
GAZİ ÜNİVERSİTESİ
Gazi
1926

GÜÇLENDİRİLMİŞ EVRİŞİMLİ SİNİR AĞI İLE TIBBİ GÖRÜNTÜLERİN SINIFLANDIRILMASI

Halise Nur AYDIN

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OCAK 2024

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Halise Nur AYDIN

03/01/2024

GÜÇLENDİRİLMİŞ EVRİŞİMLİ SİNİR AĞI İLE TIBBİ GÖRÜNTÜLERİN SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Halise Nur AYDIN

GAZİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2024

ÖZET

Vücut içindeki anatomik yapıları ve organları incelemek için tıbbi görüntüleme teknikleri yaygın olarak kullanılır. Tıbbi görüntüleme teknikleri, hastalıkların erken teşhis edilmesini sağlayarak hastalığın ilerlemesini engellemekte, hekimlere teşhis konusunda yardımcı olmakta, tedaviye hızlı bir başlangıç yapılmasını sağlamakta ve tedavi sürecinin izlenmesini kolaylaştırmaktadır. Bununla birlikte bilgisayar destekli tanı sistemleri hekimlere yardımcı olurken, bu tür sistemlerde özellikle derin öğrenme modelleri gibi yapay zeka yöntemleri önemli bir rol oynamaktadır. Bu modeller, karmaşık bir yapıya sahip olabilirler, bunun yanı sıra zaman ve maliyet açısından sorunlar yaratabilirler. Bu tez çalışması kapsamında tıbbi görüntülerin sınıflandırılması için karmaşıklığı arttırmadan yüksek doğruluk sağlayan etkin bir model önerilmektedir. Önerilen model ile literatürdeki çalışmalardan daha yüksek doğruluk elde edilmesi amaçlanmış, sunulan modelde Inception bloğu ile özellik çıkarılması; ECA bloğu ile daha önemli olabilecek özelliklere odaklanılması; ASPP bloğu ile de bilgilendirici bağlam bilgisine sahip özellikler elde edilmesi amaçlanmıştır. Önerilen model beyin, böbrek, meme kanseri veri kümeleri üzerinde eğitilmiş ve test işlemleri gerçekleştirilmiştir. Beyin tümörünün sınıflandırılması için BT-large-4C veri kümesi ve Figshare veri kümesi; böbreklerde taş, kist, tümör ve normal etiketine sahip görüntülerin sınıflandırılması için BT Kidney veri kümesi; meme kanseri tümörünün sınıflandırılması için BreaKHis veri kümesi kullanılmıştır. Elde edilen sonuçlar literatürde var olan yöntemlerle karşılaştırılmış, geliştirilen modelin beyin ve böbrek veri kümelerinde daha başarılı sınıflandırma yaptığı gözlemlenmiştir. Gerçekleştirilen deneysel çalışmalarda önerilen model dört veri kümesi üzerinde eğitilmiş ve test edilmiştir. Buna göre elde edilen doğruluk değerleri BT-large-4C veri kümesi için %98,05; Figshare veri kümesi için %99,84; BT Kidney veri kümesi için %99,5; BreaKHis veri kümesi için de %96,98'dir.

Bilim Kodu	:	92432
Anahtar Kelimeler	:	Evrişimli sinir ağları, sınıflandırma, beyin tümörü, böbrek hastalığı, meme kanseri, ECA, ASPP, Inception
Sayfa Adedi	:	69
Danışman	:	Doç. Dr. Oktay YILDIZ

CLASSIFICATION OF MEDICAL IMAGES WITH ENHANCED CONVOLUTIONAL NEURAL NETWORK

(M. Sc. Thesis)

Halise Nur AYDIN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2024

ABSTRACT

Medical imaging techniques are frequently employed to examine anatomical structures and internal organs. Medical imaging techniques prevent disease progression by providing early diagnosis of diseases, assisting physicians in diagnosis, accelerating treatment commencement, and facilitating monitoring of the treatment process. Moreover, computer-aided diagnosis systems support medical physicians, with artificial intelligence methodologies, particularly deep learning models, playing an essential role in such systems. These models often possess intricate architectures, potentially posing challenges concerning time and cost constraints. Within the scope of this thesis, a practical model that provides high accuracy without increasing complexity is proposed for the classification of medical images. The proposed model is aimed to obtain higher accuracy than the studies in the literature. In the presented model, feature extraction is done with the Inception Block; focusing on features that may be more important with the ECA Block; the ASPP Block aims to obtain features with informative context information. The proposed model was trained and tested on brain, kidney, and breast cancer datasets. BT-large-4C dataset and Figshare dataset for brain tumor classification; CT Kidney dataset for classification of images labeled stone, cyst, tumor, and normal; BreaKHis dataset was used for breast cancer tumor classification. The results obtained were compared with existing methods in the literature, and it was observed that the developed model performed more successful classification in brain and kidney datasets. The proposed model was trained and tested on four datasets in the experimental studies that were carried out. Accordingly, the accuracy values obtained are 98.05% for the BT-large-4C dataset; 99.84% for the Figshare dataset; 99.05% for the BT Kidney dataset; and 96.98% for the BreaKHis dataset.

Science Code	:	92432
Key Words	:	Convolutional neural networks, classification, brain tumor, kidney disease, breast cancer, ECA, ASPP, Inception
Page Number	:	69
Supervisor	:	Assist. Prof. Dr. Oktay YILDIZ

TEŞEKKÜR

Eğitimim boyunca bilgi ve birikimleriyle bana ışık tutan, zorlandığımda beni teşvik edip desteğini esirgemeyen değerli danışman hocam Doç. Dr. Oktay YILDIZ'a teşekkürlerimi sunarım.

Yüksek lisansa başladığım andan itibaren yanımda olan, başarılı bir şekilde eğitimimi tamamlamam için her türlü imkânı sunan sevgili aileme teşekkür ediyorum.

İÇİNDEKİLER

Sayfa

ÖZET iv

ABSTRACT v

TEŞEKKÜR vi

İÇİNDEKİLER vii

ÇİZELGELERİN LİSTESİ ix

ŞEKİLLERİN LİSTESİ x

RESİMLERİN LİSTESİ xii

SİMGELER VE KISALTMALAR xiii

1. GİRİŞ 1

2. TEORİK ARKAPLAN 15

2.1. Tıbbi Görüntüleme Yöntemleri 15

2.2. Görüntü Sınıflandırma 16

2.3. Derin Öğrenme Modelleri ile Görüntü Sınıflandırma 22

2.4. Tıbbi Görüntüler için Optimize Edilmiş Sinir Ağı 32

2.4.1. Inception bloğu 33

2.4.2. ECA bloğu 34

2.4.3. Atrous uzamsal piramit ortaklama (ASPP) bloğu 35

3. DENEYSEL ÇALIŞMA VE SONUÇLAR 37

3.1. Deneysel Çalışma 37

3.1.1. Veri kümeleri 38

3.1.2. Değerlendirme metrikleri 41

3.2. Deneysel Sonuçlar 45

Sayfa

4. SONUÇ VE DEĞERLENDİRME 55

KAYNAKLAR 61

ÖZGEÇMİŞ 69

ÇİZELGELERİN LİSTESİ

Çizelge **Sayfa**

Çizelge 3.1. Çalışmada kullanılan hiperparametre bilgileri…… 37

Çizelge 3.2. Karmaşıklık matrisi..... 42

Çizelge 3.3. Figshare veri kümesi üzerinde yapılan ablasyon çalışmasıyla blokların verimliliğinin karşılaştırılması..... 52

Çizelge 3.4. BT-large-4C veri kümesi üzerinde yapılan ablasyon çalışmasıyla blokların verimliliğinin karşılaştırılması..... 53

Çizelge 3.5. BT Kidney veri kümesi üzerinde yapılan ablasyon çalışmasıyla blokların verimliliğinin karşılaştırılması..... 53

Çizelge 3.6. BreaKHis veri kümesi üzerinde yapılan ablasyon çalışmasıyla bloklarınverimliliğinin karşılaştırılması..... 54

Çizelge 4.1. Figshare veri kümesini kullanan çalışmalar ile geliştirilen modelin karşılaştırılması..... 56

Çizelge 4.2. BT-large-4C veri kümesini kullanan çalışmalar ile geliştirilen modelin karşılaştırılması..... 57

Çizelge 4.3. BT Kidney veri kümesini kullanan çalışmalar ile geliştirilen modelin karşılaştırılması……. 58

Çizelge 4.4. BreaKHis veri kümesini kullanan çalışmalar ile geliştirilen modelin karşılaştırılması..... 59

ŞEKİLLERİN LİSTESİ

Şekil **Sayfa**

Şekil 2.1. Temel bir YSA modeli…….. 17

Şekil 2.2. Temel bir DSA modeli..... 18

Şekil 2.3. İlk katmanlardan son katmana doğru çıkarılan özellikler..... 19

Şekil 2.4. Kaydırma adımının (s=1) gösterilmesi 19

Şekil 2.5. Piksel ekleme işlemi olmadan görüntü üzerine uygulanan filtre işlemi 20

Şekil 2.6. Piksel ekleme işlemi yapılarak görüntü üzerine uygulanan filtre işlemi..... 21

Şekil 2.7. Ortalama ortaklama ve maksimum ortaklama..... 22

Şekil 2.8. GoogleNet mimarisi..... 23

Şekil 2.9. Inception bloğu 24

Şekil 2.10. SENet'in genel yapısı 24

Şekil 2.11. Soldaki normal evrişim sağdaki genişleyen evrişim (genişleme oranı:2) 26

Şekil 2.12. ASPP bloğu..... 27

Şekil 2.13. ReLU aktivasyon fonksiyonu 30

Şekil 2.14. Softmax aktivasyon fonksiyonu 31

Şekil 2.15. Sigmoid aktivasyon fonksiyonu 32

Şekil 2.16. Geliştirilen modelin genel yapısı 33

Şekil 2.17. Inception bloğu 34

Şekil 2.18. ECA bloğu 35

Şekil 2.19. ASPP bloğu..... 36

Şekil 3.1. K-kat çapraz doğrulama..... 44

Şekil 3.2. ROC-AUC eğrisi 45

Şekil 3.3. Figshare veri kümesinin karmaşıklık matrisi..... 46

Şekil 3.4. Figshare veri kümesinin kayıp grafiği 47

Şekil **Sayfa**

Şekil 3.5. BT-large-4C veri kümesinin karmaşıklık matrisi 48

Şekil 3.6. BT-large-4C veri kümesinin kayıp grafiği 48

Şekil 3.7. BT Kidney veri kümesinin karmaşıklık matrisi..... 49

Şekil 3.8. BT Kidney veri kümesinin kayıp grafiği 50

Şekil 3.9. BreaKHis veri kümesinin karmaşıklık matrisi 51

Şekil 3.10. BreaKHis veri kümesinin kayıp grafiği..... 51

RESİMLERİN LİSTESİ

Resim **Sayfa**

Resim 3.1. Figshare veri kümesi sırasıyla gliom, meningiom ve hipofiz 38

Resim 3.2. BTlarge-4C veri kümesi sırasıyla gliom, meningiom, hipofiz ve normal..... 39

Resim 3.3. BT Kidney veri kümesi. Satır 1 “normal”, 2 “tümör”, 3 “kist”, 4 “taş”..... 40

Resim 3.4. BreaKHis veri kümesi soldaki kötü huylu, sağdaki iyi huylu meme tümörü……..... 41

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
AUC	Area Under the Curve
ASPC	Atrous Uzamsal Piramit Evrişim
ASPP	Atrous Uzamsal Piramit Ortaklama
BT	Bilgisayarlı Tomografi
CNN	Evrişimli Sinir Ağları
DN	Doğru Negatif
DP	Doğru Pozitif
DSA	Derin Sinir Ağları
ECA	Efficient Channel Attention
FPR	Yanlış Pozitif Oranı
ILSVRC	ImageNet Large-Scale Visual Recognition
KNN	K-en Yakın Komşu
LDA	Doğrusal Ayırıcı Analiz
MLP	Çok Katmanlı Algılayıcı
MR	Manyetik Rezonans Görüntüleme
RCNN	Yinelemeli Evrişimli Sinir Ağları
ReLU	Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
RMSProp	Root Mean Square Propagation
ROC	Receiver Operating Characteristic
SENet	Sıkıştır-Genişlet Ağları (Squeeze-Excitation Network)
SGD	Stokastik Gradyan İniş
SPP	Uzamsal Piramit Ortaklama
SVM	Destek Vektör Makineleri
TPR	Gerçek Pozitif Oranı
YN	Yanlış Negatif
YP	Yanlış Pozitif
YSA	Yapay Sinir Ağları

1. GİRİŞ

Tıbbi görüntü, vücut içindeki organların ve anatomik yapının Ultrason, Bilgisayarlı Tomografi (BT), Manyetik Rezonans Görüntüleme (MR) gibi çeşitli görüntüleme cihazları kullanılarak elde edilmesidir. Bu cihazlar ile dokulara ve hücrelere zarar vermeden görüntüler oluşturulur. Tıbbi görüntülerin analizinin tarihsel süreci 1800'lü yıllarda atomun yapısının incelenmesiyle başlamıştır. Fotoğrafın icadıyla başlayan süreç röntgenin icadıyla devam etmiştir ve günümüzde de bu cihazların gelişmesi devam etmektedir. 1895 yılında Wilhelm Conrad Roentgen tarafından X-ışını radyasyonunun keşfedilmesinden günümüze tıbbi görüntüleme teknikleri bilimsel bir disiplin haline gelmiştir. 1957 yılında Ian Donald tarafından ultrason geliştirilmiştir. 1972 yılında Godfrey Newbold Hounsfield tarafından BT geliştirilmiştir. MR ise 1971 yılında Paul C. Lauterbur tarafından icat edilmiştir.

