla bu değerleri inceler ve en büyük değer olan 7 değerini çıkışa verir. Bu şekilde tüm görüntü incelenir. Aynı mantıkla çalışan bir diğer yöntem minimum havuzlamadır. Minimum havuzlama da değerleri inceler ve en küçük olanı çıkışa verir. Şekil 2.7. (b)'de minimum havuzlama gösterilmiştir. Benzer şekilde ortalama havuzlama (average pooling) ise verilen piksellerin ortalamasını alarak buna bağlı bir çıktı verir. Şekil 2.7. (c)'de ortalama havuzlama yöntemi gösterilmiştir. (c) görselinde değerlerin virgülden sonra bir basamağı gösterecek şekilde tam değerleri gösterilmiştir; ancak ortalama havuzlama bu değerleri tam sayı (integer)

bir değere yuvarlayarak görüntüyü gösterecektir (Rawat & Wang, 2017: 2356). Adım büyüklüğü (stride) denilen kavram ise filtrenin ne kadar piksel atlayacağını belirtir. Bahsedilen bu 3 yöntemde havuzlama teknikleri olarak oldukça sık kullanılmaktadır. Siyah beyaz tonlamalı bir görüntü düşünülecek olursa bu görüntüde ki tüm pikseller 0 ve 255 değeri arasında toplam 256 tane değer alabilecektir. 0 değeri siyah ve 255 değeri ise beyaz renge karşılık gelecektir. Verilen bu örneğe göre maksimum havuzlama 255 değerine yakın olan yani beyaz rengin (parlak), minimum havuzlama 0 değerine yakın olan yani siyah rengin (koyu) ve ortalama havuzlama ise yakınlık gözetmeksizin kullanılan filtreye göre bir ortalama rengin olduğu kısımları ön plana çıkaracaktır. Bu durumda maksimum havuzlama işlemi arka planın koyu ve istenilen kısmın açık olduğu durumlarda, minimum havuzlama bunun tam tersi olduğu durumlarda ve ortalama havuzlama ise duruma göre seçilmesi gereken havuzlama yöntemleridir. Örneğin MNIST verisetinde arka plan siyah ve rakamlar beyaz renk ile gösterilmiştir. Bu durumda maksimum havuzlama yönteminin kullanılması daha uygun olacaktır (Xiao vd., 2017: 2) (Sun vd., 2017: 96) (Kang vd., 2014: 2571).




Şekil 2.7. 3x3 filtre ve 3 adım büyüklüğü ile maksimum, minimum ve ortalama havuzlama yöntemlerinin uygulanması

Şekil 2.8.'de bu çalışma da kullanılan iyi huylu bir histopatolojik görüntü, yeniden boyutlandırma işlemiyle 224x224 çözünürlüğe getirilerek maksimum, minimum ve ortalama havuzlama işlemleri uygulandıktan sonra görüntünün değişimi gösterilmiştir. (a) görselinde 3x3 filtre ve 3 adım büyüklüğü, (b) görselinde 7x7 filtre ve 7 adım büyüklüğü kullanılmıştır. Görüleceği üzere (b) görselinde meydana gelen bozulma ve özellik kaybı daha yüksektir.




(a)



(b)

Şekil 2.8. Maksimum havuzlama, minimum havuzlama ve ortalama havuzlama işlemlerinin meydana getirdiği görüntüler


Küresel ortalama havuzlama (Global Average Pooling) işlemi ortalama havuzlamaya oldukça benzemektedir. Aradaki fark küresel ortalama havuzlama da belirli bir filtre görüntü üzerinde dolaştırılmaz; tüm görüntü tek bir seferde incelenir ve tüm görüntü içerisinde bulunan tüm piksellerin ortalaması alınmaktadır. Yapılan bu işlem her bir kanal için yapılmaktadır. Şekil 2.9.’da küresel ortalama havuzlama işleminin uygulanma şekli gösterilmiştir. Bu işlem ezberlemeyi ve toplam parametre sayısını düşürür.



Şekil 2.9. 3 kanallı (derinlik) bir matrise uygulanan küresel ortalama havuzlama işlemi ve sonrasında hesaplanan değerler


2.7. Ekranda Görüntülenen Görüntü ve Piksel İşlemleri

Standart 32 bitlik bir görüntü 4 adet kanaldan meydana gelmektedir. Bunlar: Kırmızı, yeşil, mavi ve alfa (RGBA) kanallarıdır. Daha önce siyah beyaz resim örneğinde olduğu gibi bu 4 kanalda 0 ile 255 arasında aldıkları değerlere göre bir görüntü oluşturmaktadır. Kırmızı, yeşil ve mavi renkleri 0 değeri ile siyah bir görüntü verirken 255 değeri ile kendi renklerini (örneğin kırmızı için 0 siyah 255 tam kırmızı) vermektedir. Alfa kanalında ise durum biraz farklıdır. Alfa kanalı görüntüye saydamlık (transparanlık) vermek için kullanılmaktadır. Alfa kanalı için 0 değeri tam saydam bir görüntü oluşmasını sağlarken 255 değeri saydam olmayan bir görüntü meydana getirir. Alfa değerine opaklık değeri de denilir. Bu çalışma da kullanılan görüntüler 32 bit - 4 kanallı değil 24 bit 3 kanallıdır; alfa değeri bu görüntüler için bir anlam ifade etmemektedir. Kırmızı yeşil ve mavi değerlerinin belirli oranlarda karışmasıyla ekranda görüntülenen diğer renkler meydana gelmektedir. Şekil 2.10.'da renklerin karışımı tablosu gösterilmektedir.




Şekil 2.10. Kırmızı, yeşil ve mavi renklerinin karışımları sonucu oluşan renkler (Her bir renk için tam değeri (255) kullanılmıştır)


Bu çalışma için kullanılan görüntüler için 8 bit birer renk değeri bulunmakta ve bunların farklı oranlarda birleşmeleri sonucu en nihayetinde ekranda görülen histopatolojik görüntü ortaya çıkmaktadır. Şekil 2.11.'de örnek bir kötü huylu görüntünün kırmızı, yeşil ve mavi renklerinin belirli oranlarda birleşmeleri sonucu meydana gelen görüntü gösterilmiştir. Şekil 2.12.'de (a) görseli 700x460 çözünürlüğe ve toplam 322.000 piksele sahip Şekil 2.11.'deki görüntünün histogram grafiğini göstermektedir. Histogram grafiği görüntüde bulunan kırmızı, yeşil ve mavi piksel sayısını ve bunların değerlerini özetler nitelikteki bir grafikdir. Şekil 2.12. (b) görselinde ise 224x224 çözünürlüğe ve toplam 50.176 piksele sahip olarak yeniden boyutlandırılmış hale getirilen görselin histogram grafiği verilmiştir. Bu iki grafikte incelenecek olursa 255'e yakın değerlerin yoğunlukta olduğu görülmektedir. 255'e yakın değerlerin fazla sayıda olması asıl renklerin (kırmızı - yeşil - mavi) fazla olduğu anlamına gelmektedir.



Şekil 2.11. Kırmızı, yeşil ve mavi kanallara sahip görüntünün bu 3 kanalın birleşimi ile ekranda görüntülenene hale gelmesi



(a) 700x460




(b) 224x224

Şekil 2.12. 700x460 çözünürlüğe sahip görüntünün ve yine aynı görüntünün yeniden boyutlandırma ile 224x224 çözünürlüğe getirilmesiyle oluşturulan görüntünün histogram grafikleri

2.8. Dolgu İşlemi

Dolgu (Padding) işlemi basitçe bir filtre vasıtasıyla görüntü incelenirken, görüntünün dış piksel sayısının artırılmasını ifade eden bir terimdir. Dolgu işleminde görüntünün etrafı 0 veya 1 gibi değerler ile çevrelenir. Bunun bazı avantajları bulunmaktadır. Şekil 2.13.'te gösterilen şekil incelenecek olursa sol üst kısımda gri renk ile boyanan piksel filtre ile 1 kez incelenecektir; buna karşın orta kısımda bulunan kırmızı renk ile boyanan piksel ise 1'den fazla kez incelenecektir. Bu durumda ortadaki pikseller hakkında köşede bulunan piksellere

göre daha fazla bilgiye sahip olma durumu ortaya çıkar. Bundan sakınmak amacıyla görüntünün etrafına pikseller eklenerek köşedeki pikseller hakkında da daha fazla bilgi elde edilmesi amaçlanır. Dolgu'nun bir diğer avantajı ise havuzlama amacıyla değil yalnızca piksel değeri değiştirilmesi amacıyla filtreleme yapıldığında ortaya çıkar. Bu gibi durumlarda köşelerde bulunan pikseller filtrelenemeyecek ve hata ile karşı karşıya kalınacaktır. Dolgu işlemi sayesinde bu sorun çözülür.




Şekil 2.13. Dolgu işleminin uygulama yöntemi ve kullanım amacı

2.9. Bırakma İşlemi

Derin öğrenme metotlarında modellerin birleştirilerek (kombinasyon) kullanılması pek çok durumda daha iyi bir sonuç verir. Bununla birlikte büyük ağların eğitimi çok fazla hesaplama gerektirir ve en iyi sonuca ulaşmak için gerekli parametreleri bulmak oldukça zorlu bir işlemdir. Ayrıca gelişmiş ağların eğitilmesi için oldukça fazla veriye ihtiyaç duyulmaktadır ve farklı ağların farklı veri setleri ile eğitilmesi için yeterli düzeyde veri bulunamayabilir. Bir şekilde bu sorunlar çözülerek modeller birleştirilerek kullanılsa dahi hepsini test anında kullanmak hızın önemli olduğu durumlarda mümkün değildir. Veri artırma işlemi modellere uygulanmasına karşın ezberleme problemi de kimi durumlarda tam olarak çözülememektedir. Bu problemler ile başa çıkmak için bırakma (Dropout) yöntemi önem arz etmektedir. Bırakma işleminde temel işlem eğitim sırasında nöronları (bağlantıları ile birlikte) modelden (sinir ağı) rastgele olarak düşürmektir. Bu işlem yalnızca eğitim safhasında

uygulanır test aşamasında uygulanmaz. Ayrıca bırakma işlemi pek çok farklı modele uygulanabilmektedir. Şekil 2.14.’te bırakma işlemi uygulanan bir örnek ağ gösterilmiştir (Srivastava vd., 2014: 1930).



Şekil 2.14. Bırakma işlemi uygulanan bir ağın görüntüsü (1-> Bırakma işleminden önce, 2-> Bırakma işleminden sonra)

2.10. Yığın Normalizasyonu

Aktivasyonlar ayarlanıp, ölçeklenerek giriş katmanı normalleştirilir. Örnek olarak 0’dan 1’e ve 1’den 1000’e kadar özelliklerimiz olduğunda öğrenmenin hızlandırılması için bu değerler normalleştirilir. Giriş katmanının bu işlemten yararlanması mümkün ise değerleri sürekli değişen gizli katmanlardaki değerler için de aynı işlem uygulanabilir.

Yığın normalizasyonu (Batch Normalization) gizli katman değerlerinin etrafında değiştiği miktarı azaltır [kovaryans kayması (covariance shift)]. Kovaryans kaymasını bir örnekle açıklamak gerekirse siyah otomobilleri tespit etmek için bir derin sinir ağıımız olduğunu düşünelim. Eğitim setimiz sadece siyah otomobillerden oluşmuş olsun. Bu durumda bu ağı renkli otomobilleri tespit etmek amacıyla kullanırsak pekte iyi sonuçlar elde edemeyiz. Yığın normalizasyonu bu sorunu çözebilir. Ayrıca her bir katmanın diğer katmanlardan bağımsız olarak öğrenmesine de izin verir. Daha yüksek öğrenme oranları kullanılabilir çünkü yığın normalizasyonu çok yüksek veya çok düşük bir aktivasyon olmadığından emin olur. Böylece daha önce eğitilemeyen durumlar artık eğitilebilir hale gelir. Yığın

normalizasyonunun hafif bir düzensileştirme (regularization - modele daha iyi genelleme yeteneği kazandırmak için öğrenme algoritmasında yapılan ufak değişiklikler) etkisi de vardır bu sayede ezberleme önlemede de etkili olur. Bırakma ve yığın normalizasyonunun birlikte kullanılması uygundur ancak dengenin iyi kurulması gereklidir. Tablo 2.2.'de yığın normalizasyonu gösterilmiştir. Sırayla incelenecek olursa ilk olarak mini yığında bulunan girdiler hepsi toplanır ve toplam girdi sayısına bölünür, böylece mini yığın ortalaması bulunur. Daha sonra mini yığında bulunan her bir girdiden ortalama değer eksiltip karesi alınır ve hepsi toplanarak toplam girdi sayısına bölünür. Veriler normalize edilir. Normalize olan veriler gamma ve beta ile çarpılır. Burada gamma ölçekleme parametresi ve beta kaydırma parametresidir. Basit bir tanımlama ile anlatılacak olursa yığın normalizasyonu katmanı kendinden önce gelen katmanın çıkışını normalize eder ve bir sonraki katmanı bu değerler ile besler. Böylece gizli katmanlar (hidden layers) arasındaki kovaryansı azaltır (Ioffe & Szegedy, 2015: 3) (Bjorck vd., 2018: 7694).

Tablo 2.2. Yığın normalizasyonu algoritmasının sözde kodları

<i>Giriş: mini yığın üzerindeki x değerleri: $B = \{x_{1...m}\}$;</i>	
<i>Öğrenilecek parametreler: γ, β</i>	
<i>Çıkış: $\{y_i = YN_{\gamma, \beta}(x_i)\}$</i>	
$\mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i$	<i>// mini yığın ortalaması</i>
$\sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2$	<i>// mini yığın varyansı</i>
$\hat{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}$	<i>//Normalleştirme</i>
$y_i \leftarrow \gamma \hat{x}_i + \beta \equiv YN_{\gamma, \beta}(x_i)$	<i>//Ölçeklendirme ve kaydırma</i>

2.11. Dense (Yoğun - Tam bağlı) Katman

Önceki katmanlarda belirlenen özellikler, hesap yükü azaltmaları vb. tamamı sonucunda dense (fully connected) katmanı kendinden önce gelen katmanın çıktıları alır ve sınıf sayısı boyutunda bir vektör açığa çıkarır (Softmax yaklaşımı). Bu çalışma için örnek vermek gerekirse bu vektör iyi huylu ve kötü huylu şeklinde olacaktır. Örneğin bu vektör [0.3, 0.7] şeklinde bir çıktı ise bu demektir ki görüntümüz %30 ihtimalle iyi huylu ve %70

ihtimalle kötü huyludur. Daha çok sınıfın bulunduğu problemlerde bu vektörün uzunluğu da ona göre artacaktır ve olasılıklar arasındaki karmaşa kimi durumlarda oldukça yüksek olacaktır. İkili sınıflandırma da görüntünün iki sınıftan birine ait olma zorunluluğu olduğu için ayırt etme işlemi nitekim daha kolaydır denilebilir. Aslında dense katmanı sınıflandırmayı tamamlayan görüntünün hangi sınıfa ait olduğu tahminini yapan katmandır. Bu çalışmada sınıflandırıcı olarak Softmax kullanılmıştır. SVM gibi farklı sınıflandırıcılarda bulunmaktadır (Liu vd., 2018: 2) (Ma & Lu, 2017: 2) (Qi vd., 2017: 152).

2.12. Sınıflandırma


Bu çalışma da kullanılan sınıflandırma yapısı ikili sınıflandırma (binary classification) olarak adlandırılır. Elde bulunan veriler 2 sınıfa ayrıldığı, her durumda bu iki sınıftan birisine ait olma durumu mevcut ise buna ikili sınıflandırma adı verilir. Yapılan bu çalışmada da giriş görüntüsü iyi huylu veya kötü huylu olarak bu iki sınıftan birine ait olma zorunluluğuna sahiptir. Eğer sınıf sayısı 2'den fazla ise örneğin bir hayvan görüntüsünün kedi, köpek, aslan, kaplan vb. veya meyvelerin elma, armut, ayva vb. gibi birden çok sınıftan hangisine ait olduğunun bilinmesi isteniyorsa buna da çok sınıflı sınıflandırma (multiclass classification) adı verilir. Bu sınıflandırma yöntemleri performans ölçütlerinin hesaplanma yöntemlerinde oldukça önem arz eden durumlardır. İkili sınıflandırma ve çok sınıflı sınıflandırma modelleri arasında hassasiyet, hatırlama, f1 skor ve bunların ortalamalarının hesaplanmaları farklılık göstermektedir. Özellikle bu değerlerin makro ortalama ve ağırlıklandırılmış ortalama değerleri hesaplanırken kullanılan mimarinin ikili sınıflandırma veya çok sınıflı sınıflandırma olması oldukça önem arz etmektedir.

2.13. Ön Eğitimli Ağlar

Ön-eğitimli ağlar ESA modellerinde öğrenmenin daha hızlı sağlanması, işlemlerin daha hızlı yapılması ve doğruluk başarımının artırılması için oldukça önemlidir. Bu ağlar benzer bir problem üzerinde önceden kullanılarak buna bağlı ağırlıklar alan modeller olarak bilinir. Her bir problem için tam olarak en uygun çözüm olmasalar dahi aynı işlemleri tekrar tekrar yapmanın önüne geçerler. Bu ağlar genellikle ImageNet ismi verilen ve görsel nesne tanıma üzerine kurulmuş çok büyük bir veri tabanı üzerinde önceden kullanılmıştır. Bu çalışmada da ön-eğitimli olan ResNet50, DenseNet201, InceptionV3 ve Xception ağları kullanılmıştır.

2.13.1. Residual Neural Network (ResNet)


Residual Network (ResNet) artık değerlerin (residual network) ve artık blokların (residual block) modele eklenmesiyle meydana gelir. Her iki katmanda bir [doğrusal ve ReLU (Düzleştirilmiş doğrusal birim katmanı) arasında iki katmanda bir] sisteme farklı bir değer ekleyerek gradyen kaybolmasının (vanishing gradient) önüne geçer (Tai vd., 2017: 3148). Bu aşama da bir durumda ağırlık sıfır olsa bile iki önceki katmandan gelen değer öğrenme hatasını geliştirir. Böylece ağ da daha çabuk eğitilmiş olur. Şekil 2.15.'te ResNet ağının örnek bir bloğu gösterilmiştir (Szegedy vd., 2017: 3).



Şekil 2.15. ResNet'te her iki katmanda bir eklenen değerın örnek bir blok üzerinde gösterilmesi (He vd., 2016: 771)

2.13.2. Dense Convolutional Network (DenseNet)


ResNet'te her iki katmanda bir eklenen değer DenseNet'te kendinden sonra gelen tüm katmanlara eklenmektedir. Bu sistem modele birçok avantaj kazandırmıştır. Bu sayede ağ daha kolay eğitilebilir hale gelmiş ve yüksek katmanlı ağlarda çoğu katmanın işlevsiz olma sorununu optimize etmiştir (G. Huang vd., 2017). Şekil 2.16.'da DenseNet ağının genel yapısı gösterilmiştir. Birleştirme işleminde aynı yükseklik ve genişliğe sahip girdiler alınır ve bunlar üçüncü boyut (kanal - derinlik boyutu) boyunca birleştirilir.




Şekil 2.16. DenseNet ağının yapısı

2.13.3. Ağ İçinde Ağlar

2013 yılında yayınlanan “Network in network (ağ içinde ağ)” makalesi ile Inception ağlarının temeli atılmaya başlanmıştır. Yayınlanan bu makalede geleneksel evrişimsel katmanın girişi taramak için doğrusal filtreler ve ardından doğrusal olmayan bir aktivasyon fonksiyonu kullanımından bahseder. Bu klasik yaklaşım yerine doğrusal yapıdaki evrişimsel ağın içine bir adet çok katmanlı algılayıcı (perceptron) yapısı eklenerek yeni bir model elde edilmiştir. Ayrıca bu model de küresel ortalama havuzlama (global average pooling) kullanılmıştır. Şekil 2.17.’de bu işlem gösterilmiştir. Modele uygulanan bu geliştirmeler sonrası CIFAR - 10, CIFAR - 100, MNIST ve SVHN veri setlerinde elde edilen performanslar oldukça başarılıdır. Modelin genel yapısı ise Şekil 2.18.’de gösterilmiştir (Lin vd., 2013: 1-4).