Tıbbi görüntülerde tümörün tespit edilmesi için hastanın tıbbi öyküsünün ve muayenenin dışında tıbbi görüntüleme cihazları da yaygın olarak kullanılmaktadır. Cihazlar incelenen bölgeye, hastanın durumuna ve semptomlara göre farklılık gösterebilmektedir. Hekimler tarafından en çok tercih edilen görüntüleme yöntemleri Ultrason, MR ve BT'dir [1].

Ultrason yüksek frekansta ses dalgalarının kullanılmasıyla oluşturulur ve insanların duyamayacağı frekans aralığındadır. İlk başlarda denizaltıların tespit edilmesi için kullanılırken tıbbi alanda da kullanılabileceğinin farkına varılmasıyla vücut içi yapıların görüntülenmesi için de kullanılmaya başlanmıştır. Ultrason genellikle organların görüntülenmesinde ve hamilelik döneminde bebeğin takibinde hekimler tarafından tercih edilmektedir.

MR güçlü manyetik alanların ve radyo dalgalarının kullanılmasıyla oluşturulur [2]. Radyo dalgaları hastanın vücuduna gönderildikten sonra farklı olan dokular farklı şekillerde yansır. Bu yansımalar bilgisayar ortamına taşınarak görüntü oluşturulur. Dokunun iç yapısının bilgisini elde edebilir ve tümörlerin konumunu, büyüklüğünü, çevresindeki dokularla olan ilişkisini belirleyebilir.

BT dijital bir x-ışını yöntemidir. Bu yöntemi kullanarak incelenen dokunun detaylı kesitsel görüntüleri oluşturulur [3]. Oluşan bu görüntüler bilgisayar ortamına taşınarak üç boyutlu

bir görüntüye dönüştürülür. Dokunun yoğunluğuna ve konumuna bakılarak farklı olan dokular tespit edilerek hastalık teşhis edilmeye çalışılır.

Tıbbi görüntüleme yöntemleri ile beyin, böbrek, meme, akciğer, karaciğer gibi vücuttaki tüm organlar görüntülenebilir. Bu görüntüleme yöntemleri sayesinde hastalığın tanı koyma süreci hızlanmış olur.

Beyin tümörü, beyindeki hücrelerin kontrolsüzce büyümesi ve çoğalması sonucu meydana gelmektedir ve hücrelerdeki DNA'nın değişiklik göstermesinden kaynaklanmaktadır. DNA'lar genellikle ebeveynlerden alınmış olsa da kişinin yaşamı boyunca bulunduğu çevrenin önemi daha büyüktür. Alınan kimyasallar sonucunda değişen gen değişikliğinde normal hücreler tümörlü hücrelere dönüşebilmektedir. Beyinde oluşan anormal hücrelerin hepsine kanser denilemediği için tümör denilmektedir. Amerikan Ulusal Beyin Tümörü Topluluğuna göre 120'den daha fazla türde beyin tümörü bulunmaktadır. Bu tümör türlerinin hepsi kötü huylu olarak sınıflandırılamaz. Beyinde meydana gelen tümörler iyi huylu olsa bile, yeri ve büyüklüğü açısından ciddi problemlere sebep olabilmektedir [4].

Beyin tümörlerinin birincil ve ikincil olarak iki tipi vardır [5]. Bunların ne anlama geldiğini ifade etmek gerekirse, birincil beyin tümörü beyindeki hücre ve yapılardan kaynaklanmaktadır. İkincil beyin tümörü ise vücudun herhangi bir bölgesinde başlayıp beyin dokularına kadar ulaşmasıdır. Bu durum metastaz olarak bilinmektedir. Birincil beyin tümörleri kendi içerisinde iyi huylu ve kötü huylu olarak ayrılmaktadır.

İyi huylu beyin tümörleri omuriliği ve beyni kaplayan zarlardan kaynaklanmaktadır. Daha yavaş büyürler, çevrelerine yayılma riski ve tekrar oluşma riskleri de düşüktür [6]. Ancak bu tümörler iyi huyluda olsa yaşam kalitesini düşürürler ve sağlık problemlerine de neden olabilirler.

Sinir hücrelerinde bölünme ve üreme olmadığı için kötü huylu beyin tümörleri, sinir hücrelerinin etrafındaki diğer hücrelerden kaynaklanır [7]. İyi huylu tümörünün aksine hızlı bir şekilde büyür ve çevresindeki dokulara da yayılım gösterir. Bu sebeple beyne baskı yaparak beynin yerine getirmesi gereken işlevleri yapmamasına engel olur.

Beyin tümörü denge sorunu, baş ağrısı, basınç hissi, mide bulantısı, nöbet geçirme, yüz felci, zihinsel yeteneklerde değişiklik vb. gibi semptomlar gösterebilir. Bu semptomlar hastadan hastaya değişebilmektedir. Diğer bir ifadeyle hastada bu semptomlar yerine başka belirtiler de olabilir ya da bu semptomların hepsi görülmeyebilir. Ayrıca bu semptomlar sadece tümörün özellikleri olmayıp birçok hastalığın habercisi de olabilir. Tümör bazen bu semptomlar ile kendini belli ederken bazen de tesadüf ile bulunabilir.

Beyin tümörü, dünya nüfusu yaşlandıkça daha sık görülmekte olup, nedeninin net bir açıklaması henüz bulunmamaktadır. Yapılan çalışmalar, dünya nüfusu yaşlandıkça beyin tümörlerinin görülme olasılığının arttığını gösterse de bu hastalık tüm yaş gruplarından herhangi birinde görülebilir. İlerleyen dönemlerde, toplumda beyin tümörlerinin sıklığının artacağı öngörülmektedir. Buna paralel olarak yapay zeka kullanımı da gittikçe artmaktadır. Yapay zekanın birçok alanda olduğu gibi sağlık alanında da kullanılmasıyla hastalıkların ortaya çıkma veya ilerleme oranını azaltabileceği günümüzdeki çalışmalara bakılarak bir fikir vermektedir.

Özellikle kadınlar arasında sıklıkla görülen ve ölüme neden olabilen diğer bir ciddi rahatsızlık da meme kanseridir. Meme tümörü en fazla tanı koyulan kanser türlerinden biridir [8]. Meme tümörü de beyin tümörü gibi hücrelerdeki kontrolsüz büyüme ve çoğalma sonucu meydana gelmektedir. Tümörün yeri, büyüklüğü gibi faktörler baz alındığında meme tümörünün dört farklı evresi vardır. Ayrıca bu dört evre kendi içerisinde alt evrelere ayrılır. Erken teşhis edilebilmesi için kişinin kendi kendisini elle muayene etmesi ve yılda bir kez hekim kontrolüne gitmesi önem arz etmektedir. Düzenli tarama yaptıran kişilerde meme tümöründen ölenlerin oranında yaklaşık olarak %20 azalma olduğu görülmüştür [9].

Meme tümörünün teşhis edilmesi için yapılan görüntülemelerde mamografi, ultrason, BT ve MR kullanılmaktadır. Ancak mamografi diğer görüntüleme yöntemlerine göre daha fazla tercih edilmektedir. MR genellikle meme tümörü olma riski yüksek olan kişilerde tercih edilmektedir. Bunun sebebi ise görüntü çözünürlüğünün iyi olması, iki memenin de aynı anda görüntülenip değerlendirilmesidir [10]. BT ise lenf düğümleri ilgili problemlerde tercih edilmektedir [11].

Toplumda sıklıkla görülen diğer bir hastalık da böbrek rahatsızlığıdır. Böbrekler vücuttaki en önemli işlevleri yapan organlardan birisidir. Böbreklerin temel işlevleri; kandaki atıkları,

toksinleri ve fazla suyu vücuttan uzaklaştırmak, hormon üretimini gerçekleştirmek, kan basıncı seviyesini, ph seviyesini, asit-baz seviyesini ve sıvı dengesini korumaktır. Kısacası insan vücudundaki homeostazın korunmasında çok önemli bir role sahiptir [12]. Böbrekler bu işlevleri yapabilmek için nefronlar adı verilen hücreleri kullanır. Her bir böbrekte yaklaşık bir milyon nefron adı verilen küçük hücre bulunmaktadır. Nefronlar hasar gördüğünde böbrekler gereken işlevleri yerine getiremeyeceği için böbrek hastalığı börek yetmezliğine dönüşecektir. Dolayısıyla vücut bu durumdan oldukça etkilenecektir. Hastalık böbrek yetmezliğine dönüştüğü için tedavi şansı da oldukça düşecektir. Diğer hastalıklarda olduğu gibi böbrek hastalığında da erken teşhis ve tedavi çok önemlidir. Ne kadar erken teşhis edilirse etkili tedavi olasılığı artacaktır. Ancak böbrek hastalığının erken teşhis edilmesi belirgin semptomlar göstermediği için zor olabilmektedir. İlerleyen aşamalarda idrarda değişiklik, kan basıncında yükselme, yorgunluk, halsizlik, uzuvlarda ödem, iştah azalması, bulantı, kusma ve deri değişiklikleri gibi semptomlarla kendini gösterebilmektedir. Bu semptomlar hastadan hastaya değişebilmektedir. Yani hastada bu semptomlar yerine başka belirtiler de olabilmekte ya da bu semptomların hepsinin görülmeme durumu da bulunmaktadır.

Böbrek hastalığının teşhis edilmesi için kan ve idrar gibi laboratuvar testleri kullanılmaktadır. Aynı zamanda böbrek hastalığının teşhisinde BT, ultrason, MR, radyografi gibi araçlar kullanılmaktadır. Bilgisayarlı tomografi dijital bir x-ışını yöntemidir. Genellikle böbrek taşlarını ve tümörlerini tespit etmek için kullanılmaktadır. BT kistik hastalıkların teşhis edilmesinde ultrasondan daha iyi sonuçlar vermektedir. BT kullanılmasının avantajları hassasiyet ve kesinlikte %100'e yakın sonuçlar vermesi, hızlı sonuç vermesi ve çoğu tıp merkezinde mevcut olmasıdır.

Tıbbi görüntüleme teknikleri kullanılarak elde edilen görüntülerin hekimler tarafından yapılan tanıda erken teşhis edilmesi hayati bir önem taşımaktadır. Erken teşhis edilmesi durumunda hastalığın ilerlemesini yavaşlatacak tedaviler uygulanabilmektedir. Hastalığın erken teşhis edilmesi, hastaların sosyal ve ekonomik yönden problemlerle karşılaşmaması, insan kaynaklı hataların önüne geçilmesi için yapay zeka temelli yöntemler günümüzde önem kazanmıştır. Bu yöntemler verileri analiz etmede, tespit etmede ve karar vermede başarılı bir rol üstlenmektedir.

Yapay zekanın alt dallarından biri olan derin öğrenme modelleriyle ilgili literatürde birçok çalışma mevcuttur. Literatürdeki çalışmalar sınıflandırma işleminde yüksek başarı elde etmiş olsa da bu başarı genellikle işlem süresini ve parametre sayısını arttırarak elde edilmiştir. Hesaplama karmaşıklığının ve zaman maliyetinin artması gerçek zamanlı uygulamalarda bir dezavantaj teşkil etmektedir. Bu sebeple tez kapsamında görüntülerin sınıflandırılmasında daha yüksek doğruluk sağlayacak güçlendirilmiş bir model önerilmiştir. Model farklı tıbbi görüntü veri kümeleri üzerinde test edilmiştir. Beyin ve böbrek veri kümelerinde literatürdeki çalışmalardan daha iyi sonuçlar verdiği gözlemlenmiştir. Meme veri kümesine bakıldığında bazı çalışmaların üzerinde bazı çalışmaların ise altında bir başarı elde edildiği görülmüştür. Modelde kullanılan Inception bloğu ile daha fazla özellik çıkarımı yaparak görüntülerin ayırt edici özellikleri elde edilmiştir. Inception bloğundaki maksimum ortaklama katmanını kaldırıp öğrenme işlemine devam etmesi için 1x1 evrişim katmanı kullanılmıştır. Verimli kanal dikkat bloğu özellik haritalarındaki önemli özellikleri ön plana çıkarmak için kullanılmıştır. ASPP bloğu ise yüksek ve düşük seviyeli bilgilerden daha fazla anlamsal bilgiler çıkarmak için kullanılmıştır.

Literatürde bilgisayar destekli tanı sistemleri üzerine yapılan teorik çalışmalar mevcuttur. Tıp, mühendislik, biyoloji gibi birçok alanda yaygın olarak kullanılmaktadır. Yapılan literatür taramasında öne çıkan çalışmalardan bazıları aşağıda özetlenmiştir.

Alzu'bi ve diğerleri tarafından yapılan çalışmada böbrek tümör türünün tespitinin tanımlanması amaçlanmıştır. Bu sebeple görüntülerden ve meta veriden oluşan yeni bir veri kümesi oluşturmuşlar ve ön işleme aşaması uygulamışlardır. Veri kümesi King Abdullah University hastanesinden toplanarak oluşturulmuştur. Modelin eğitilmesi ve test edilmesi için üç derin öğrenme modeli kullanılmış ve karşılaştırılmıştır. Çalışmada kullanılan modeller CNN-6, CNN-4, ResNet50 ve VGG16'dır. Modellerin doğruluk değerleri CNN-6 için %97, CNN-4 için %92, ResNet50 için %96, VGG-16 için %60 elde edilmiştir [13].