(a) Doğrusal evrişim katmanı



(b) Mlpconv katmanı


Şekil 2.17. Doğrusal evrişim katmanı ve mlpconv katmanının karşılaştırılması. Doğrusal evrişim katmanı doğrusal bir filtre içerirken Mlpconv katmanı bir mikro ağ içerir (Lin vd., 2013: 1-4)




Şekil 2.18. Ağ içinde ağ modelinin genel yapısını gösterir şekil. Ağ içinde ağ modelini literatüre kazandıran makale de üç mlpconv katmanı ve bir küresel ortalama havuzlama katmanı kullanılmıştır (Lin vd., 2013: 1-4)

2.13.3.1. Inception V1

Ağ içinde ağ modeli Google tarafından da benimsenmiştir. 2015 yılında derinlik ve genişlik olarak diğer modellere göre daha gelişmiş yeni bir model tasarlamışlardır. Bu model de kullanılan genişlik kavramı inception (başlangıç) adı verilen bloklar sayesinde sağlanmıştır. Naif Inception Modülü (Naive Inception Module) ismini verdikleri bir blok evrişim katmanlarında 1x1, 3x3, 5x5 ve 3x3 maksimum havuzlama (max pooling) işlemlerinin eş zamanlı (paralel) olarak yapılmasını sağlar. Bu yapı Şekil 2.19.'da gösterilmiştir (Szegedy vd., 2015: 1-4). Bu modül yüksek performans ölçütleri elde etmesine karşın bazı dezavantajları beraberinde getirmektedir. Evrişim katmanlarının fazla olması nedeniyle işlem karmaşıklığı, yapılan işlemler neticesinde çıkış boyutunun fazla olması ve parametre sayısının yapılan paralel işlemler neticesinde çok fazla artması bunlardan bazılarıdır. Bu sorunları optimize (en iyileme) etmek amacıyla 1x1 evrişim katmanları Naif Inception Modülü'nün evrişim katmanlarından önce kullanılarak boyut düşürme işlemi yapılmış ve 1x1 evrişim işlemlerinden sonra aktivasyon fonksiyonlarından ReLU kullanılır. Bu işlem Şekil 2.20.'de gösterilmiştir. Böylece InceptionV1 modeli ortaya çıkmıştır. Inception V1 modeli 9 modülden oluşmaktadır.



Şekil 2.19. Naif Inception modülü (Szegedy vd., 2015: 1-4)



Şekil 2.20. Boyut düşürme işlemleri eklendikten sonra ki Inception modülü (Szegedy vd., 2015: 1-4)

1x1 evrişim işlemlerinin boyut düşürme açısından faydalı olduklarından bahsetmiştik; ancak bir matris işlemi üzerinde 1x1 evrişimin herhangi bir etkisi olmayacaktır. Bu durum Şekil 2.21.'de gösterilmiştir. Buna karşın giriş görüntüsünün çok kanallı olduğu durumlarda (örneğin bu çalışmada kullanılan görüntüler 3 kanallıdır) 1x1 evrişim uygulandığında çıkış

görüntüsünün kanal sayısı filtre sayısına eşit olacaktır. Bu durumda 1x1 evrişim kanal sayısında (derinlikte) boyut azaltmaktadır denilir.

1	3	5	7	2	6
9	2	4	1	3	8
4	3	7	6	8	2
2	5	9	4	9	1
3	7	4	1	2	5
8	6	2	4	7	3


$$* \begin{bmatrix} 2 \end{bmatrix} =$$

2	6	10	14	4	12
18	4	8	2	6	16
8	6	14	12	16	4
4	10	18	8	18	2
6	14	8	2	4	10
16	12	4	8	14	6


Şekil 2.21. 2 boyutlu matrislerde yapılan 1x1 evrişim işlemi.

2.13.3.2. Inception V2

InceptionV1 derin öğrenmeye yeni bir bakış açısı kazandırmasına karşın halen işlem yükü açısından eksiklikler barındırmaktaydı. Hesap yükünün daha da azaltılması amacıyla InceptionV1’de bulunan 5x5 evrişim işlemi 2 adet 3x3 evrişim işlemi ile sağlanmaya çalışılmıştır. Yapılan bu işlem Şekil 2.22.’de gösterilmiştir. 3x3 evrişim işlemi ise 3x1 olarak katmanlara ayrılmış ve çıkış sayısı 3 olmuştur. Böylece kazanç daha da artırılmıştır. 3x3 katmandan 3x1 katmanları oluşturulurken nxn evrişim işlemi 1xn ve nx1 olarak ifade edildiğinden hesap yükü n olarak artar. Ağ yapısı başlangıç katmanlarında çok başarı gösteremezken orta katmanda oldukça başarılı olmuştur. Ayrıca yığın normalizasyonu (batch normalization) ve bırakma (dropout) kullanımı da modelin performansına olumlu yönde yansımıştır. Bu işlemler sonucunda Inception modülünün geldiği aşama Şekil 2.23.’te gösterilmiştir. Bu yapı InceptionV2 olarak adlandırılır (Szegedy vd., 2016: 2818-2823).



Şekil 2.22. Klasik modüldeki 5x5 evrişim işleminin 2 adet 3x3 evrişim işlemi ile gerçekleştirilmesi (Szegedy vd., 2016: 2818-2823)



Şekil 2.23. 3x3 evrişim katmanlarının alt katmanlara ayrıldıktan sonraki Inception modülünün görüntüsü (Szegedy vd., 2016: 2818-2823)


2.13.3.3. Inception V3

InceptionV3 ağına InceptionV2'den farkı yardımcı sınıflandırıcının sadece evrişim katmanlarını değil tam bağlı katmanı da (fully connected layer) normalize etmesi ile meydana gelir (Szegedy vd., 2016: 2818-2823).


2.13.4. Xception

Xception ağı Inception ağlarının üzerine inşa edilmiş bir ağ yapısıdır. “Extreme Inception (Aşırı Inception)” olarak da adlandırılır. InceptionV3 üzerine eklediği katkı 1x1 evrişimin çıkış kanallarının her birisi için evrişim kullanmasıdır (Bkz. Şekil 2.26). Şekil 2.25'te basitleştirilmiş Inception modülü gösterilmiştir. Bu modül klasik Inception modülünün tamamen eşdeğer bir yeniden formülasyonudur. Xception modülünde kullanılan bir diğer farklılık değiştirilmiş derinlikle ayrılabilir evrişim (modified depthwise convolution) olarak adlandırılır. Bu yapı aslında InceptionV3'te de kullanılan 1x1 evrişim ve ardından gelen nxn evrişimlerin devamlılığına verilen isimdir, buna rağmen bu yapının orijinal halinde öncelikle nxn evrişimler ve ardından 1x1 evrişimler uygulanmaktaydı. Yani Xception ve InceptionV3'te izlenen yolun tam tersi yapılmaktaydı. Orijinal halde yapılan ilk işlem sonrası bir doğrusal olmayanlık (non-linearity) mevcuttu, ancak değiştirilmiş derinlikle ayrılabilir evrişim de ara ReLU doğrusalsızlığı (intermediate ReLU non-linearity) yoktur. Buna karşın farklı aktivasyon üniteleri ile test edilen Xception en yüksek doğruluk değerine herhangi bir ara ReLU aktivasyonu kullanılmadan ulaşmıştır. Bu durum Xception mimarlarından Chollet'in çalışmasında Şekil 2.27.'de gösterilmiştir (Chollet, 2017: 1251-1258).


Xception ağı kullanılarak oluşturulan modelin genel yapısı Şekil 2.24.'te gösterilmiştir. Şekilde görüldüğü üzere 299x299 ve 3 kanallı giriş görüntüsü arada bulunan katmanlardan geçerek çıkışta iyi huylu veya kötü huylu olarak sınıflandırılmaktadır.




Şekil 2.24. Xception kullanılarak oluşturulan mimarinin genel yapısı.



Şekil 2.25. Basitleştirilmiş Inception modülü (Chollet, 2017: 1251-1258)




Şekil 2.26. Inception modülünün extreme (aşırı) versiyonu, 1x1 evrişimlerin çıkış kanallarının her birisi için evrişim kullanması (Chollet, 2017: 1251-1258)



Şekil 2.27. Ara aktivasyon kullanılmadığı durumda Xception ağına daha yüksek doğruluk değerlerine ulaşması (Chollet, 2017: 1251-1258)

Şekil 2.28’de Xception ağına tüm yapısı gösterilmiştir. Burada belirtilen SeperableConv değiştirilmiş derinlikle ayrılabilir evrişimi ifade etmektedir. Bu yapının tüm mimari boyunca kullanıldığı görülmektedir, ayrıca ResNet’te kullanılan artık değerler burada da kullanılmıştır. Yine Chollet’in çalışmasına göre Xception artık değerler ile daha başarılı sonuçlar elde etmektedir (Chollet, 2017: 1251-1258).



Şekil 2.28. Xception ağıının tüm yapısı gösterir şekil (stride: Adım büyüklüğü, +: Filtre birleştirme işlemi, SeperableConv: Değiştirilmiş derinlikle ayrılabilir evrişim) (Chollet, 2017: 1251-1258).

3. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışmada ResNet50, DenseNet201, InceptionV3 ve Xception olmak üzere dört farklı ön-eğitilmiş ağ kullanılmış ve gerçekleştirilen deneysel çalışmalar ile her birisi ile elde edilen sonuçlar kendi arasında karşılaştırılmıştır. Ulaşılan sonuçlar histopatolojik görüntüler üzerinde meme kanserinin tespiti ve sınıflandırılmasında Xception ağının daha başarılı olduğunu göstermektedir. Nadiren de olsa, DenseNet201 ve InceptionV3 ağı Xception ile benzer ve hatta iyi sonuçlar elde etmiştir.