Kazemi ve Mirroshandel tarafından yapılan çalışmada böbrek taşının tespitini yapabilmek amacıyla topluluk öğrenmesi kullanılarak yeni bir yöntem önerilmiştir. Bireysel sınıflandırıcıları birleştirmek için genetik algoritma tabanlı yeni bir yöntem geliştirilmiştir. Bu yöntemde, her sınıflandırıcı için ağırlık ataması yapılmıştır. Bayes modeli, Karar Ağaçları, Yapay Sinir Ağları, K-en Yakın Komşu (KNN), Destek Vektör Makineleri (SVM), Çok Katmanlı Algılayıcı (MLP) gibi çeşitli makine öğrenmesi yöntemleri kullanılmış ve

karşılaştırılmıştır. Önerilen topluluk yönteminin diğer yöntemlere göre daha başarılı bir sonuç verdiği AUC değeri ile gözlemlenmiştir. AUC değeri 99,6 elde edilmiştir. Modelin eğitilmesi ve test edilmesi için kullanılan veri kümesi Razi hastanesinden toplanarak elde edilmiştir [14].

Aksakallı, Kaçdıoğlu ve Hanay tarafından yapılan çalışmada böbrek X-ray görüntülerinin sınıflandırılması için makine öğrenmesi yöntemleri ve derin öğrenme yöntemleri kullanılarak hangi yöntemin daha iyi sonuç verdiği değerlendirilmiştir. Yöntemlerin değerlendirilmesi için kullanılan veri kümesi Atatürk Üniversitesi Üroloji Departmanından elde edilmiştir ve veri kümesi sağlıklı/hasta olarak iki etikete sahip görüntülerden oluşturulmuştur. Veri kümesindeki görüntüler makine öğrenmesi ve derin öğrenme yöntemlerine verilmeden önce ön işleme adımından geçirilmiştir. Karar Ağaçları, Rastgele Orman, SVM, MLP, KNN, Bayes, CNN yöntemleri kullanılarak eğitilmiş ve test edilmiştir. Bu yöntemlerin arasından Karar Ağaçları %85,3 F1-skor, %78,4 kesinlik değerleri ile en başarılı yöntem olmuştur [15].

Sudharson ve Kokil tarafından yapılan çalışmada böbrek ultrason görüntülerinin sınıflandırılması için transfer öğrenme yöntemine dayalı olarak derin sinir ağları modeli önerilmiştir. Çalışmada üç değişken veri kümesi üzerinde özellik çıkarımı yapabilmek için önceden eğitilmiş derin sinir ağları modeli kullanılmıştır ve SVM kullanılarak sınıflandırılmıştır. ResNet101, ShuffleNet ve MobileNet-v2 gibi önceden eğitilmiş derin öğrenme modelleri birleştirilerek tahminler oluşturulmuştur. Bu tahminler çoğunluk oylama tekniği kullanılarak yapılmıştır. Geliştirilen bu model dört sınıfa ait böbrek ultrason görüntülerinden oluşan ve Chettinad Health City hastanesinden toplanan veri kümesi üzerinde test edilerek diğer modellerle karşılaştırılmıştır. Elde edilen sonuçlara göre önerilen modelin daha yüksek başarı gösterdiği gözlemlenmiştir. Elde edilen doğruluk değeri %95,58 bulunmuştur [16].

Narmada, Shekhar ve Singh tarafından yapılan çalışmada böbrek hastalığının sınıflandırılması için CNN modeli önerilmiştir. Önerilen model kendilerinin oluşturduğu az katmana sahip bir CNN modelidir. Model 12,510 görüntüden oluşmaktadır ve dört etikete sahiptir (kist, tümör, normal, taş). Model CT Kidney veri kümesi üzerinde eğitilmiş ve test edilmiştir. Elde edilen doğruluk değeri %99,36 bulunmuştur [17].

Swati ve diğerleri tarafından yapılan çalışmada beyin MRI görüntülerinin sınıflandırılması için transfer öğrenme ve hassas ayar yöntemleri kullanılmıştır. Çalışmada önceden eğitilmiş CNN mimarisi kullanılarak transfer öğrenmeye dayalı hassas ayar yapılmış ve CE-MRI veri seti üzerinde test edilmiştir. CE-MRI veri setinin boyutu küçük olduğu için ve CNN mimarileri büyük veri setleri üzerinde daha iyi başarı gösterdiği için önceden eğitilmiş CNN mimarisi kullanılarak performansın geliştirilmesi hedeflenmiştir. Kullanılan CNN mimarisi 19 katmana sahip olan VGG-19 modelidir. Bu çalışmada önerilen model veri seti üzerinde 5-kat çapraz doğrulama kullanılarak test edildiğinde ortalama doğruluğu %94,82 elde edilmiştir [18].

Wang, Li ve Huang tarafından yapılan çalışmada yeni bir tıbbi görüntü birleştirme algoritması önerilmiştir ve beyin MR görüntülerinde test edilmiştir. Bu önerilen algoritma üç kısımdan oluşmuştur. İlk kısım da üç katmanlı ayrıştırma modeli kullanılarak görüntüler doku, parlaklık gibi katmanlara ayrıştırılmıştır. İkinci kısımda kayan pencere ile elde edilen yamaların ağırlık haritaları oluşturulmuştur. Son kısımda ise tekrar haritalama yapma fonksiyonları ile son birleştirme görüntüsünü yeniden yapılandıran birleştirme katmanı geliştirilmiştir. Çalışmada MRI-PET, MRI-SPECT ve PC-GFP olmak üzere üç ana deneysel nesne vardır. MRI ve PC gri seviyeli görüntüler iken PET, SPECT ve GFP ise renkli görüntülerdir [19].

Kasinathan ve diğerleri tarafından yapılan çalışmada otomatik bir şekilde 3 boyutlu akciğer tümörünün tespit edilebilmesi ve sınıflandırılabilmesi için etkin bir kontür modeli önerilmiştir. Modelin amacı etkin kontür modeli ile yerel görüntü bias alanı formülasyonunu entegre etmektir. Akciğer nodülünü tespit etme, özellik çıkarma, nodül kısmını sınıflandırma gibi üç aşamadan geçirilmiştir. 3 boyutlu görüntüler de merkezi deformasyon olduğu için merkezi yer değiştirme kontür noktaları eğri yayılım metodu ile tahmin edilmiş ve çıkarılan görüntüler geliştirilen CNN ile sınıflandırılmıştır. Modelin değerlendirilmesi için Lung Image Database Consortium veri seti kullanılmıştır. Önerilen model SVM, CNN gibi yöntemlerle karşılaştırıldığında daha iyi bir performans göstermiştir ki elde edilen sonuçlara bakıldığında ise doğruluk %97'dir [20].

Moitra ve Mandal tarafından yapılan çalışmada küçük olmayan hücre akciğer kanserinin (NSCLC) bir boyutlu evrişimli sinir ağları kullanılarak sınıflandırılması hedeflenmiştir. Veriler, model için kullanılmadan önce Gaussian blurlama tekniği gibi önişleme

aşamalarından geçirilmiştir. Önerilen model de bölütlenmiş tümör görüntüleri hibrit özellik tespit etme ve çıkarma modeline beslenmiş, çıkarılan özellikler klinik TNM aşamalarıyla ve histopatolojik derece bilgileriyle kümelenmiş ve 2 boyutlu CNN'e beslenmiştir. CNN sonucunda elde edilen sonuçların makine öğrenmesi yöntemlerinden daha başarılı olduğu gözlemlenmiştir. Çalışmanın değerlendirilmesi için kullanılan veri seti 2210 görüntüden oluşmaktadır. Modelin veri seti üzerinde değerlendirilmesi sonucu elde edilen doğruluk %96 bulunmuştur [21].

Banik, Saha ve Kim tarafından yapılan çalışmada beyaz kan hücrelerinin sınıflandırılması için CNN tabanlı ve otomatik çekirdek bölütlemesine dayalı bir metot önerilmiştir. Model beyaz kan hücrelerinin çekirdek bölütlemesi, beyaz kan hücreleri yerelleştirme ve CNN ile sınıflandırma olmak üzere üç aşamadan oluşmuştur. Model dört farklı veri kümesi üzerinde denenmiştir. Elde edilen sonuçlara bakıldığında BCCD veri seti için %99,42 doğruluk, Cella Vision veri seti için %97,57 doğruluk, JTSC veri seti için %98,86 doğruluk, ALL-IDB2 veri seti için %98,61 doğruluk verdiği gözlemlenmiştir [22].

Zhang ve diğerleri tarafından yapılan çalışmada 1mm-5mm gibi küçük lezyonların tespit edilme başarısını arttırmak ve ağı daha kararlı hale getirmek amacıyla Faster RCNN modelindeki iki morfoloji katman değiştirilmiş ve özellik piramit ağı önerilmiştir. Aynı zamanda dört IOU eşik basamaklı RCNN birleştirilmiştir. Model the DeepLesion adında tomografi görüntülerinden oluşan veri kümesinde test edilmiştir. Önerilen yöntem diğer ağlarla karşılaştırıldığına AUC, AP, hassasiyet ve F1-skor metriklerinde en iyi sonucun önerilen model tarafından elde edildiği gözlemlenmiştir. AUC değeri 0,871, hassasiyet 0,838, F1-skor 0,839 elde edilmiştir [23].

Yıldız tarafından yapılmış olan çalışmada cilt kanserinin bir türü olan melanom tanısı için C4Net isimli bir model önerilmiştir. İlgili model literatürde yaygın olarak kullanılan AlexNet, GoogleNet, ResNet ve VGGNet gibi derin öğrenme modelleriyle karşılaştırılmıştır. Aynı zamanda KNN, SVM gibi makine öğrenmesiyle yöntemleri de önerilen model ile karşılaştırılmıştır. Veri kümesi olarak ISIC kullanılmıştır. Bu kapsamlı deneysel çalışma sonrasında önerilen modelin diğer derin öğrenme ve makine öğrenmesi modellerine göre daha başarılı sonuç verdiği gözlemlenmiştir. Çalışmada önerilen C4Net derin sinir ağ modeli ile %96,94 doğrulukta melanom tanısı konulabilmiştir [24].

Pang, Wong, Ng ve Chan tarafından yapılan çalışmada meme ultrason kitle sınıflandırmada veri artırma işlemi için yarı denetimli üretici çekişmeli ağlara dayalı radyomik model önerilmiştir. Geleneksel veri artırma yöntemi ile birleştirilen veri setinin kullanılmasıyla sentetik görüntülerin elde edilmesi için TripleGAN mimarisi eğitilmiştir. Elde edilen görüntüler bir araya getirilerek InceptionV3 CNN modeli ile sınıflandırılmıştır. TripleGAN mimarisi sınıflandırıcı, üretici, ayırıcı olmak üzere üç ağdan oluşmaktadır. Üretici sadece sahte görüntülere odaklanmayıp koşullu gerçek etiketler ve gürültüleri kullanarak sahte etiketli verileri sentezler, sınıflandırıcı ise gerçek görüntülere ve sahte etiketlere göre gerçek etiketsiz verileri elde eder, ayırıcı ise bu verilerin gerçek-sahte ve iyi-kötü huylu ayırımını yapmayı hedefler. Modelin başarısı değerlendirildiğinde elde edilen sonuçların doğruluk metriğinde %90,41 hassasiyet metriğinde %87,94 kesinlik metriğinde %85,86 başarı gösterdiği gözlemlenmiştir [25].

H. Li, Zhuang, D. Li, Zhao ve Ma tarafından yapılan çalışmada mamogram görüntülerinin iyi/kötü huylu olarak sınıflandırılması için DenseNet-II mimarisi geliştirilmiştir. DenseNet-II modeli ilk katmanında klasik CNN modellerinin aksine Inception bloğuyla başlar. GoogLeNet modelindeki Inception bloğu ile başlanmasının amacı daha derin ve daha geniş bir ağ yapısı oluşturarak daha iyi tahmin yapan bir modelin geliştirilmesidir. Model Inception bloğundan sonra yoğun blok ile devam etmiş ve mimaride üç tane yoğun blok kullanılmıştır. Veri kümesi First Hospital of Shanxi Medical University'den toplanarak elde edilmiştir. Çalışmada önerilen model AlexNet, VGGNet, GoogLeNet gibi diğer CNN modelleri ile karşılaştırıldığında DenseNet-II modelinin en iyi sonucu verdiği görülmüştür. DenseNet-II modelinin başarısı değerlendirildiğinde elde edilen sonuçların doğruluk metriğinde %94,55 hassasiyet metriğinde %95,60 ve kesinlik metriğinde %95,36 başarı gösterdiği gözlemlenmiştir [26].

Toğaçar, Özkurt, Ergen ve Cömert tarafından yapılan çalışmada meme kanserinin teşhisi için histopatolojik görüntüler üzerinde BreastNet adı verilen yeni bir evrişimli sinir ağı modeli geliştirilmiştir. BreastNet modelinde evrişimli, ortaklama bloklarının yanı sıra evrişimli blok dikkat modülü, yoğun blok, artık blok ve hiper sütun teknikleri de kullanılmıştır. Mevcut evrişimli sinir ağları modelleri ile karşılaştırıldığında %98,80 başarı ile daha iyi sonuç verdiği gözlemlenmiştir. Ayrıca bu çalışmada kullanılan BreakHis veri kümesi ile diğer çalışmalar karşılaştırıldığında da en iyi sonucu BreastNet modelinin verdiği gözlemlenmiştir [27].

Supriya ve Deepa tarafından yapılan çalışmada optimize edilmiş yapay sinir ağları kullanılarak meme kanserinin tahmini için yeni bir yaklaşım önerilmiştir. Bu yaklaşımda meme kanseriyle ilgili veriler işlenmemiş yapıda olduğu için gerekli adımlar uygulanmıştır. Bu adımlar büyük veri ile ilgilidir. Büyük veri depolama da tekrarlı veriler Hadoop MapReduce kullanılarak temizlenmiş, eksik öznitelikler doldurulmuş, normalizasyon teknikleri uygulanarak veriler işlenmiştir. Özellik seçme işlemi için Uyarlanmış Dragonfly algoritması (MDF) kullanılmıştır. Optimizasyon için Gray Wolf Optimization (GWO) kullanılmıştır. Veri kümesi olarak ise Wisconsin BC kullanılmıştır. Çalışmanın uygulanması sonucu başarımı değerlendirmek için kesinlik, doğruluk, geri çağırma ve ROC değerlendirme metrikleri kullanılmıştır [28].

Feng ve diğerleri tarafından önerilen çalışmada MR görüntüleri üzerinde meme kanseri teşhisi yapılması için bilgi odaklı özellik öğrenme ve entegrasyon çerçevesi önerilmiştir. Önerilen çerçeve sekans bölme modülü ve adaptif ağırlıklandırma modülü olmak üzere iki bölümden oluşmuştur. Sekans bölme modülünde DWI ve DCE-MRI girdi görüntülerinden alınan farklı alt bölgeler üzerinde ResNet-50 mimarisi kullanılarak özellik çıkarma işlemi gerçekleştirilmiştir. Kullanılan ResNet-50 mimarisi ImageNet üzerinde önceden eğitilmiştir. Adaptif ağırlıklandırma modülünde ise elde edilen özellikler birleştirilmiş ve farklı sekansların ağırlıklarını öğrenmesi sağlanmıştır. Sonuç olarak meme kanseri teşhisinin iyi huylu veya kötü huylu olduğu tahmin edilmiştir. Modelin başarımı değerlendirildiğinde hassasiyetin %84,6 kesinliğin %85,7 ve doğruluğun %85,0 başarı verdiği gözlemlenmiştir [29].

Toğaçar, Ergen ve Cömert tarafından yapılan çalışmada invazif meme kanserinin sınıflandırılması için evrişimli sinir ağları modelleriyle oto-kodlayıcılar birleştirilerek yeni bir yaklaşım önerilmiştir. Model 3 aşamadan oluşturulmuştur. İlk aşama da oto-kodlayıcılar kullanılarak veri kümesi yeniden yapılandırılmıştır ve hem yapılandırılan veri kümesi hem de orijinal veri kümesi CNN modelleri (AlexNet, GoogLeNet, ResNet-50, VGG-19) ile eğitilerek özellikler çıkarılmıştır. İkinci aşamada ilk aşamadan elde edilen özellikler (hem orijinal hem de yapılandırılan setler) birleştirilerek özellik seti oluşturulmuştur. Son olarak üçüncü aşamada ise iki özellik seti birleştirip yeni bir özellik seti oluşturulmuştur. Çok fazla özellik olduğu için verimli özellikleri seçerek zamandan tasarruf yapmak amacıyla özellik seçimi yapılmıştır. Bu adım için Ridge regresyon modeli yöntemi kullanılmıştır. Doğrusal ayırıcı analiz (LDA) ile sınıflandırma yapılarak çalışma sonuçlandırılmıştır. Bu çalışmada

kullanılan veri kümesi IDC'dir. Duyarlılığın %92,42 özgünlüğün %95,72 hassasiyetin %90,70 F1-skorun %94,82 başarı gösterdiği gözlemlenmiştir [30].

Lou, Li, Qian, Lu ve Ma tarafından yapılan çalışmada mamogram görüntülerini sınıflandırmak için ECA ve ResNet50 mimarisine dayalı ECA-Net50 isminde yeni bir model önerilmiştir. İlgili çalışma, literatürdeki diğer çalışmalarda ortaya çıkan zaman, kaynak ve manuel tanı gibi zorluklara çözüm bulmak amacıyla görüntü önişleme ve model optimizasyonu işlemini birleştiren iki aşamalı bir yöntemi öne çıkarmıştır. Veri kümesi olarak INbreast kullanılmıştır. Görüntüler üzerinde Meme Görüntüleme Raporlama ve Veri Sistemi (BI-RADS) kullanılarak etiketleme işlemi yapılmıştır. Önişleme adımında meme veri tabanı (BDP) önişleme metodu kullanılarak görüntüler istenilen yapıya dönüştürülmüştür. Bu adımdan sonra görüntüler ECA-Net50 mimarisinde eğitilmiş ve test edilmiştir. Literatürdeki diğer mimarilerle karşılaştırıldığında doğruluğu %92,9 bulunarak en iyi sonucu elde ettiği gözlemlenmiştir [31].

Wang ve diğerleri tarafından yapılan çalışmada verimli kanal dikkat modülü önerilmiştir. İlgili çalışmanın, sıkıştır-genişlet dikkat mekanizmalarından farkı 1x1 evrişim blokları kullanarak kanal dikkat mekanizması oluşturmasıdır. Bu sayede model karmaşıklığının ve parametre sayısının azaldığı ve sıkıştır-genişlet dikkat mekanizmalarına göre daha başarılı sonuçlar verdiği gözlemlenmiştir. Önerilen modül ResNet ve MobileNetV2 mimarileri ile kullanılarak MS COCO ve ImageNet veri kümeleri üzerinde test edilmiştir. ECA-Net ile birleştirilen mimarilerin daha üstün sonuçlar elde ettiği gözlemlenmiştir [32].

Ramamurthy, Vaichole, Kulkarni, Yadav ve Khan tarafından yapılan çalışmada Eff2Net isimli yeni bir mimari önermişlerdir. Mimari, EfficentNetV2 mimarisi ile ECA modülünün birleştirilmesiyle oluşturulmuştur. Eff2Net ile literatürdeki diğer çalışmalar karşılaştırıldığında daha az parametre ile daha üstün sonuçlar verdiği gözlemlenmiştir. DermNet NZ, Derm7pt, DermatoWeb, Fitzpatrick17k vb. gibi 13 farklı veri kümesinden elde edilen görüntüler kullanılmıştır. Model cilt veri kümesinde test edilmiştir ve doğruluğu %97,29 bulunmuştur [33].

Jin ve diğerleri tarafından yapılan çalışmada sıkıştır-genişlet dikkat mekanizmasındaki sıkıştır bloğunun değiştirerek iki aşamalı uzamsal ortaklama yapısı önermişlerdir. İlgili yöntem, metot zengin tanımlayıcı çıkarımı ve bilgi birleştirme aşamalarından

oluşturulmuştur. Zengin tanımlayıcı çıkarımı da uzamsal piramit ortaklama ve çözünürlük kılavuzlu ortaklama aşamalarından oluşturulmuştur. Uzamsal piramit ortaklama CNN modellerinde daha derin tanımlayıcılar oluşturmak için kullanılırken, çözünürlük kılavuzlu ortaklama sabit bir ortaklama penceresi kullanarak aşamaya duyarlı sayıda derin tanımlayıcı üretmek için kullanılmıştır. Önerilen model ImageNet ve MS-COCO veri kümesi üzerinde test edilmiştir. ResNet50 ve ResNet101 modelleriyle karşılaştırılmış daha üstün başarılar elde edildiği gözlemlenmiştir [34].

Zhou, Liu, Lei, Yu ve Luo tarafından yapılan çalışmada RGB-D (KırmızıYeşilMavi-Derinlik) belirginlik tespiti ve çok ölçekli özellikleri geliştirmek için MASPP (Multilevel Atrous Spatial Pyramid Pooling) yöntemini içeren hiyerarşik bir geri bildirim ağı önerilmiştir. MASPP yöntemi çok ölçekli bilgi elde edebilmek için hiyerarşik ağ modellerine uygulanmıştır. Görüntüdeki önemli bilgilerin belirlenmesinde hem renk hem de derinlik bilgisi kullanılmıştır. Çok ölçekli özellikleri öğrenmek için iki Res2Net-50 mimarisi kullanılmıştır. İki tane kullanılmasının sebebi ise hem RGB'den hem de derinlik haritasından öğrenme işleminin yapılmış olmasıdır. Farklı nesnelere ait görüntülerin bulunduğu NJUD veri kümesi üzerinde test edilmiştir. Diğer çalışmalarla karşılaştırıldığında MAE metriği sonuçlarına önerilen HFNet modelinin daha başarılı olduğu gözlemlenmiştir [35].

Jie, Nie, Li, Yin ve Jin tarafından yapılan çalışmada nesne tespiti yapabilmek için kodlayıcı-kod çözücü ile birlikte kullanılan ASPC (Atrous Spatial Pyramid Convolution) modülü önerilmiştir. Önerilen mimaride ResNet literatürde bulunan çalışmalarda bağlam özelliklerini düşük çözünürlüklü, güçlü anlamsal özelliklerden yüksek çözünürlüklü zayıf anlamsal olaylara yayma durumlarından sadece bir tanesi kullanılmıştır. İlgili çalışmada ise bu iki modülün avantaj sağlayan bölümlerini birleştirilerek ASPC-ED (Atrous Spatial Pyramid Convolution-Encoder Decoder) diye adlandırılan yeni bir nesne algılama yöntemi önerilmiştir. Pascal VOC ve MS COCO veri kümesi üzerinde eğitilen ve test edilen mimari literatürde yaygın olarak kullanılan mimarilerle karşılaştırılmıştır. MS COCO veri kümesinde CBNet (Composite Backone Network) modeli daha iyi sonuç verirken, Pascal VOC veri kümesinde önerilen mimari daha iyi sonuç vermiştir [36].

Zhu, Wa, Xu ve Wang tarafından yapılan çalışmada 6B nesne poz tahmini yapabilmek için ASPP-DF-PVNet (Atrous Spatial Pyramid Pooling-Distance Filtered-PVNet) isimli bir mimari önermişlerdir. Nesne tanıma için özellik tabanlı yöntemler ile ilgili yapılan

çalışmalara katkı sağlayan bir çalışmadır. PVNet mimarisinin kodlayıcı-kod çözücü bloklarının arasına ASPP modülünün eklenmesiyle yeni bir mimari elde edilmiştir ve görülmüştür ki önerilen yöntem PVNet'e göre daha başarılıdır. İlgili çalışma da çok ölçekli özellikleri elde edebilmek ve küresel bağlam bilgilerini kodlamak için ASPP modülünü ve mesafe filtreli özellik eşleştirme teknikleri kullanmışlardır. Farklı nesne görüntüleri olan LINEMOD ve Occlusion LINEMOD veri kümeleri kullanılarak değerlendirilmiştir. ASPP-DF-PVNet modelinin benzer çalışmalara göre da düşük hata oranı ve daha yüksek doğruluk oranı elde ettiği gözlemlenmiştir. LINEMOD veri kümesinde ADD(-S) metriği %89,63, Occlusion LINEMOD veri kümesinde ADD(-S) metriği %45,18 elde edilmiştir [37].

Tezin literatüre katkısı

Yapılan literatür taramasında sağlık alanında tıbbi görüntüleme ve bilgisayar destekli tanı sistemlerinin yaygın olarak kullanıldığı görülmüştür. Ancak her problem için ayrı ayrı tanı modeli tasarlamak gerektiği, bu modellerin bazı problemler için iyi bazı problemler için kötü sonuç verdiği bilinmektedir. Önerilen tez çalışmasında tıbbi görüntülerinin sınıflandırılmasında başarı sağlayan, düşük örnekleme sahip veri kümelerinde de yüksek doğruluk veren, yüksek seviyeli özelliklere odaklanıp, düşük seviyeli özelliklere daha az odaklanarak hesaplama ve zaman karmaşıklığını azaltan güçlü bir model önerilmektedir. Bu model evrişim katmanları, Inception Bloğu, Verimli Kanal Dikkat Bloğu (ECA) ve Atrous Uzamsal Piramit Ortaklama Bloğundan (ASPP) oluşmaktadır. Görüntü Inception bloğundan önce evrişim katmanına verilir. Burada oluşan özellik haritaları Inception bloğuna girdi olarak verilir. Inception bloğu ile özellik çıkarma gerçekleştirilir ve bu çıkarılan özellikler ECA bloğuna girdi olarak verilerek görüntülerde daha önemli özelliklere odaklanması amaçlanır. ASPP bloğu ile de bilgilendirici bağlam bilgisine sahip özellikler elde edilir. ASPP'den çıkan özellikler evrişim katmanlarına, küresel ortaklama katmanına verilir. Son olarak softmax katmanı ile sınıflandırma işlemi gerçekleştirilir. Deneysel çalışmalarda önerilen yeni model dört tıbbi görüntü veri kümesi üzerinde eğitilmiş ve test edilmiştir. Buna göre elde edilen doğruluk değerleri BT-large-4C veri kümesi için %98,05; Figshare veri kümesi için %99,84; BT Kidney veri kümesi için %99,5; BreaKHis veri kümesi için de %96,98 elde edilmiş, modelin üç veri kümesinde literatüre göre oldukça yüksek başarım yakaladığı görülmüştür.

Tezin diğer bölümleri teorik arka plan, deneysel çalışma ve sonuçlar, sonuç ve değerlendirme başlıkları altında incelenecektir. Teorik arka plan bölümünde tıbbi görüntüleme yöntemlerine, derin öğrenmenin genel yapısına, derin öğrenme modellerine ve tez çalışmasında önerilen modelin nasıl oluşturulduğuna değinilmiştir. Deneysel çalışma ve sonuçlar bölümünde kullanılan veri kümelerine, modelin başarısının ölçülmesi için değerlendirmeyi hangi metrikler kullanılarak yapıldığına, çalışmada elde edilen sonuçlara yer verilmiştir. Sonuçlar ve değerlendirme bölümünde gerçekleştirilen modelin test sonuçlarına değinilmiş, elde edilen doğruluk değerleri ile modelin başarısı değerlendirilmiştir. Ayrıca bu bölümde literatürdeki diğer çalışmalarla karşılaştırması yapılmıştır.