Bu çalışma da önerilen model eğitilirken kullanılan bilgisayar Intel Core i7-7700HQ 2.80 GHz işlemci, 16 GB DDR4 RAM ve 4 GB NVIDIA GeForce GTX 1050 Ti grafik kartına (GPU) sahiptir. Yapılan çalışma da kullanılan görüntülerin %80'i eğitim için ve kalan %20'si test için kullanılmıştır. Deneysel çalışmalar Python programlama dili ve Keras kütüphane ortamı kullanılarak gerçekleştirilmiştir.

Tablo 3.1.'de formülasyonlarda kullanılan kısaltmaların ve bunların ne anlamlara geldiği gösterilmiştir.

Tablo 3.1. Ölçüm metriklerinde kullanılan karmaşıklık matrisi parametreleri

Doğru Pozitif (DP): - Görüntünün gerçek niteliği: Kötü huylu - Model tarafından tahmin edilen nitelik: Kötü huylu	Yanlış Pozitif (YP): - Görüntünün gerçek niteliği: İyi huylu - Model tarafından tahmin edilen nitelik: Kötü huylu
Yanlış Negatif (YN): - Görüntünün gerçek niteliği: Kötü huylu - Model tarafından tahmin edilen nitelik: İyi huylu	Doğru Negatif (DN): - Görüntünün gerçek niteliği: İyi huylu - Model tarafından tahmin edilen nitelik: İyi huylu

Ağların performanslarının değerlendirilmesi amacıyla kullanılan Doğruluk, Hassasiyet, Hatırlama ve F1 Skor değerlerinin hesaplanma eşitlikleri sırasıyla (1), (2), (3) ve (4)'te verilmiştir.

$$\text{Doğruluk (Accuracy)} = \frac{DP + DN}{(DP + DN + YP + YN)} \quad (1)$$

$$\text{Hassasiyet (Precision)} = \frac{DP}{(DP + YP)} \quad (2)$$


$$\text{Hatırlama (Recall)} = \frac{DP}{(DP + YN)} \quad (3)$$

$$\text{F1 Skor} = \frac{2 * (\text{Hassasiyet} * \text{Hatırlama})}{(\text{Hassasiyet} + \text{Hatırlama})} \quad (4)$$


Çalışmada kullanılan tüm ağlar 40 epok (adım) boyunca eğitilmiş, doğruluk, onaylama doğruluğu, kayıp ve onaylama kaybı değerlerini gösteren grafikler Şekil 3.1.'de gösterilmiştir. Bu grafikler verisetindeki 200X yakınlaştırma oranına sahip görüntülerin sonuçlarını göstermektedir.

Şekil 3.1.'de neredeyse tüm ağların yaklaşık ilk 20-25 epok boyunca bir salınım içerisinde bulunduğu daha sonra ise daha stabil bir hale geldiği görülmektedir. Bunun nedeni öğrenme oranının başlangıçta yüksek; ama zamanla azaltılarak daha doğru sonuçlar elde edilmesidir. Şekil 3.1.'de ortaya çıkan bir diğer durum ise eğitim aşamasında ulaşılan doğruluk değeri onaylama aşamasında ulaşılanlara göre 4 ön eğitilmiş ağda da daha düşük kalmıştır. Bu durum başlangıçta oldukça kötü bir durum gibi gözükmeyle beraber aslında her durumda istenilen bu şekilde olması kabul edilen bir durumdur, çünkü ağın son aldığı parametreler ve asıl ulaştığı konum onaylama aşamasında ki başarıyı ile doğru orantılıdır. Bunun sebebi ise eğitim aşamasında uygulanan bırakma ve veri artırma yöntemleridir. Bırakma işlemi sadece eğitim aşamasında uygulanır ve bazı birimleri yok sayarak onaylama aşamasında daha başarılı bir ağ ortaya çıkmasını sağlar. Veri artırma işleminde ise elde bulunan veri farklı işlemlerden geçerek bazı değişikliklere uğrar ve ağ eğitim aşamasında bu yeni görüntüleri tahminde zorlansa dahi onaylama aşamasında çok daha başarılı olacaktır. Bu durum Şekil 3.2.'de Xception ağının 200X yakınlaştırma oranında bırakma ve veri artırma işlemlerinin uygulandığı (a) ve bu işlemlerin uygulanmadığı (b) durumlarda eğitim ve onaylama aşamalarında ki doğruluk değerleri gösterilmiştir. Bu işlemler uygulanmadığı durumda eğitim aşamasındaki doğruluk değeri onaylama aşamasındaki geçmiştir; ancak ağın

genel başarımı için daha çok önem arz eden onaylama aşamasındaki doğruluk değeri ise bu işlemlerin uygulandığı duruma göre daha düşük kalmıştır. Bu nedenle bu işlemlerin uygulanması oldukça önem arz etmektedir.



Şekil 3.1. DenseNet201, InceptionV3, ResNet50 ve Xception önceden eğitilmiş ağlarının 200X yakınlaştırma oranındaki başarımlarını gösteren grafikleri.




(a) Xception 200X yakınlaştırma oranı için bırakma ve veri artırma işlemlerinin uygulanması durumunda doğruluk ve kayıp değerlerinin durumu.

(b) Xception 200X yakınlaştırma oranı için bırakma ve veri artırma işlemlerinin uygulanmaması durumunda doğruluk ve kayıp değerlerinin durumu.


Şekil 3.2. Xception ağının bırakma ve veri artırma işlemlerine verdiği tepkiler

Xception ağının en başarılı olduğu 200X yakınlaştırma oranı için Xception ve diğer ağların karmaşıklık matrisi TTA işlemi uygulanmadan önce ve uygulandıktan sonra Şekil 3.3.'te gösterilmiştir. Karmaşıklık matrislerinde ağların verisetinde yapılan ayırım sonucu görüntülere verdikleri tahminler ve görüntülerin gerçek değerleri gösterilmektedir. Xception ağının karmaşıklık matrisi incelenecek olursa (TTA işleminden sonra) toplam 404 görüntü üzerinde gerçekten iyi huylu olan 126 görüntü ve gerçekten kötü huylu olan 278 görüntü bulunmaktadır. Xception ağı iyi huyluların 121 tanesini doğru (iyi huylu tahmini yapmış) ve 5 tanesini yanlış (kötü huylu tahmini yapmış) tahmin etmiş, kötü huyluların ise 275 tanesini doğru (kötü huylu tahmini yapmış) ve 3 tanesini yanlış (iyi huylu tahmini yapmış) değerlendirmiştir. DenseNet201 ağı iyi huyluların 123 tanesini doğru (iyi huylu tahmini yapmış) ve 3 tanesini yanlış (kötü huylu tahmini yapmış) tahmin etmiş, kötü huyluların ise 272 tanesini doğru (kötü huylu tahmini yapmış) ve 6 tanesini yanlış (iyi huylu tahmini yapmış) değerlendirmiştir.



TTA uygulanmadan önceki
karmaşıklık matrisi



TTA uygulandıktan sonraki
karmaşıklık matrisi





(a) DenseNet201





(b) InceptionV3

TTA uygulanmadan önceki
karmaşıklık matrisi



TTA uygulandıktan sonraki
karmaşıklık matrisi



(c) ResNet50

(d) Xception

Şekil 3.3. 200X yakınlaştırma oranındaki görüntülerde ön-eğitilmiş ağların TTA'lı ve TTA'sız karmaşıklık matrisleri

ResNet50 ağı iyi huyluların 115 tanesini doğru (iyi huylu tahmini yapmış) ve 11 tanesini yanlış (kötü huylu tahmini yapmış) tahmin etmiş, kötü huyluların ise 271 tanesini doğru (kötü huylu tahmini yapmış) ve 7 tanesini yanlış (iyi huylu tahmini yapmış) değerlendirmiştir. InceptionV3 ağı iyi huyluların 116 tanesini doğru (iyi huylu tahmini yapmış) ve 10 tanesini yanlış (kötü huylu tahmini yapmış) tahmin etmiş, kötü huyluların ise 270 tanesini doğru (kötü huylu tahmini yapmış) ve 8 tanesini yanlış (iyi huylu tahmini yapmış) değerlendirmiştir. Bu tahminler arasında Xception ağının çok daha başarılı olduğu görülür. Öte yandan TTA işleminin ağlara olan etkileri incelendiğinde toplam hatalı tahmin sayısı: Xception için 10'dan 8'e, ResNet50 için 28'den 18'e, InceptionV3 için 25'ten 18'e düşmüş ve DenseNet201 ağı için de olumlu veya olumsuz bir sonuç doğurmamıştır. Bu bilgiler ışığında TTA işlemi 3 ağı olumlu yönde etkilemiş 1 ağı ise ne olumlu ne de olumsuz olarak etkilememiştir. Buna göre TTA işleminin genel anlamda ağların başarımını olumlu yönde etkilediği söylenir.