2. TEORİK ARKA PLAN

Bu bölüm başlığının altında tıbbi görüntüleme teknikleri, görüntü sınıflandırmanın genel yapısı, önerilen yöntemde kullanılan modellerin temelleri, derin öğrenme kullanılarak yapılan sınıflandırma işlemi, derin öğrenme de kullanılan aktivasyon ve optimizasyon fonksiyonları ile ilgili bilgiler verilecektir.

2.1. Tıbbi Görüntüleme Yöntemleri

Tıbbi görüntüleme yöntemleri hastalarda tanının koyulması ve tedavinin sağlanması için günümüzde yaygın olarak kullanılmaktadır. Hastalığın belirtileri de dikkate alınarak MR, Ultrason ve BT tıbbi görüntüleme için hekimler tarafından en çok tercin edilen yöntemlerdir. Bu tez çalışması kapsamında kullanılan veri kümelerinde görüntüler MR veya BT ile elde edildiğinden bu başlık altında ikisi hakkında bilgi verilecektir.

BT ilk başlarda beyin görüntüleme için kullanılırken zamanla vücudun diğer yapıları için de kullanılmaya başlanmıştır. Vücudun iç yapısını 3 boyutlu görüntülemek için kullanılan invazif olmayan bir görüntüleme yöntemidir [38]. BT'de üçüncü boyut, görüntülenmek istenen objenin kesitsel görüntülerinin bir araya getirilmesidir. Böylece ortaya hacimsel bir görüntü çıkmaktadır. BT hastanın vücut kesitlerinin oluşturulması amacıyla hastanın etrafında dönerek X-ışını tüpünden veriler toplar. Hekimler tarafından daha çok vücudun daha kesin tam bir görünümünün sağlanması için tercih edilmektedir.

BT bazı avantaj ve dezavantajlara sahiptir. Avantajlarını sıralamak gerekirse;

- Tarama işlemi hızlı olduğu için hızlı bir şekilde sonuç elde edilir.
- Kemik dokusunu daha net bir şekilde görüntülemeyi ve analiz edebilmeyi sağlar.
- Hastaların tarama süresince küçük hareketlerini algılamaz. Böylece hareketler sonuca etki etmez.

Dezavantajlarını ifade etmek gerekirse;

- Radyasyon içerdiği için tekrarlanması tehlikelidir.
- Kontrast madde kullanımı gereken durumlarda hastalarda yan etki oluşturma ihtimali vardır.

- Yumuşak dokuların tam ve detaylı gösterimi zayıftır.
- Maliyeti fazladır.

MR vücudun kasları, yumuşak dokuları, sinirleri, kemikleri ve iç yapıları görüntülemek için kullanılan tıbbi görüntüleme yöntemlerinden biridir [39]. Bu görüntülerin elde edilmesi için manyetik alan ve radyo dalgaları kullanılır. MR yönteminin bazı avantaj ve dezavantajları varıdır.

Avantajlarını sıralamak gerekirse;

- Yüksek çözünürlüğe sahiptir. Başka bir ifadeyle yapıyı daha detaylı gösterir.
- X-ışınlarının aksine radyasyon içermez. Bu da MR'nin tekrarlanabilmesini sağlar.
- Kontrastlı maddelerin kullanılmasıyla istenilen dokuların daha net görünmesini sağlar.

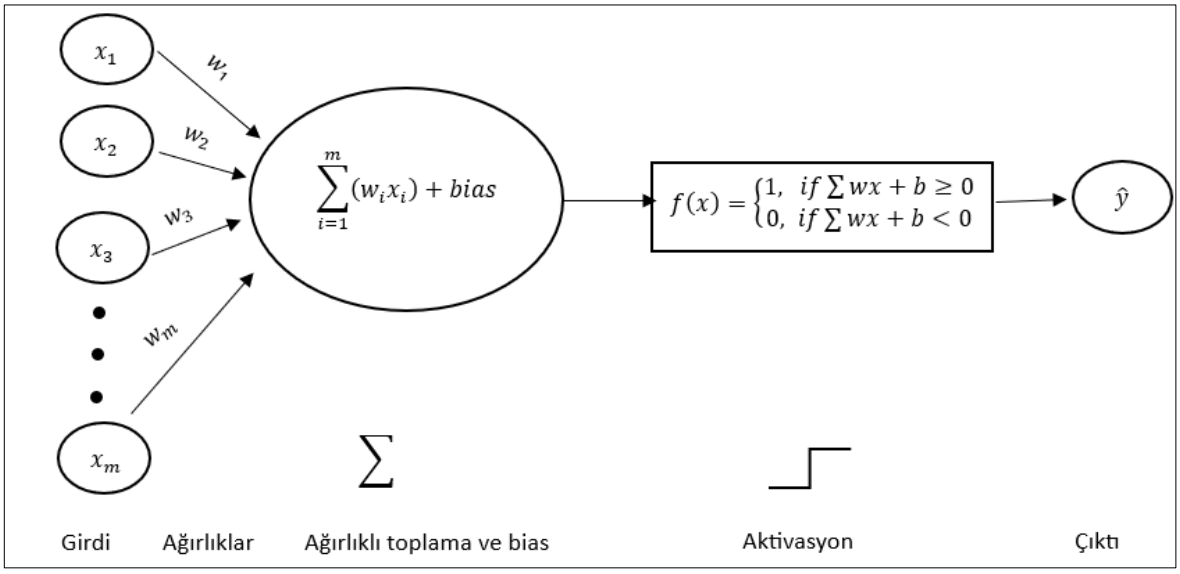
Avantajlarının yanında bazı dezavantajlara da sahiptir. MR cihazlarının ve işlem maliyetinin yüksek olması, dar bir alana sahip olmasından dolayı bazı hastaların kapalı alan korkusunun olması, hareket hassasiyetinin olması, taramaların nispeten daha uzun sürmesi örnek verilebilir.

MR ile BT'nin temel farkını belirtmek gerekirse BT X-ışınlarını kullanarak görüntüler oluştururken MR manyetik alan ve radyo dalgalarını kullanarak görüntü oluşturur. Ayrıca BT MR'ye göre daha hızlı bir tarama sürecine sahiptir. BT'de kontrastlı madde kullanımı bir dezavantaja sahipken MR'de bir avantaja sahip olduğu söylenebilir. Bunun nedenini açıklamak gerekirse, BT'de organların veya dokuların belirgin görülmesi için kontrastlı madde kullanılır. Bu da hastalarda alerjik bir reaksiyona neden olabilir. MR'de ise genellikle yumuşak dokuların, tümörlerin vs. belirgin görülmesi için kontrastlı madde kullanılır ve BT'deki gibi bir radyasyon yoktur. Dolayısıyla alerjik reaksiyon riski daha azdır.

2.2. Görüntü Sınıflandırma

Yapay zekanın alt dallarından birisi derin öğrenmedir. Derin öğrenme, kendisine verilen veri kümesini kullanarak çıktıyı tahmin edebilmek amacıyla yapay zekayı eğitmek için kullanılan hesaplama modellerinin genel adıdır [40]. Yapay sinir ağları, derin sinir ağları, evrişimli sinir ağları ve benzeri modelleri kapsayan bir alandır.

Yapay sinir ağları (YSA) kendi kendine öğrenebilen, eğitilebilen ve bunların sonucunda değerlendirme yapabilen bir alandır [41]. Sınıflandırma ve regresyon gibi uygulamalar için kullanılmaktadır. YSA'da yapılan temel işlem, model için en uygun ağırlık ve bias parametrelerinin hesabını yapmaktır [42]. Şekil 2.1.'de bir YSA modeli gösterilmektedir ve burada x'ler girdileri, w'ler ağırlıkları ifade etmektedir. Girdi görüntülerindeki değerler ilgili ağırlık değerleriyle çarpılır, bias değeriyle toplanır. Ardından aktivasyon fonksiyonu ile lineer olmayan değerler üretilir. Bu yapı YSA'nın temelini oluşturmaktadır.

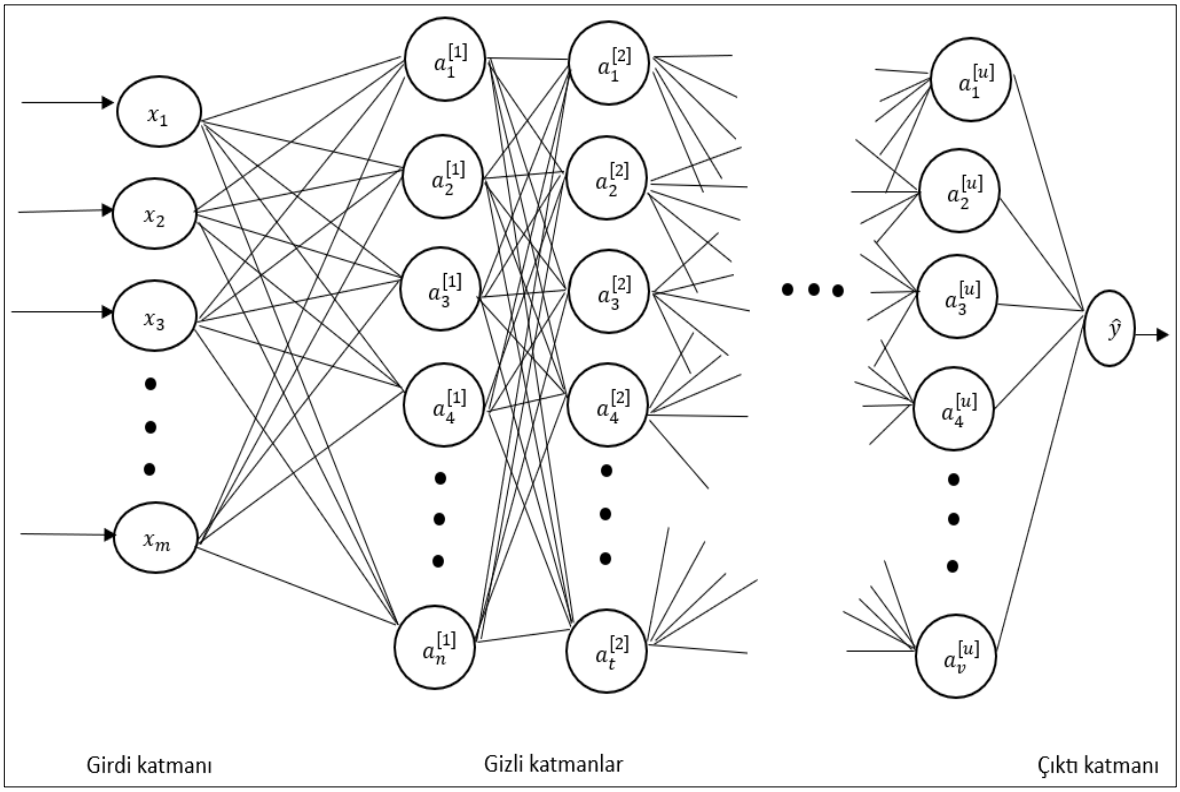


Şekil 2.1. Temel bir YSA modeli

Derin sinir ağları girdi katmanı, çıktı katmanı ve bu iki katmanı birbirine bağlayan gizli katmanlardan oluşur. Bir modelde girdi ve çıktı katmanı bir tane olurken gizli katmanı birden fazla katmandan oluşmaktadır. Girdi katmanındaki değerler ağırlıklarla çarpılıp aktivasyon fonksiyonu işleminden geçirildikten sonra bir sonraki katmanın girdisi olur. Bu işlemler yapılırken ağırlık değeri ilk başta 0 ile 1 arasında rastgele değer alır. Sonrasında oluşan çıktı ile olması gereken çıktı arasındaki kayıp değeri bulunur. Bulunan kayıp değeri ile yeni ağırlıklar geriye yayılım yöntemiyle yeniden hesaplanır [43]. Geriye yayılım yapılmasının amacı oluşan çıktının olması gereken çıktıya yakın olmasıdır. Şekil 2.2.'de bir derin sinir ağı modeli gösterilmektedir.

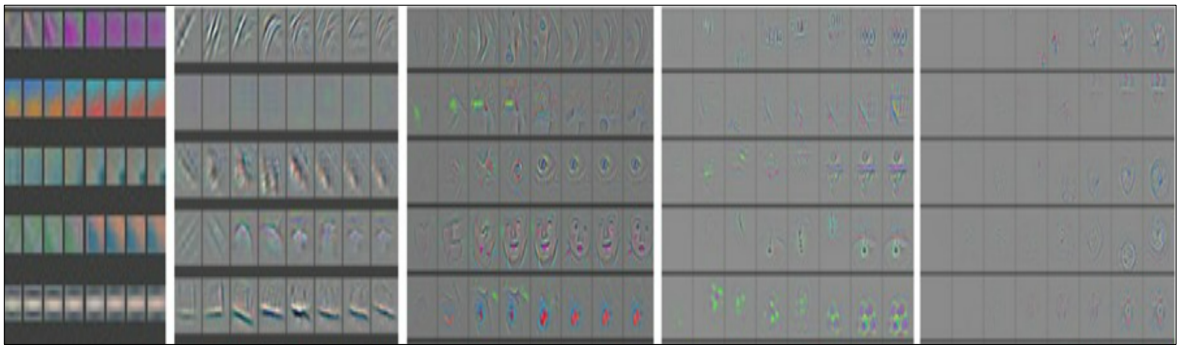
Makine öğrenmesinde özellikler manuel olarak çıkarılırken DSA'larda bu işlem gizli katmanlar aracılığıyla gerçekleşmektedir. Ayrıca makine öğrenmesinden bir farkı da

DSA'larda bir ağı eğitmek için gereken verinin miktarının makine öğrenmesine göre daha büyük olmasıdır.



Şekil 2.2. Temel bir DSA modeli

Evrişimli sinir ağları (CNN) yapay sinir ağlarının en çok kullanılan alanlarından birisidir. CNN girdi olarak kompleks yapıları (görüntü, video, ses, metin vb.) alıp istenilen çıktıyı oluşturmak için girdi üzerinde katmanlar aracılığıyla öğrenme işlemini gerçekleştiren bir yapıdır. CNN'in yapı taşlarından birisi katmanlardır. Katmanlar bir veya birden fazla görüntüyü girdi olarak alıp çıktı olarak bir veya birden fazla katmana dönüştürür. CNN genel olarak üç katmandan oluşmaktadır. Bunlar evrişim katmanı, ortaklama katmanı ve tam bağlantı katmanıdır. Temel CNN mimarisinin katman sayılarının ve katmanlarda uygulanan işlemlerin değiştirilmesi ile çeşitli sinir ağları oluşturulup problemlerin çözümünde kullanılırlar [44-45]. Katmanların amacı öznitelik çıkarmaktır [46]. CNN'de katmanlar derinleştikçe çıkarılan öznitelikler de derinleşir. Ancak katman sayılarının çok fazla olması ile modelin başarısı doğru orantılı değildir. Şekil 2.3'te ilk katmanlardan son katmanlara doğru gidildikçe çıkarılan özelliklere örnek verilmiştir.

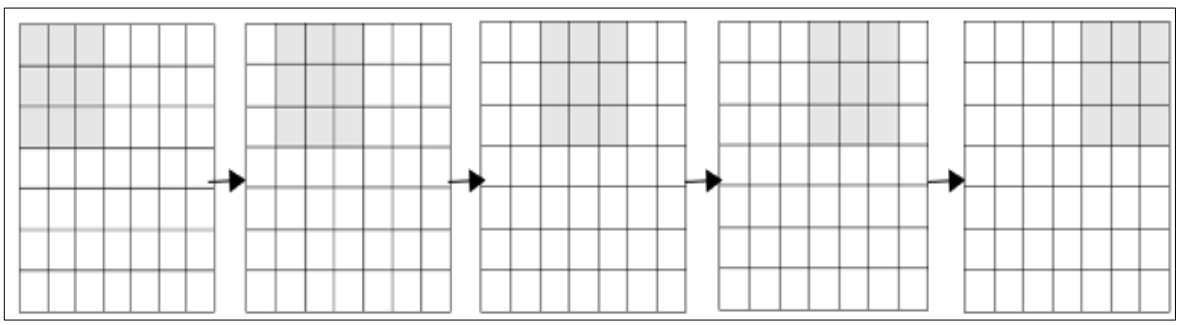


Şekil 2.3. İlk katmanlardan son katmana doğru çıkarılan özellikler

Evrişim katmanı (Convolution layer)

Evrişim katmanı evrişim işleminin yapıldığı katmandır. Verilen girdi görüntüleri ile filtreler arasında bir evrişim işlemi uygular. Ardından aktivasyon fonksiyonları uygulanıp bias değeri ile toplandıktan sonra evrişim katmanının çıktısı oluşmuş olur. Elde edilen çıktı bir özellik haritasıdır. Evrişim katmanı CNN mimarisinde özniteliklerin çıkarılması için kullanılır. Evrişim katmanları çıktıyı optimize ederek modelin karmaşıklığını azaltabilir. Görüntülere uygulanan filtrelerin farklı olması farklı özelliklerin çıkarılmasına olanak sağlar.

Kaydırma adımı (stride) evrişim işlemi yapılırken görüntüye uygulanacak filtrenin görüntü üzerinde kaç adım kaydırılacağını belirler. Kaydırma adımını belirlemek önemlidir. Çünkü kaydırma adım değerinin çok büyük olması görüntüden çıkarılacak özelliklerin kaybolmasına neden olabilir. Şekil 2.4.'te kaydırma adımının 1 olması durumunda görüntü üzerinde filtrenin nasıl kaydırıldığı gösterilmektedir.



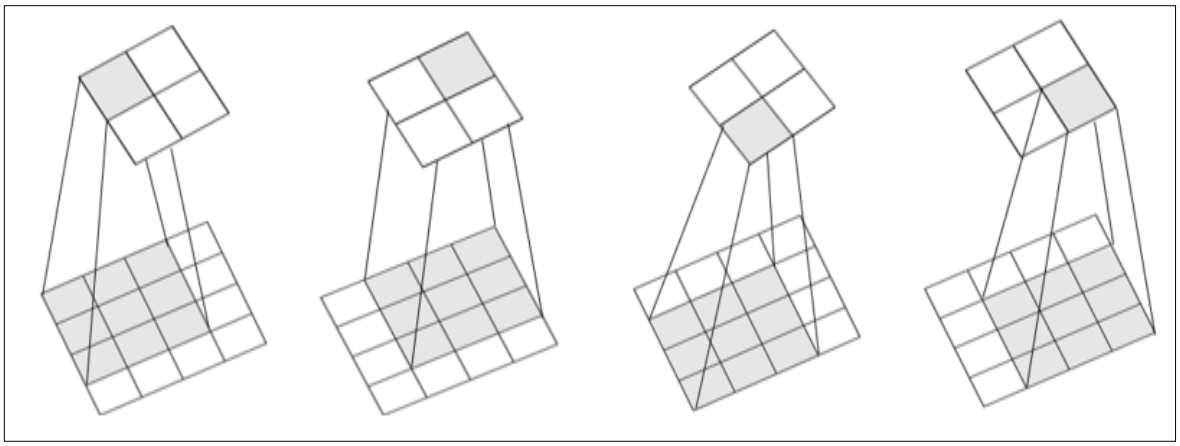
Şekil 2.4. Kaydırma adımının (s=1) gösterilmesi

NxN boyutlarında bir görüntü verildiğinde ve bu görüntüye fxf boyutlu filtre uygulandığında elde edilen çıktı görüntüsünün boyutu Eş. 2.1'de verilen formül ile hesaplanmaktadır. s kaydırma adımını, O çıktı görüntüsünü ifade etmektedir.

$$O = 1 + \frac{N-f}{s} \tag{2.1}$$

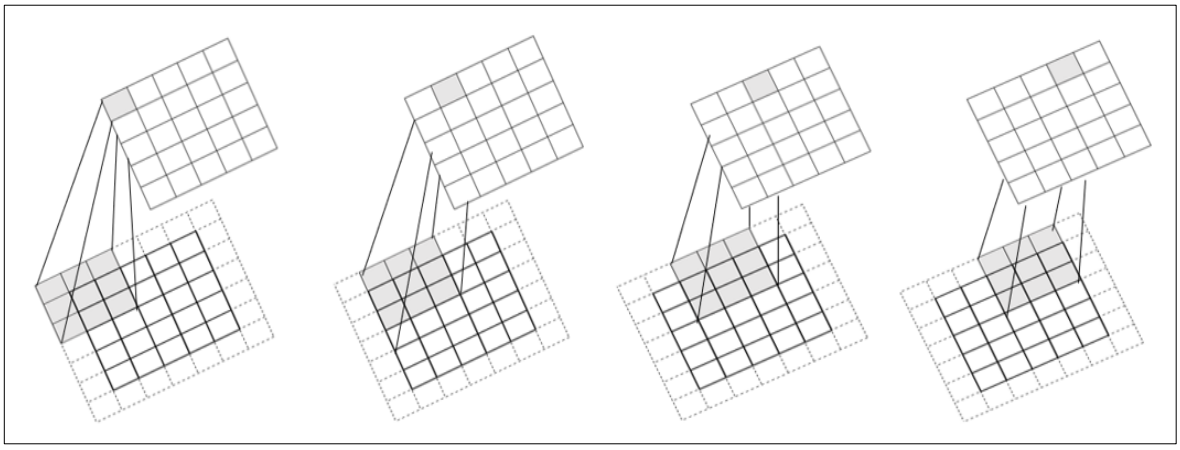
Görüntülere piksek ekleme işlemi iki amaç için uygulanabilir. Bunlardan ilki görüntüler üzerine filtre uygulandığında görüntünün kenarlarında bilgi kaybı olma ihtimalinin ortadan kalkması, ikincisi ise çıktı görüntüsünün boyutunun girdi görüntüsü ile aynı boyutlarda olmasının istenmesidir. Piksel ekleme işleminin iki yöntemi vardır. Bunlardan ilki görüntünün kenarlarına sıfırların eklenmesidir. İkincisi ise kenarlara eklenecek değerlerin komşu piksellerin değerleri ile aynı olacak şekilde ekleme yapılmasıdır.

Şekil 2.5'te görüntü üzerine uygulanan filtre için kenar ekleme işlemi yapılmamıştır. 4x4'lük görüntüye 3x3'lük filtre uygulandığında ve kaydırma adımı 1 seçildiğinde elde edilen çıktı görüntüsü 2x2'lik olur.



Şekil 2.5. Piksel ekleme işlemi olmadan görüntü üzerine uygulanan filtre işlemi

Şekil 2.6'da ise görüntü üzerine uygulanan filtre için kenar ekleme işlemi yapılmıştır. Kenar ekleme işlemi yapıldığında filtreleme işleminden sonra görüntünün boyutunda bir değişim olmayacaktır. Şekil 2.6.'da 5x5'lik görüntüye piksel ekleme işlemi yapılmış ve çıktı görüntüsünün boyutu 5x5 olur.



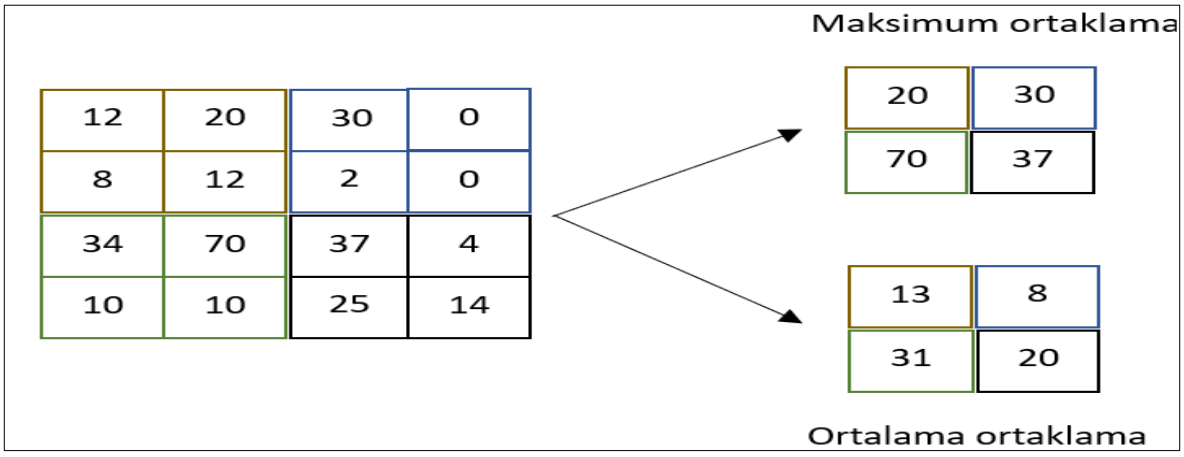
Şekil 2.6. Piksel ekleme işlemi yapılarak görüntü üzerine uygulanan filtre işlemi

Piksel ekleme işlemi yapıldığında çıktı görüntüsünün boyutunu hesaplamak için Eş. 2.2'de verilen formül kullanılır. p, eklenecek piksel boyutunu ifade etmektedir.

$$O = 1 + \frac{N+2p-f}{s} \tag{2.2}$$

Ortaklama katmanı (Pooling layer)

Ortaklama katmanı hesaplama karmaşıklığını azaltmak için boyut azaltmanın yapıldığı katmandır ve bu katmanda öğrenme işlemi gerçekleşmez yani öğrenilen parametre yoktur. Boyut azaltma işlemi yaparken görüntünün boyutlarında (yükseklik ve genişlik) azaltma yapılır ancak kanal sayılarında bir azaltma yapılmaz. Ortaklama işlemi iki şekilde yapılabilir. Biri ortalama ortaklama diğeri ise maksimum ortaklamadır. En çok kullanılan ise maksimum ortaklamadır. Ortaklama işlemini yapmak için verilen görüntü belirlenen alt görüntü bölgelerine ayrılır. Maksimum ortaklama için alt bölgelerdeki en büyük değer alınırken, ortalama ortaklama için alt bölgelerdeki değerlerin ortalaması alınarak boyut azaltma işlemi uygulanır. Şekil 2.7.'de ortaklama türleri gösterilmektedir.