Tablo 3.2.'de sunulan sonuçlar, bu çalışma da kullanılan tüm ön-eğitilmiş ağların 40X, 100X, 200X ve 400X yakınlaştırma oranlarına sahip histopatolojik görüntüler üzerindeki eğitimlerinin sonuçlarını özetlemektedir. Ağların doğruluk skorları genel olarak karşılaştırıldığında Xception ağının göstermiş olduğu başarı açıkça görülür. Özellikle 200X yakınlaştırma oranında Xception %98.01'lik bir başarı ortaya koymuştur. Bu değer hem bu çalışma da kullanılan diğer ağların yakınlaştırma oranı fark etmeksizin elde ettiği doğruluk skoru değerlerinden hem de Xception ağının kendi yakınlaştırma oranı değerlerinden yüksektir. Bu da göstermektedir ki bu çalışma da elde edilen en başarılı sonuç Xception ağının 200X yakınlaştırma oranında elde ettiği %98.01'lik doğruluk skoru değeridir. Bu tablodaki makro ortalama ve ağırlıklı ortalama değerleri her bir performans ölçütü için ayrı ayrı hesaplanır. Eşitlik 1, Eşitlik 2 ve Eşitlik 3'te sırasıyla hassasiyet değeri, hatırlama değeri ve F1 skor değerinin makro ortalamaları gösterilmiştir. Eşitlik 4, Eşitlik 5 ve Eşitlik 6'da ise hassasiyet değeri, hatırlama değeri ve F1 skor değerinin ağırlıklı ortalamaları gösterilmiştir. 1, 2 ve 3. eşitliklerde n : Verisetindeki sınıf sayısı, $P_1, P_2, \dots, P_n$: Her bir sınıf için hesaplanan hassasiyet değeri. 4, 5 ve 6. Eşitliklerde n : Verisetindeki toplam sınıf sayısı, $R_1, R_2, \dots, R_n$: Her bir sınıf için hesaplanan hatırlama değeridir (Behera & Kumaravelan, 2019: 222) (Vani & Rao, 2019: 334) (Goutte & Gaussier, 2005: 346-347) (David MW Powers, 2015: 3).

$$\text{Hassasiyet Değeri (Makro Ortalama)} = \frac{\sum_{i=1}^n P_i}{n} \quad (1)$$

$$\text{Hatırlama Değeri (Makro Ortalama)} = \frac{\sum_{i=1}^n R_i}{n} \quad (2)$$

$$\text{F1 Skor Değeri (Makro Ortalama)} = \frac{2}{\frac{1}{\frac{\sum_{i=1}^n P_i}{n}} + \frac{1}{\frac{\sum_{i=1}^n R_i}{n}}} \quad (3)$$

$$\text{Hassasiyet Değeri (Ağırlık. Ort.)} = \frac{\sum_{i=1}^n |y_i| \frac{dp_i}{dp_i + yp_i}}{\sum_{i=1}^n |y_i|} \quad (4)$$


$$\text{Hatırlama Değeri (Ağırlık. Ort.)} = \frac{\sum_{i=1}^n |y_i| \frac{dp_i}{dp_i + yn_i}}{\sum_{i=1}^n |y_i|} \quad (5)$$

$$\text{F1 Skor Değeri (Ağırlık. Ort.)} = \frac{\sum_{i=1}^n |y_i| \frac{2dp_i}{2dp_i + yn_i + yp_i}}{\sum_{i=1}^n |y_i|} \quad (6)$$

Tablo 3.2.'de gösterilen F1 skor ve doğruluk skor değerleri ağların başarımlarının değerlendirilmesinde kullanılan ölçütlerdir. Bu ölçütlerin hesaplanma yöntemleri birbirinden farklılık gösterebilir dahi ikisi de performans ölçütü olarak kullanılabilir. F1 skor, hassasiyet, hatırlama ve doğruluk değerlerinin hesaplanma yöntemleri dikkate alındığında doğruluk değerinin doğru pozitif ve doğru negatif değerleri önem arz ettiğinde F1 skor değerinin ise yanlış negatif ve yanlış pozitif değerlerinin önem arz ettiği durumlarda kullanılmasının daha uygun olduğu söylenebilir.

Tablo 3.2.'deki doğruluk ve F1 skor değerleri dikkate alındığında bu ağlar arasındaki kıyaslama Xception -> DenseNet201 -> InceptionV3 ve ResNet50 şeklinde yapılabilir. Bu tablodan çıkarılabilecek bir diğer husus ağların yakınlık oranlarına göre verdikleri sonuçların durumlara göre farklılık göstermesidir. Örneğin InceptionV3 ağı 400X yakınlık oranında 92.34 gibi nispeten düşük bir doğruluk skoru değerine ulaşırken 200X değerinde 95.54 gibi oldukça yüksek bir değere ulaşmıştır. Hassasiyet değeri ve hatırlama değeri F1 skorunun hesaplanmasında kullanılır ve hesaplamalarına bakıldığında oldukça kolay birbiri ile karıştırılmaktadır. Hassasiyet değeri “pozitif tanımlamaların ne kadar gerçekten pozitif?” sorusuna cevap verirken hatırlama değeri “Gerçekten pozitif olanların ne

kadarı doğru tanımlandı?” sorusuna cevap vermektedir (David Martin Powers, 2011) (Saito & Rehmsmeier, 2015: 3). Bu durum Şekil 3.4.’te gösterilmiştir.




Şekil 3.4. Hassasiyet ve Hatırlama değerlerinin farkı


Tablo 3.2. Bütün ağların göstermiş olduğu performans metrikleri (Yak.D.: Yakınlaştırma Değeri D.S.: Doğruluk Skoru, Has. D.:Hassasiyet Değeri, Hat.D.: Hatırlama Değeri, M.O.: Makro Ortalama, A.O.: Ağırlıklandırılmış Ortalama)

Ağ Adı	Yak. D.	D.S.	Has.D.	Hat.D.	F1 Skoru	Has.D. (M.O.)	Hat.D. (M.O.)	F1 Skoru (M.O.)	Has.D. (A.O.)	Hat. D. (A.O.)	F1 Skoru (A.O.)
DenseNet201	40X	97.50	98.52	97.81	98.16	96.92	97.31	97.11	97.51	97.50	97.50
	100X	94.49	94.61	97.56	96.06	94.41	92.63	93.51	94.48	94.49	94.49
	200X	97.77	97.86	98.92	98.38	97.71	97.07	97.39	97.77	97.77	97.77
	400X	95.08	96.74	95.96	96.35	94.20	94.59	94.40	95.10	95.08	95.09
InceptionV3	40X	94.75	97.02	95.25	96.13	93.55	94.45	93.99	94.83	94.75	94.79
	100X	95.21	95.57	97.56	96.56	94.96	93.78	94.37	95.19	95.21	95.20
	200X	95.54	96.42	97.12	96.77	94.98	94.59	94.79	95.53	95.54	95.53
	400X	92.34	92.63	96.37	94.46	92.15	90.13	91.13	92.32	92.34	92.33
ResNet50	40X	93.25	92.73	97.81	95.20	93.66	90.57	92.09	93.31	93.25	93.28
	100X	93.30	92.20	98.61	95.30	94.28	90.07	92.13	93.50	93.30	93.40
	200X	95.54	96.09	97.48	96.78	95.18	94.37	94.77	95.52	95.54	95.53
	400X	90.43	89.88	96.77	93.20	90.90	86.94	88.88	90.54	90.43	90.48
Xception	40X	97.25	97.47	98.54	98.00	97.11	96.49	96.80	97.24	97.25	97.24
	100X	94.97	95.87	96.87	96.37	94.39	93.82	94.10	94.95	94.97	94.96
	200X	98.01	98.21	98.92	98.56	97.89	97.47	97.68	98.01	98.01	98.01
	400X	95.35	92.92	95.16	96.52	94.16	95.46	94.80	95.49	95.35	95.42


Makine öğrenmesi uygulamalarında performans değerlendirmesi için en yaygın olarak kullanılan yöntemlerden birisi de AİK [Alıcı İşletim Karakteristiği - ROC (Receiver Operating Characteristic)] eğrileridir. AİK grafikleri modelin tahminlerinde ne kadar başarılı olduğunu gösterir. AİK eğrisinin altında kalan alan ise EAA [Eğri altındaki alan - AUC (Area under curve)] olarak adlandırılır. EAA değeri bir alan kapsamıyla gösterilir ve bu alan ne kadar geniş ise modelin sınıflandırma da elde ettiği başarı da o kadar yüksek olarak tanımlanır. EAA değeri için optimum değer 1 olarak ifade edilir (Bradley, 1997: 1146-1147) (Hajian-Tilaki, 2013: 631). Şekil 3.5.'te Xception ağına 40X, 100X, 200X ve 400X yakınlaştırma oranlarındaki AİK grafikleri ve EAA değerleri gösterilmiştir. EAA değeri, doğruluk değeri, F1 skor değeri hepsi ağların başarımlarının değerlendirilmesi için kullanılan ölçütlerdir. Kimi çalışmalara göre EAA değeri doğruluk değerine göre daha güvenilir ve ağına başarımlarını ölçmede doğruluk değerine göre daha doğru sonuçlar vermektedir (Ling vd., 2003: 329) (J. Huang & Ling, 2005: 299-302). Şekil 3.5. ve Şekil 3.6.'de yer alan değerlere göre DenseNet201 ağına 40X yakınlaştırma oranındaki EAA değeri (0.973), F1 skor değeri (98.16) ve doğruluk değeri (97.50) Xception ağına (0.965 - 98.00 - 97.25) ve diğer ağların değerlerine göre daha yüksektir. Bu durumda 40X yakınlaştırma oranı özelinde DenseNet201 ağı bu dört ağ arasındaki en başarılı ağıdır. 100X yakınlaştırma oranında ise Inception V3 ağına F1 Skor ve Doğruluk (96.56 - 95.21) değerleri Xception'ın (96.37 - 94.97) ve diğer ağların değerlerine göre daha yüksektir; ancak Xception ve Inception V3'ün EAA değerleri (0.938) birbirine eşittir. Bunlara karşın 200X ve 400X yakınlaştırma oranları incelendiğinde Xception ağına EAA - F1 skor ve doğruluk değerlerinin diğer tüm ağlara göre daha yüksek olduğu görülmektedir. Sonuç olarak 40X yakınlaştırma oranında DenseNet201, 100X yakınlaştırma oranında EAA'ya göre Xception ve InceptionV3 eşit; F1 - Skor ve Doğruluk değerine göre Inception V3, 200X ve 400X yakınlaştırma oranında Xception ağı diğer ağlara oranla daha başarılıdır.




(a) Xception 40X



(b) Xception 100X




(c) Xception 200X



(d) Xception 400X

Şekil 3.5. Xception ağıının tüm yakınlaştırma oranlarındaki AİK eğrileri ve EAA değerleri

Şekil 3.6.'de Xception harici diğer ağların tüm yakınlaştırma oranlarındaki AİK eğrileri ve EAA değerleri gösterilmiştir.