Şekil 2.7. Ortalama ortaklama ve maksimum ortaklama işlemi

Tam bağlantı katmanı (Fully connected layer)

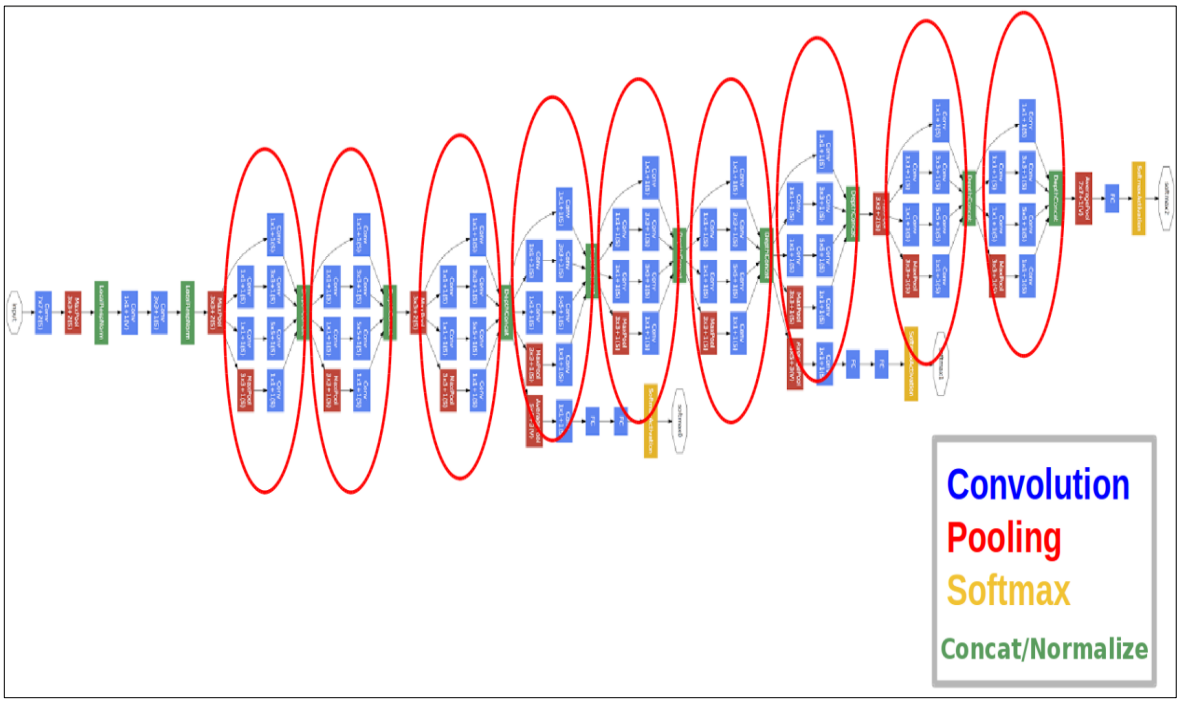
Tam bağlantı katmanı üst katmanın çıktısını alarak çıkarılan özellikler doğrultusunda en uygun hangi kategoriye ait olduğunu belirler. Bu katman girdi tensörünü alarak veri setindeki sınıf sınıfların sayısı ile aynı sayıda bir vektöre dönüştürür. Yani tam bağlantı katmanı özellik çıkarmaz sınıflandırma yapar.

2.3. Derin Öğrenme Modelleri ile Görüntü Sınıflandırma

Tez kapsamında geliştirilen modelin temel yapılarına bu başlık altında yer verilmiştir. Geliştirilen model de bu yapıların olduğu gibi kullanılmayıp başarıyı arttırmak amacıyla en optimal sonucu verecek parametrelerle ve katmanlarla değiştirilmiştir.

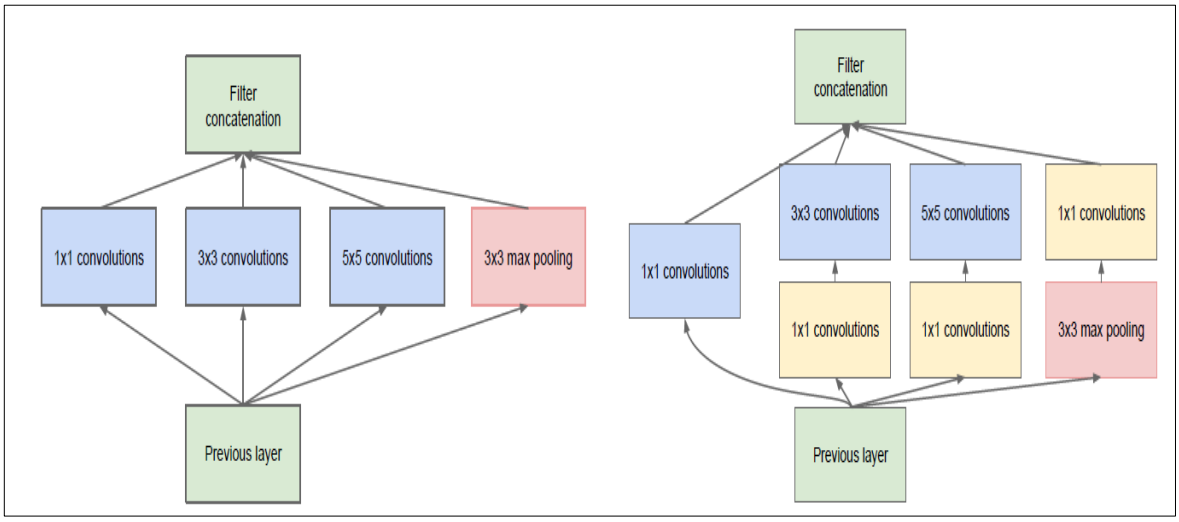
GoogLeNet mimarisi, Szegedy ve diğerleri tarafından 2014 yılında gerçekleştirilen bir CNN modelidir [47]. Google tarafından sunulan GoogLeNet, ILSVRC14 (ImageNet Large-Scale Visual Recognition 2014) yarışmasında birincilik elde etmiştir. GoogLeNet modeli LeNet modelinden esinlenilerek oluşturulmuş bir modeldir. 2012 yılında yine aynı yarışmayı kazanan ALexNet [48] modelinden yaklaşık 12 kat daha az parametre ile daha yüksek doğruluk elde etmiştir. GoogLeNet 22 katmana sahip derin bir ağ modelidir. Şekil 2.8.'de mimarisi gösterilmektedir.

Model de aktivasyon fonksiyonu için ReLU, ortaklama işleminde Inception için maksimum ortaklama diğerlerinde ortalama ortaklama kullanılmıştır. Unutma katmanında bilgilerin %70'i unutulmuştur.



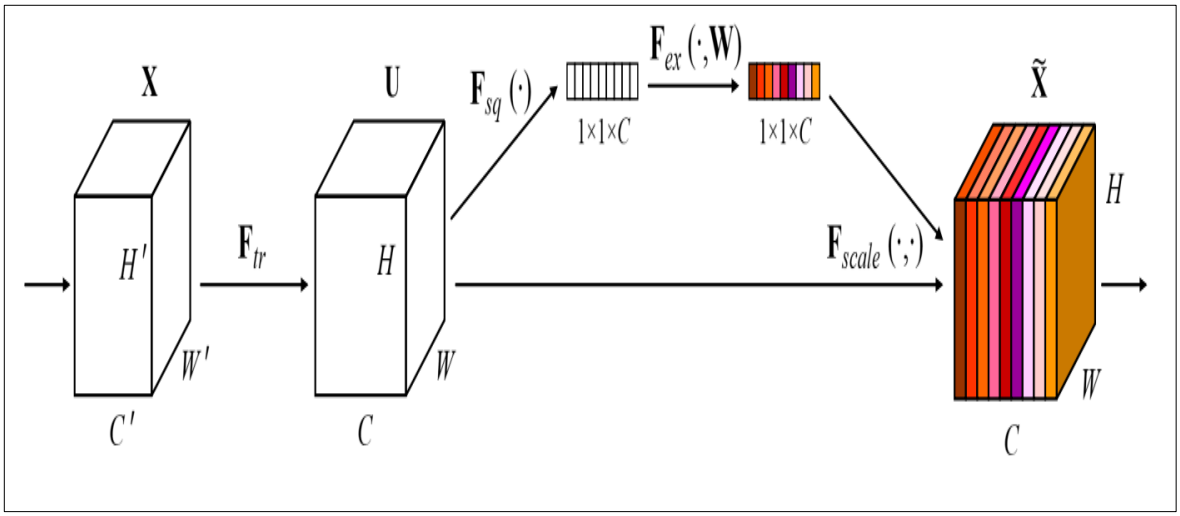
Şekil 2.8. GoogLeNet mimarisi [47]

Şekil 2.8'deki GoogLeNet modeline bakıldığında 9 tane Inception bloğu kullanıldığı görülmektedir. Inception bloğu ile daha derin bir ağ yapısı oluşturularak daha iyi sonuçlar elde edilmesi hedeflenmiştir. Aynı zamanda Inception bloğu seyrek bağlantılı bir yapıya da sahiptir. Farklı filtrelere sahip evrişim katmanlarının birleştirilmesiyle oluşturulmuştur. Şekil 2.9.'da Inception bloğunun yapısı gösterilmektedir.



Şekil 2.9. Inception bloğu [47]

Hu ve diğerleri geliştirdikleri SENet [49] mimarisi ile ILSVRC 2017 yarışmasında birincilik elde etmişlerdir. Mimari CNN'in bilgi çıkarma işlemindeki eksikliği gidermek amacıyla geliştirilmiştir. SENet, kanallar arasındaki karşılıklı bağımlılıklara odaklanarak kanal açısından özellik yanıtlarını uyarlamıştır. Kanallar arasındaki karmaşık bağımlılıkların çok daha fazlasını yakalamak için farklı yöntemler üretmişlerdir ancak bu durum modelin karmaşıklığını arttırmaya neden olmuştur. Bu da istenmeyen bir durumdur. Şekil 2.10'da SENet'in genel yapısı gösterilmektedir. Bu yapı içerisinde sıkıştır-genişlet yapıları da gösterilmektedir.



Şekil 2.10. SENet'in genel yapısı [49]

SENet mimarisi iki alt yapıdan oluşmaktadır. Bunlar sıkıştır ve genişlet bloklarıdır.

Sıkıştır bloğu

Sıkıştırma işleminde, girdi özelliklerinin her kanalına küresel ortalama ortaklama uygulanır. Özellik haritalarının uzamsal boyutlarını tekil bir değere indirmek için CNN'de ortaklama işlemi uygulanmıştır. CNN'de bu ortaklama işlemi için iki seçenek mevcuttur. Bunlar ortalama ortaklama ve maksimum ortaklamadır. Bu ikisinden biraz daha iyi sonuç veren küresel ortalama ortaklama tercih edilmiştir [50]. GAP ile özellik haritasındaki bütün piksellerinin ortalaması alınarak tekil bir değere indirilmiştir. Örneğin özellik haritasının boyutu Yükseklik x Genişlik x Kanal ise GAP uygulandıktan sonra çıktı 1 x 1 x Kanal olacaktır.

$$z_c = F_{sq}(u_c) = \frac{1}{WxH}\sum_{i=1}^{W}\sum_{j=1}^{H} u_c(i,j) \tag{2.3}$$

Sıkıştırma işleminin formülü Eş. 2.3'te gösterilmektedir. F_{sq} küresel ortalama ortaklama ile küresel uzamsal bilgileri kanal bazında istatistiklere sıkıştırdığını ifade etmektedir. c kanal sayısını, u özellik haritasını, z ise çıktıyı ifade etmektedir.

Genişlet bloğu

Sıkıştırma işleminin ardından özellik haritası ağırlıklandırma için uygun hale getirilmiştir. Sıkıştırılan özellik haritalarını tekrar eski haline getirmek için genişlet yapısı kullanılmıştır. Sıkıştırma işleminde toplanan bilgilerden yararlanmak için, kanal bazında bağımlılıkları tam olarak yakalamak içi genişlet bloğu kullanılmıştır.

$$s = F_{ex}(z, W) = \sigma\big(g(z, W)\big) = \sigma(W_2\delta(W_1 z)) \tag{2.4}$$

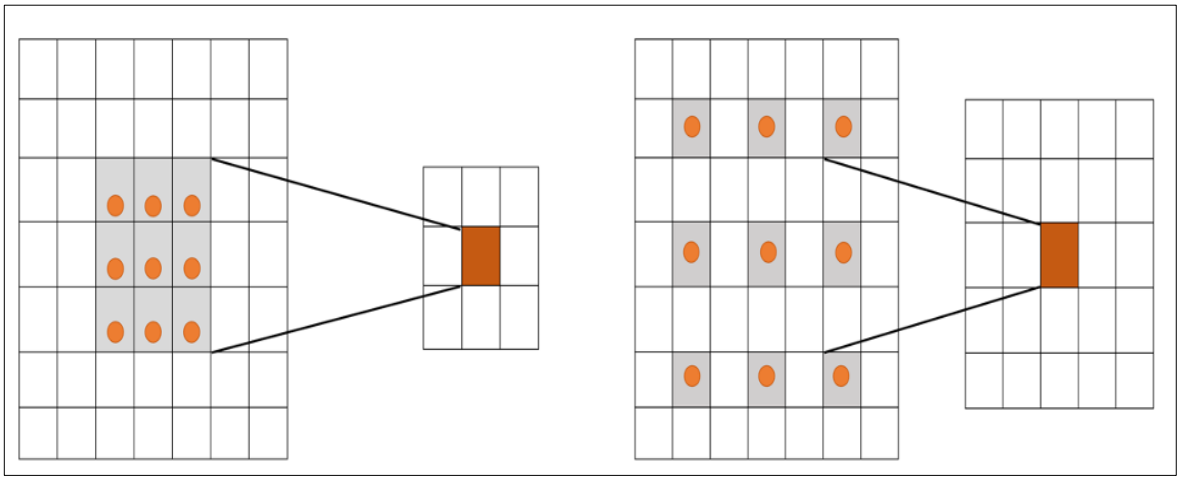
Genişletme işleminin formülü Eş. 2.4'te gösterilmektedir. F_{ex} küresel ortalama ortaklama ile küresel uzamsal bilgileri kanal bazında istatistiklere sıkıştırdığını ifade etmektedir. σ sigmoid fonksiyonunu, δ ReLU aktivasyon fonksiyonunu ifade etmektedir. $W_1 \in \mathbb{R}^{Cx\frac{C}{r}}$, $W_2 \in \mathbb{R}^{\frac{C}{r}xC}$ iki tane tam bağlantılı katmanının ağırlıklarını ifade etmektedir.