Şekil 3.6. Ağların tüm yakınlaştırma oranlarındaki AİK eğrileri ve EAA değerleri


Şekil 3.7.'de rastgele seçilen 8 adet 200X yakınlaştırma oranındaki histopatolojik görüntü için Xception ağının yapmış olduğu tahminler ve bu görüntülerin gerçek değerleri gösterilmektedir (Xception ağının en başarılı sonucunu 200X yakınlaştırma oranında verdiğiinden önceki bölümlerde bahsedilmişti). Bu görüntüler yeniden boyutlandırma işlemi ile 299x299 konumuna getirilmiş ve ağın bu görüntüler için bir tahmin yapması istenmiştir. Görüldüğü üzere a, c, e, g ve h'de gerçek sonuçlar kötü huylu ve ağın tahmin ettiği sonuçta kötü huyludur. b, d ve f'de ise gerçek sonuçlar iyi huylu ve ağın tahmin ettiği sonuçta iyi huyludur. Bu 8 görüntü içinde Xception ağı doğru tahmin yapmıştır. Buna karşın Şekil 3.8.'de gösterildiği üzere k, l ve m'de gerçek sonuç kötü huylu iken Xception iyi huylu tahmini yapmıştır. Son olarak j'de ise gerçek sonuç iyi huylu iken Xception kötü huylu tahmini yapmıştır. Bu 4 görüntüde ise Xception yanılmıştır.

200X yakınlaştırma oranında %98.01'lik bir doğruluk değerine ulaşan Xception bu başarımını yaptığı tahminler ile de görsel olarak göstermektedir. Şekil 3.8.'de Xception ağının özellikle yaptığı yanlış tahminler seçilerek gözler önüne serilmiştir. Bu nedenle 4 tane art arda hatalı sonuca yer verilmiştir ki Xception'ın 200X yakınlaştırma oranında ki karmaşıklık matrisi tekrardan incelenecek olursa (Şekil 3.3.), Xception 5 iyi huylu görüntüye kötü huylu diyerek yanılmış ve 3 tane de kötü huylu görüntüye iyi huylu diyerek yanılmıştı. Toplam 8 görüntüyü hatalı olarak tespit eden Xception'ın yaptığı 4 hatalı tahmin de (yaptığı toplam hatalı tahminlerin yarısı) Şekil 3.8.'de görülmektedir. Bunlara ek olarak Şekil 3.8.'de Xception 3 tane kötü huylu görüntüye (k, l ve m) iyi huylu tahmininde bulunmuştur ve yine karmaşıklık matrisinden hatırlanacağı üzere Xception 3 tane kötü huylu görüntüyü yanlış tahmin etmişti. Bir başka deyişle Xception ağının yapmış olduğu tüm yanlış negatif değerleri Şekil 3.8.'de görülebilmektedir.

Yapılan analizler ve incelemeler neticesinde farklı yakınlaştırma oranlarına sahip histopatolojik meme kanseri görüntülerinde farklı ağlar başarılı olmayı başarmıştır. Buna göre kesin olarak hangi ağın daha başarılı olduğunu belirtebilmek için özellikle yakınlaştırma oranının dikkate alınması gerektiği sonucuna varılır. Buna karşın Xception ağının hem toplam 4 yakınlaştırma oranının 2'sinde en iyi sonucu vermesi hem de ilk sırayı alamasa dahi diğer 2 yakınlaştırma oranında da oldukça yüksek performans ölçütü değerlerine ulaşması yapılan bu kıyaslamamanın galibinin Xception olduğunu söyleyebilmek için yeterlidir.



Şekil 3.7. Xception ağının 200X yakınlaştırma oranındaki rastgele seçilen 8 görüntünün gerçek değerini doğru olarak tahmin etmesi



Şekil 3.8. Xception ağının 200X yakınlaştırma oranındaki rastgele seçilen 4 görüntünün gerçek değerini yanlış olarak tahmin etmesi

Tablo 3.3.'te literatürde BreakHis veriseti kullanılarak yapılan diğer çalışmalar, yöntemleri, algoritmaları ve doğruluk değerleri sunulmuştur. Bu tablodan elde edilen verilere göre, bu tez çalışmasında önerilen yöntemin histopatolojik görüntüler üzerinde meme kanserinin tespitinde başarılı olduğu görülmektedir.

Tablo 3.3. Literatürde BreakHis veriseti kullanılan benzer çalışmaların karşılaştırılması

Çalışma	Yöntem	Algoritma	Doğruluk (%)
(Chan & Tuszynski, 2016: 1)	Çok sınıflı tümör sınıflandırma	Fraktal boyut + Destek Vektör Makineleri (SVM)	55.60
(Nahid vd., 2018b: 1)	Tümör sınıflandırma	ESA + Uzun Kısa Süreli Hafıza (LSTM) + Softmax + Destek Vektör Makineleri (SVM)	91.00
(Adeshina vd., 2018: 206)	Tümör sınıflandırma	Derin Evrişimsel Sinir Ağı (DCNN) + TensorFlow + Düzleştirilmiş Doğrusal Birim Katmanı (ReLU)	91.50
(Celik vd., 2020: 232)	Tümör sınıflandırma	DenseNet161	91.57
(Han vd., 2017: 1)	Çok sınıflı tümör sınıflandırma	Yapılandırılmış Derin Öğrenme Modeli (SDLM)	93.2
(Dimitropoulos vd., 2017: 1)	Tümör derecelendirmesi	Yerel Olarak Toplanmış Tanımlayıcıların Vektörü (VLAD)	95.8
(Wei vd., 2017: 348)	Tümör sınıflandırma	Derin Evrişimsel Sinir Ağlarına Dayalı Histopatolojik Görüntülerde Meme Kanseri Sınıflandırması (BiCNN)	97.89
Önerilen Çalışma	Tümör sınıflandırma	Xception	98.01

4. SONUÇLAR

Yapılan çalışmada meme kanseri histopatolojik görüntüleri üzerinde tahmin yapabilen bir model geliştirilmiştir. Geliştirilen bu modele önceden eğitilmiş 4 farklı ağ desteği eklenmiştir. 4 ağda %90 ve üzeri başarı oranlarına ulaşarak meme kanseri tespitinde etkili sonuçlar elde etmiştir.

Çalışma sonucuna göre ağlar yakınlaştırma oranından etkilenmiş ve yapı aynı olsa dahi farklı başarı oranlarına ulaşmışlardır. Bu da göstermektedir ki veri setlerinin farklı olması bir kenara aynı görüntüde ki farklı yakınlaştırma oranları dahi ağların başarı oranını etkilemektedir. Eğitim sırasındaki başarı oranı daima onaylama aşamasındakine göre daha düşük kalmıştır. Bu başlangıçta kötü bir durummuş gibi gözükse de aslında oldukça faydalı hatta neredeyse her durumda istenilen bir şeydir çünkü ağın son hali onaylama işlemi sırasında ki ağıdır ve son hali o parametrelerde bulunan ağ olacaktır. Bunun yanı sıra eğitim sırasındaki başarı oranının daha düşük olmasının sebebi bırakma ve veri artırma işlemleridir. Bırakma değeri eğitim sırasında bazı birimleri yok sayarak parametrelerin gelişmesini sağlayarak onaylama sırasında daha sağlam ve daha doğru kararlar alabilen bir model ortaya koymaktadır bu nedenle onaylama aşamasındaki başarı oranı daha yüksektir. Yapılan analizler ve karşılaştırmalara göre Xception, DenseNet201 ve InceptionV3 ağları her bir yakınlaştırma oranına sahip verisetinde yüksek performans metrik değerleri elde ederek ResNet50'ye göre bu verisetinde daha başarılı olduklarını göstermişlerdir. Bu 3 ağ arasındaki bir kıyaslama durumunda ise yakınlaştırma oranına göre farklılık gösterse de Xception ağının daha başarılı bir sonuç elde ettiği ortaya koyulmuştur. Karmaşıklık matrislerinin incelenmesi sonucu TTA işleminin sadece bir durumda olumlu veya olumsuz bir etki etmediği diğer tüm durumlarda doğru tahmin sayılarında olumlu bir gelişme sağladığı görülmüştür. Buna dayanarak TTA işleminin başarı sonucunu olumlu yönde etkilediği sonucuna varılmıştır.

Yapılan bu çalışma da kullanılan görüntüler ağa girdi olarak verilmeden önce aynı boyuta getirilmelidir. Bu çalışma da tek bir veriseti (tüm görüntüler aynı çözünürlükte) kullanıldığı için doğrudan ortak çözünürlük değeri kullanılabilirdi ancak birden fazla verisetinden görüntüler alındığı durumda veya aynı verisetinde ama farklı çözünürlük değerlerine sahip görüntüler kullanıldığında bunların aynı boyuta getirilmesi gerekmektedir. Ayrıca ön-eğitilmiş ağların önceden eğitildiği veri setlerinde kullanılan görüntü çözünürlükleri de oldukça önem arz etmektedir. Ön-eğitilmiş ağlardan daha efektif bir şekilde yararlanabilmek için bu değerlerin de göz önünde bulundurulması gerekmektedir. Model eğitiminin çok uzun süreler almaması için merkezi işlem birimi (CPU) veya grafik işlem

birimi (GPU) güçlü olan bir bilgisayarın (tercihen GPU'su güçlü bir bilgisayarın daha faydalı olacağı önerilmektedir) kullanılması önerilmektedir. Ayrıca yüksek kapasiteye sahip bellekler (RAM) kullanılması da bellekte tutulacak parametreler açısından fayda sağlayacaktır. Yapılan bu çalışma da özellikle 40 epok değerine kadar bir eğitim yapılmıştır. Yapılan analizler sonuçların stabil ve standart bir hale gelmesi için en uygun değerin 40 olduğunu göstermiştir.

Gelecekteki çalışmalar için doğruluk değerini artırmaya yönelik daha geniş ve derin bir veriseti kullanılması amaçlanmaktadır. Verisetindeki görüntü sayısının artırılmayacağı durumlarda ise farklı veri setleri birleştirilerek pek çok farklı görüntünün bulunduğu bir karma veriseti oluşturulması düşünülmektedir. Böyle bir çalışma hem literatüre katkı sağlayacak hem de karma olmasından ötürü ağı tahmin yeteneğini geliştirecektir. Bunun yanı sıra geliştirilen yeni ön-eğitilmiş ağların takibi yapılacak ve sonuca ulaşım mantıkları sürekli göz önünde bulundurulacaktır. Yapılan diğer çalışmalardaki ve özgün veri setleri insanların kullanımına açılırsa onlarla karşılaştırmak ve yapılacak çalışmalarda kullanılması oldukça fayda sağlayacaktır. Bunun yanında donanımsal gelişmelerde makine öğrenmesi, görüntü işleme ve derin öğrenme gibi konularda oldukça önem arz ettiğinden bu alandaki gelişmeler de takip edilecektir. Yüksek bir donanım geliştirmesi ekran kartlarının ve işlemcilerin yüksek hızlara ulaşması bu alanın geleceğini çok olumlu yönde etkileyecek, sürelerin kısaltılmasına vesile olacaktır. Ayrıca bellek teknolojisinin geliştirilmesi hafıza da daha fazla parametre tutulmasını sağlayacak ve sadece yüksek seviyeli bilgisayarlarda değil standart bilgisayarlarda da kolaylıkla derin öğrenmenin efektif olarak kullanılabilmesini sağlayacaktır. Kişisel verilerin kullanımı tabii ki çok dikkat edilmesi gereken bir konudur; fakat bazı durumlarda bunun tıbbi ve insanlık yararına olacağı durumlar için bir nebze hafifletilmesi belki de bu alan için çok daha farklı çalışmalar ortaya koyabilir.

Kullanılan yapı ve mimari sonuçları oldukça umut vaat etmektedir. Derin öğrenme ve ön-eğitilmiş ağlar vasıtasıyla yapılan sınıflandırmanın doğrudan bir meme kanseri tespit yöntemi olarak kullanılması için henüz erkendir. Buna karşın bu tezin de amacı olan doktorlara yardımcı bir destek rolü üstlenmesi için sonuçların oldukça yeterli olduğu aşîkârdır. Özellikle Xception ağı veri artırma, bırakma, yığın normalizasyonu ve test zamanı artırması gibi desteklemeler ile normal başarımının dahi oldukça üzerine çıkmaktadır. Ayrıca pek çok durum için ortalamanın çok üzerinde bir başarı elde etmesi, doğruluk ve F1 Skor fark etmeksizin yeterli bir başarıyı ortaya koyması ve diğer ağlara karşı üstünlüğünü göstermesi sebebiyle meme kanseri sınıflandırması için göz önünde bulundurulması gereken en önemli ön-eğitilmiş ağlardan birisi olduğunu kanıtlamıştır.

KAYNAKÇA

- Abdel-Zaher, A. M., & Eldeib, A. M.** (2016). Breast cancer classification using deep belief networks. *Expert Systems with Applications*, 46, 139-144.
- Adeshina, S. A., Adedigba, A. P., Adeniyi, A. A., & Aibinu, A. M.** (2018). *Breast cancer histopathology image classification with deep convolutional neural networks*. Paper presented at the 2018 14th International Conference on Electronics Computer and Computation (ICECCO)206-212.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., . . . Asari, V. K.** (2018). The history began from alexnet: A comprehensive survey on deep learning approaches. *arXiv preprint arXiv:1803.01164*, 1-39.
- Aloyayri, A.** (2020). *Breast Cancer Classification from Histopathological Images Using Transfer Learning and Deep Neural Networks*. Concordia University. 1-77)
- Azar, A. T., & El-Said, S. A.** (2013). Probabilistic neural network for breast cancer classification. *Neural Computing and Applications*, 23(6), 1737-1751.
- Bayramoglu, N., Kannala, J., & Heikkilä, J.** (2016). *Deep learning for magnification independent breast cancer histopathology image classification*. Paper presented at the 2016 23rd International conference on pattern recognition (ICPR)2440-2445.
- Behera, B., & Kumaravelan, G.** (2019). *Performance Evaluation of Deep Learning Algorithms in Biomedical Document Classification*. Paper presented at the 2019 11th International Conference on Advanced Computing (ICoAC)220-224.
- Bjorck, N., Gomes, C. P., Selman, B., & Weinberger, K. Q.** (2018). *Understanding batch normalization*. Paper presented at the Advances in Neural Information Processing Systems7694-7705.
- Bottou, L.** (2012). Stochastic gradient descent tricks *Neural networks: Tricks of the trade* (pp. 421-436): Springer421-436.
- Bradley, A. P.** (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern recognition*, 30(7), 1145-1159.

- Burcak, K. C., Baykan, Ö. K., & Uğuz, H.** (2020). A new deep convolutional neural network model for classifying breast cancer histopathological images and the hyperparameter optimisation of the proposed model. *JOURNAL OF SUPERCOMPUTING*, 1-17.
- Celik, Y., Talo, M., Yildirim, O., Karabatak, M., & Acharya, U. R.** (2020). Automated invasive ductal carcinoma detection based using deep transfer learning with whole-slide images. *Pattern recognition letters*, 232-239.
- Chan, A., & Tuszynski, J. A.** (2016). Automatic prediction of tumour malignancy in breast cancer with fractal dimension. *Royal Society open science*, 3(12), 1-10.
- Charan, S., Khan, M. J., & Khurshid, K.** (2018). *Breast cancer detection in mammograms using convolutional neural network*. Paper presented at the 2018 International Conference on Computing, Mathematics and Engineering Technologies (iCoMET)1-5.
- Chaves, E., Gonçalves, C. B., Albertini, M. K., Lee, S., Jeon, G., & Fernandes, H. C.** (2020). Evaluation of transfer learning of pre-trained CNNs applied to breast cancer detection on infrared images. *Applied Optics*, 59(17), E23-E28.
- Chollet, F.** (2017). *Xception: Deep learning with depthwise separable convolutions*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition1251-1258.
- Chowkkar, M.** (2020). *Breast Cancer Detection from Histopathological Images using Deep Learning and Transfer Learning*. Dublin, National College of Ireland. 1-23)
- DeSantis, C. E., Ma, J., Gaudet, M. M., Newman, L. A., Miller, K. D., Goding Sauer, A., . . . Siegel, R. L.** (2019). Breast cancer statistics, 2019. *CA: a cancer journal for clinicians*, 69(6), 438-451.
- Dimitropoulos, K., Barmpoutis, P., Zioga, C., Kamas, A., Patsiaoura, K., & Grammalidis, N.** (2017). Grading of invasive breast carcinoma through Grassmannian VLAD encoding. *PloS one*, 12(9), 1-18.
- Dogan, B. E., Gonzalez-Angulo, A. M., Gilcrease, M., Dryden, M. J., & Yang, W. T.** (2010). Multimodality imaging of triple receptor-negative tumors with mammography, ultrasound, and MRI. *American Journal of Roentgenology*, 194(4), 1160-1166.

Erhan, D., Manzagol, P.-A., Bengio, Y., Bengio, S., & Vincent, P. (2009). *The difficulty of training deep architectures and the effect of unsupervised pre-training*. Paper presented at the Artificial Intelligence and Statistics 153-160.

Ertam, F., & Aydın, G. (2017). *Data classification with deep learning using Tensorflow*. Paper presented at the 2017 international conference on computer science and engineering (UBMK) 755-758.

Ferreira, C. A., Melo, T., Sousa, P., Meyer, M. I., Shakibapour, E., Costa, P., & Campilho, A. (2018). *Classification of breast cancer histology images through transfer learning using a pre-trained inception resnet v2*. Paper presented at the International Conference Image Analysis and Recognition 763-770.

Fukushima, K. (1988). Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural networks, 1*(2), 119-130.

Gour, M., Jain, S., & Sunil Kumar, T. (2020). Residual learning based CNN for breast cancer histopathological image classification. *International Journal of Imaging Systems and Technology*, 1-15.

Goutte, C., & Gaussier, E. (2005). *A probabilistic interpretation of precision, recall and F-score, with implication for evaluation*. Paper presented at the European Conference on Information Retrieval 345-359.

Hajian-Tilaki, K. (2013). Receiver operating characteristic (ROC) curve analysis for medical diagnostic test evaluation. *Caspian journal of internal medicine, 4*(2), 627-635.

Hamed, G., Marey, M. A. E.-R., Amin, S. E.-S., & Tolba, M. F. (2020). *Deep Learning in Breast Cancer Detection and Classification*. Paper presented at the Joint European-US Workshop on Applications of Invariance in Computer Vision 322-333.

Han, Z., Wei, B., Zheng, Y., Yin, Y., Li, K., & Li, S. (2017). Breast cancer multi-classification from histopathological images with structured deep learning model. *Scientific reports, 7*(1), 1-10.

Hashemi, M. (2019). Enlarging smaller images before inputting into convolutional neural network: zero-padding vs. interpolation. *Journal of Big Data, 6*(1), 1-13.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition 770-778.

Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). *Densely connected convolutional networks*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition 4700-4708.

Huang, J., & Ling, C. X. (2005). Using AUC and accuracy in evaluating learning algorithms. *IEEE Transactions on knowledge and Data Engineering*, 17(3), 299-310.

Ide, H., & Kurita, T. (2017). *Improvement of learning for CNN with ReLU activation by sparse regularization*. Paper presented at the 2017 International Joint Conference on Neural Networks (IJCNN) 2684-2691.

Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*, 1-11.

Kalchbrenner, N., Grefenstette, E., & Blunsom, P. (2014). A convolutional neural network for modelling sentences. *arXiv preprint arXiv:1404.2188*, 1-45.

Kang, L., Ye, P., Li, Y., & Doermann, D. (2014). *A deep learning approach to document image quality assessment*. Paper presented at the 2014 IEEE International Conference on Image Processing (ICIP) 2570-2574.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). *Imagenet classification with deep convolutional neural networks*. Paper presented at the Advances in neural information processing systems 1097-1105.

Kumar, A., Singh, S. K., Saxena, S., Lakshmanan, K., Sangaiah, A. K., Chauhan, H., . . . Singh, R. K. (2020). Deep feature learning for histopathological image classification of canine mammary tumors and human breast cancer. *Information Sciences*, 508, 405-421.

LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.

Lin, M., Chen, Q., & Yan, S. (2013). Network in network. *arXiv preprint arXiv:1312.4400*, 1-10.

Ling, C. X., Huang, J., & Zhang, H. (2003). *AUC: a better measure than accuracy in comparing learning algorithms*. Paper presented at the Conference of the canadian society for computational studies of intelligence 329-341.

Liu, K., Kang, G., Zhang, N., & Hou, B. (2018). Breast cancer classification based on fully-connected layer first convolutional neural networks. *IEEE Access*, 6, 1-12.

Ma, W., & Lu, J. (2017). An equivalence of fully connected layer and convolutional layer. *arXiv preprint arXiv:1712.01252*, 1-9.

Mehra, R. (2018). Breast cancer histology images classification: Training from scratch or transfer learning? *ICT Express*, 4(4), 247-254.

Mohammed, M. A., Al-Khateeb, B., Rashid, A. N., Ibrahim, D. A., Ghani, M. K. A., & Mostafa, S. A. (2018). Neural network and multi-fractal dimension features for breast cancer classification from ultrasound images. *Computers & Electrical Engineering*, 70, 871-882.

Moshkov, N., Mathe, B., Kertesz-Farkas, A., Hollandi, R., & Horvath, P. (2020). Test-time augmentation for deep learning-based cell segmentation on microscopy images. *Scientific reports*, 10(1), 1-7.

Nahid, A.-A., Mehrabi, M. A., & Kong, Y. (2018a). Histopathological breast cancer image classification by deep neural network techniques guided by local clustering. *BioMed research international*, 2018, 1-20.

Nahid, A.-A., Mehrabi, M. A., & Kong, Y. (2018b). Histopathological breast cancer image classification by deep neural network techniques guided by local clustering. *BioMed research international*, 2018, 1-21.

National Breast Cancer Foundation, I. (2019). (Erişim: 21.08.2020, <https://www.nationalbreastcancer.org/breast-cancer-diagnosis/>). 1.

Özkan, İ., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.

Öztürk, Ş., & Akdemir, B. (2019). HIC-net: A deep convolutional neural network model for classification of histopathological breast images. *Computers & Electrical Engineering*, 76, 299-310.

- Paasio, A., & Dawidziuk, A.** (1999). CNN template robustness with different output nonlinearities. *International Journal of Circuit Theory and Applications*, 27(1), 87-102.
- Perez, L., & Wang, J.** (2017). The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*, 1-8.
- Powers, D. M.** (2011). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation.
- Powers, D. M.** (2015). What the F-measure doesn't measure: Features, Flaws, Fallacies and Fixes. *arXiv preprint arXiv:1503.06410*, 1-19.
- Qi, X., Wang, T., & Liu, J.** (2017). *Comparison of support vector machine and softmax classifiers in computer vision*. Paper presented at the 2017 Second International Conference on Mechanical, Control and Computer Engineering (ICMCCE)151-155.
- Rakhlin, A., Shvets, A., Iglovikov, V., & Kalinin, A. A.** (2018). *Deep convolutional neural networks for breast cancer histology image analysis*. Paper presented at the International Conference Image Analysis and Recognition737-744.
- Rawat, W., & Wang, Z.** (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, 29(9), 2352-2449.
- Robbin, S., Cotran, R., Kumar, V., & Collins, T.** (1999). Pathological basis of disease (pp. 4-5): Har Cocert Asia: Saunders Company.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J.** (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- 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), 1-21.
- Siegel, R. L., Miller, K. D., & Jemal, A.** (2015). Cancer statistics, 2015. *CA: a cancer journal for clinicians*, 65(1), 5-29.
- Siegel, R. L., Miller, K. D., & Jemal, A.** (2019). Cancer statistics, 2019. *CA: a cancer journal for clinicians*, 69(1), 7-34.

Spanhol, F. A., Oliveira, L. S., Cavalin, P. R., Petitjean, C., & Heutte, L. (2017). *Deep features for breast cancer histopathological image classification*. Paper presented at the 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)1868-1873.

Spanhol, F. A., Oliveira, L. S., Petitjean, C., & Heutte, L. (2015). A dataset for breast cancer histopathological image classification. *IEEE Transactions on Biomedical Engineering*, 63(7), 1-8.

Spanhol, F. A., Oliveira, L. S., Petitjean, C., & Heutte, L. (2016). *Breast cancer histopathological image classification using convolutional neural networks*. Paper presented at the 2016 international joint conference on neural networks (IJCNN)2560-2567.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.

Sudharshan, P., Petitjean, C., Spanhol, F., Oliveira, L. E., Heutte, L., & Honeine, P. (2019). Multiple instance learning for histopathological breast cancer image classification. *Expert Systems with Applications*, 117, 103-111.

Sun, M., Song, Z., Jiang, X., Pan, J., & Pang, Y. (2017). Learning pooling for convolutional neural network. *Neurocomputing*, 224, 96-104.

Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. (2017). *Inception-v4, inception-resnet and the impact of residual connections on learning*. Paper presented at the Thirty-first AAAI conference on artificial intelligence1-12.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015). *Going deeper with convolutions*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition1-9.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). *Rethinking the inception architecture for computer vision*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition2818-2826.

- Tai, Y., Yang, J., & Liu, X.** (2017). *Image super-resolution via deep recursive residual network*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition 3147-3155.
- Talo, M.** Meme Kanseri Histopatolojik Görüntülerinin Konvolüsyonel Sinir Ağları ile Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(2), 391-398.
- Taylor, L., & Nitschke, G.** (2017). Improving deep learning using generic data augmentation. *arXiv preprint arXiv:1708.06020*, 1-6.
- Toğaçar, M., Özkurt, K. B., Ergen, B., & Cömert, Z.** (2020). BreastNet: A novel convolutional neural network model through histopathological images for the diagnosis of breast cancer. *Physica A: Statistical Mechanics and its Applications*, 545, 1-33.
- Tolias, G., Sicre, R., & Jégou, H.** (2015). Particular object retrieval with integral max-pooling of CNN activations. *arXiv preprint arXiv:1511.05879*, 1-12.
- Vani, S., & Rao, T. M.** (2019). *An Experimental Approach towards the Performance Assessment of Various Optimizers on Convolutional Neural Network*. Paper presented at the 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI) 331-336.
- Velasco, J. S., Cabatuan, M. K., & Dadios, E. P.** Urine Sediment Classification Using Deep Learning. 180-185.
- Vesal, S., Ravikumar, N., Davari, A., Ellmann, S., & Maier, A.** (2018). *Classification of breast cancer histology images using transfer learning*. Paper presented at the International conference image analysis and recognition 812-819.
- Wang, D., Khosla, A., Gargeya, R., Irshad, H., & Beck, A. H.** (2016). Deep learning for identifying metastatic breast cancer. *arXiv preprint arXiv:1606.05718*, 1-6.
- Wei, B., Han, Z., He, X., & Yin, Y.** (2017). *Deep learning model based breast cancer histopathological image classification*. Paper presented at the 2017 IEEE 2nd international conference on cloud computing and big data analysis (ICCCBDA) 348-353.
- Wenzhong, L., Huanlan, L., Caijian, H., & Liangjun, Z.** (2020). Classifications of Breast Cancer Images by Deep Learning. *medRxiv*, 1-13.

Xiao, H., Rasul, K., & Vollgraf, R. (2017). Fashion-mnist: a novel image dataset for benchmarking machine learning algorithms. *arXiv preprint arXiv:1708.07747*, 1-6.

Yu, D., & Deng, L. (2012). Efficient and effective algorithms for training single-hidden-layer neural networks. *Pattern recognition letters*, 33(5), 554-558.

TEZDEN YAPILAN YAYINLAR VE KONFERANSLAR

DANDIL, E., & Serin, Z. (2020). Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*(Ejosat Özel Sayı 2020 (HORA)), 451-463. (*Tam metin*)

DANDIL, E., & Serin, Z. (2020). *Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti*. Paper presented at the 2nd International Congress on Human-Computer Interaction, Optimization and Robotic Applications, June 26-27, Ankara, Turkey (Online). (*Özet metin*)

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Zafer SERİN
Doğum Yeri ve Tarihi : Konya/İlgın 30.08.1995



Eğitim Durumu

Lisans Öğrenimi : BŞEÜ Bilgisayar Mühendisliği Bölümü
Bildiği Yabancı Diller : İngilizce (Orta)
Bilimsel Faaliyetleri :

İş Deneyimi

Stajlar : BŞEÜ Bilgi İşlem Daire Başkanlığı
Projeler :
Çalıştığı Kurumlar : Devlet Su İşleri

İletişim

Adres : Pelitözü Mah. Cumhuriyet 3 Sk. No:13/1 Merkez/BİLECİK
E-Posta Adresi : zafer.serinn@gmail.com

Akademik Çalışmaları

Yıldız, M., Çubukçu, B., Serin, Z., & Yüzgeç, U. (2018). *Leap Motion Based Physical Therapy Application for Stroke Patients*. Paper presented at the 2018 3rd International Conference on Computer Science and Engineering (UBMK)190-194.

Garip, B., Çubukçu, B., Serin, Z., & Yüzgeç, U. (2019). *Kinect based Office Exercises: BreakOut*. Paper presented at the 2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)1-5.

DANDIL, E., & Serin, Z. (2020). *Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti*. *Avrupa Bilim ve Teknoloji Dergisi* (Ejosat Özel Sayı 2020 (HORA)), 451-463. (Tam metin)

DANDIL, E., & Serin, Z. (2020). *Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti*. Paper presented at the 2nd International Congress on Human-Computer Interaction, Optimization and Robotic Applications, June 26-27, Ankara, Turkey. (Özet metin)

Tarih: 3.9.2020