Sıkıştır ve genişlet bloklarının yapılmasının ardından Şekil 2.10'da da gösterildiği gibi

sıkıştır bloğuna girdi olarak verilen özellik haritası ile genişlet bloğunun çıktısı birleştirilir. Birleştirme işlemi için kullanılan formül Eş. 2.5'te verilmiştir.

$$\widetilde{x_c} = F_{scale}(u_c, s_c) = s_c . u_c \tag{2.5}$$

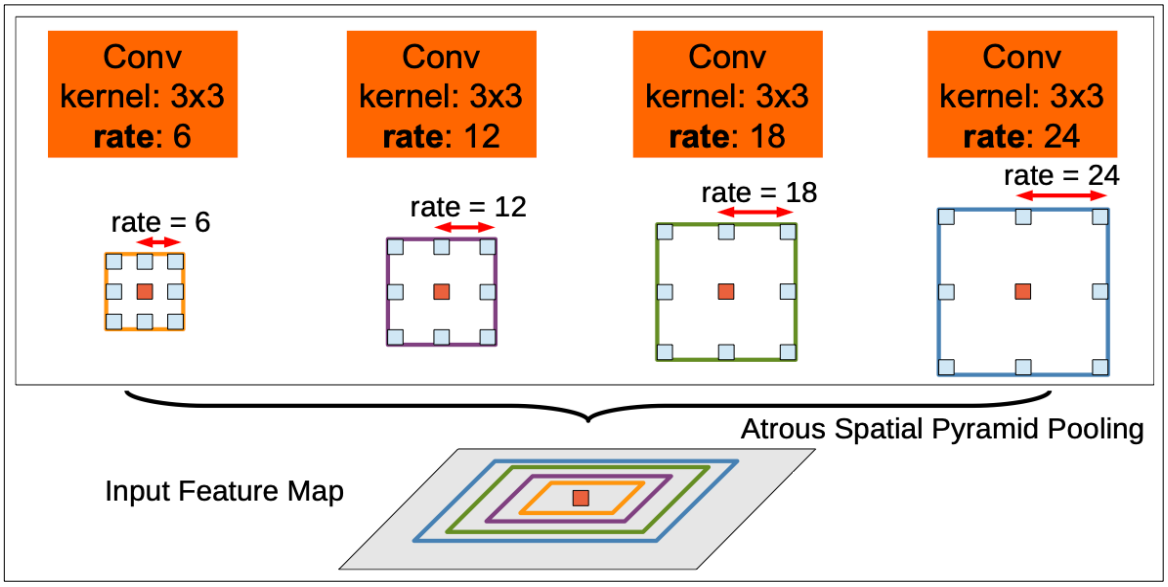
Chen ve diğerleri [51] 2017 yılında ASPP modülünü tanıtmışlardır. Bu modül uzamsal piramit ortaklama (SPP) modülünden esinlenilerek geliştirilen derin öğrenme tabanlı bir yaklaşımdır. Modülün SPP modülünden esinlenilen tarafı, farklı ölçeklere sahip özellikleri yeniden ölçekleyerek çeşitli boyutlarda olan nesnelerin sınıflandırmasında etkili olmasıdır [52]. ASPP modülü normal evrişim işlemlerinden farklı olarak genişletilmiş evrişimleri kullanır. Genişletilmiş evrişim kullanıldığında hesaplama maliyetini ve parametre sayısını arttırmadan bu işlem yapılır [53]. Şekil 2.11'de normal evrişim ile genişleyen evrişimin nasıl bir kullanıma sahip olduğu gösterilmektedir. Genişleyen evrişim işleminde art arda gelen çekirdeklerin arasındaki değerlere sıfır eklenir. Yani genişleme oranına bakılarak eklenecek sıfır sayısı ortaya çıkar. Genişleme oranının r olması durumunda eklenecek sıfır sayısı r-1 ile bulunur. Şekil 2.11'deki örnekte genişleme oranı 2 olduğu için eklenecek olan sıfırların sayısı 1 olur.



Şekil 2.11. Soldaki normal evrişim, sağdaki genişleyen evrişim (genişleme oranı:2)

ASPP kullanılmasıyla CNN'lerin görüntü sınıflandırma, nesne algılama, semantik bölütleme gibi işlemlerinde performansı iyileştirdiği belirtilmiştir. Görüntülerdeki bağlamsal bilgiyi çıkarma yeteneğini geliştirilmesi için ASPP iyi bir yaklaşımdır [54]. Şekil 2.12'de özellik haritalarından farklı ölçeklerdeki bağlamsal bilgileri çıkarmak kullanılan genişleme oranları

6, 8,12 ve 24 gösterilmektedir. Bu genişleme oranları uygulandıktan sonra, çıkan özellik haritaları birleştirilmektedir.



Şekil 2.12. ASPP bloğu [55]

Günümüzde verinin ciddi boyutlarda artmasıyla optimizasyon algoritmalarına olan ihtiyaç da artmıştır. Optimizasyon algoritmalarının amacı karmaşık problemleri çözüme ulaştırırken problem için optimum çözümü bulmaktır. Hata fonksiyonlarını minimize ederek modelin başarılı bir sınıflandırma yapmasını amaçlar. Çeşitli optimizasyon algoritmaları olmasına rağmen yaygın olarak kullanılanlar Stokastik Gradyan İniş (SGD), Adagrad, Adadelta, Adam, RMSprop'tur. Bu algoritmalar birbirlerinden hız ve öğrenme yeteneği açısından farklılık gösterdiği için optimizasyon algoritması seçiminde bu durumlar göz önünde bulundurulmalıdır [56]. Bu çalışmada Adam, RMSprop ve Momentum algoritmalarından bahsedilmiştir.

ADAM optimizasyon algoritması

Adam optimizasyon algoritması RMSProp ve momentum algoritmalarının avantaj sağladıkları yerlerin birleştirilmesi ile oluşturulmuştur. Örneğin RMSProp algoritmasındaki gibi öğrenme hızını ölçeklendirmek için kare gradyanlar kullanılır, momentum algoritmasındaki gibi gradyan yerine gradyanın hareketli ortalaması kullanılır [57-58]. Bu algoritma her parametre için adaptif öğrenme oranlarını hesaplar. Adam optimizasyonu sinir

ağlarındaki her ağırlık için öğrenme oranını uyarlamak için birinci ve ikinci gradyan momentlerinin tahminini kullanır. Adam optimizasyon algoritmasının diğer optimizasyon algoritmalarından ayıran avantajları vardır. Örneğin, bellek gereksinimi azdır ve parametre sayıları çok olan modeller için uygundur, adım boyutu hiperparametre ile sınırlandırılarak sezgisel anlayış katar ve adım boyutu eğimin büyüklüğüne bağımlı olmadığı için eğimli yerlere çok fazla takılmadan zamandan tasarruf eder. Avantajlarının yanı sıra optimal çözüme çok fazla yaklaşamaması gibi dezavantajı da vardır.

$$w_{t+1} = w_t - \frac{a}{\sqrt{\frac{S_t}{1-\beta_2^t}+\in}} * \frac{V_t}{1-\beta_1^t} \tag{2.6}$$

$$V_t = \beta_1 V_{t-1} + (1-\beta_1) * \frac{\vartheta L}{\vartheta w_t} \tag{2.7}$$

$$S_t = \beta_2 S_{t-2} + (1-\beta_2) * \left[\frac{\vartheta L}{\vartheta w_t}\right]^2 \tag{2.8}$$

Yukarıda verilen denklemlerdeki parametre değerlerine varsayılan olarak S=0, V=0, a = 0,001, β_1=0,9, β_2=0,999 ve $\in$ = 10-8 verilmektedir.

RMSProp optimizasyon algoritması

RMSProp (Root Mean Square Propagation) optimizasyon algoritması parametreleri güncelleyerek momentum ile gradyan inişine benzer şekilde üstel ağırlıklı ortalama gradyanı kullanır [58] [59]. RMSProp algoritması sonraki ağırlık ortalamasını bulmak için mevcut durumun karesi ile geçmiş değerlerin ortalaması arasında bir ağırlık ataması yapar [60].

Momentum optimizasyon algoritması

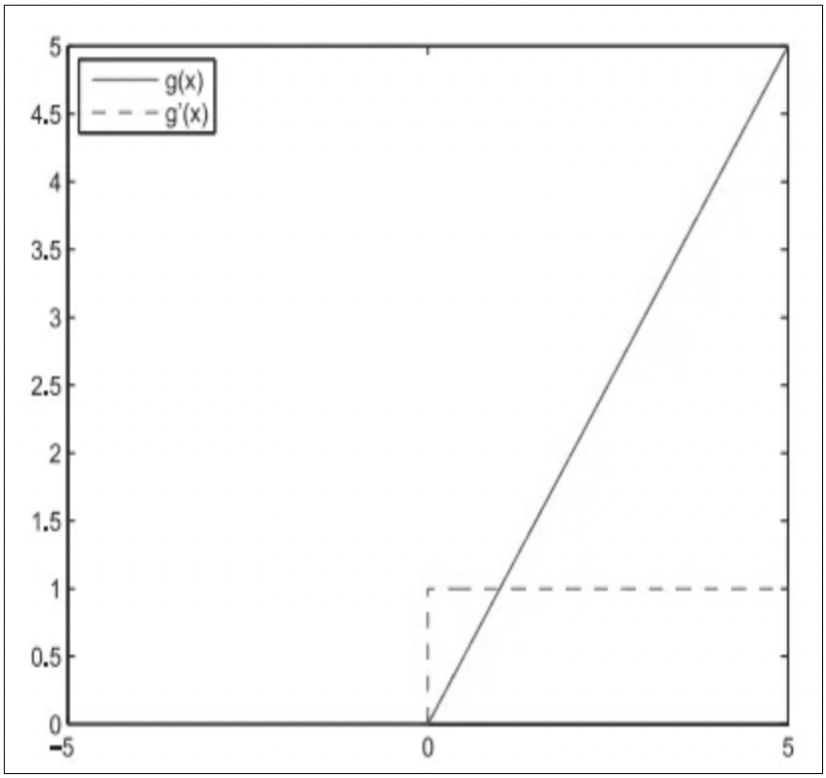
Momentum optimizasyon algoritması diğer algoritmalara göre daha hızlı ilerler ancak daha fazla detaylara takıldığı için eğitimi olumsuz etkileyebilir. Bu yüzden bu optimizasyon algoritmasının amacı, yanıt verme hızını arttırmak ve gradyan inişinin yavaşlamasını sağlamaktır [61]. Momentum optimizasyon algoritmasının avantajı kararlılık açısından avantaj sağlamasıdır. Çünkü gradyan ile hareket ettiği için doğru yere gidilmesini kolaylaştırmaktadır.

Aktivasyon fonksiyonları YSA'ya uygulanarak modelin doğrusallığı yerine doğrusal olmayan halinin elde edilmesini sağlar. Yani gerçek dünya problemleri basit olmadığı için aktivasyon fonksiyonları ile modeli gerçek dünyaya yakınsamaya çalışır. Modele aktivasyon fonksiyonu uygulanmadığı takdirde modelin öğrenmesi sınırlı kalır ve bu da performansı etkiler [62]. Kısacası modele ses, görüntü, metin gibi doğrusal olmayan karmaşık gerçek dünya bilgileri verildiğinde anlamlı özellikleri öğrenebilmesi için aktivasyon fonksiyonlarına ihtiyaç vardır. En çok kullanılan aktivasyon fonksiyonları sigmoid, hiperbolik tanjant, ReLU, sızıntı ReLU, softmax, swish'tir. Bu fonksiyonların birbirinden farklı avantaj ve dezavantajları olduğu için modelin gereksinimlerine uygun fonksiyonun seçilmesi önemlidir. Bu çalışmada ReLU, Sigmoid, Softmax aktivasyon fonksiyonlarından bahsedilmiştir.

ReLU aktivasyon fonksiyonu

Çok katmanlı sinir ağlarda kullanılan ReLU (Rectifcied Linear Unit) aktivasyon fonksiyonuna gelen girdi eğer negatifse 0, pozitifse kendi değerini alır [63]. Hangi değerin alınacağıyla ilgili denklem Eş. 2.9'da gösterilmektedir. ReLU aktivasyon fonksiyonu bazı avantajlara sahiptir. Diğer aktivasyon fonksiyonlarından daha hızlıdır çünkü sadece pozitif değerleri dikkate alarak daha az işlem yapar. Ancak sıfır noktasında türevi sıfır olduğu için öğrenme işlemi gerçekleşmiyor demektir. Gradyanların yok olması durumu bu aktivasyon fonksiyonunda hafiflemiş yapıdadır. Şekil 2.13.'te ReLU aktivasyon fonksiyonlarının hangi değerlerde aktifleştiği gösterilmektedir.

$$f(x) = \begin{cases} 0\ için\ x < 0 \\ x\ için\ x >= 0 \end{cases} aralığı[0, \infty) \tag{2.9}$$

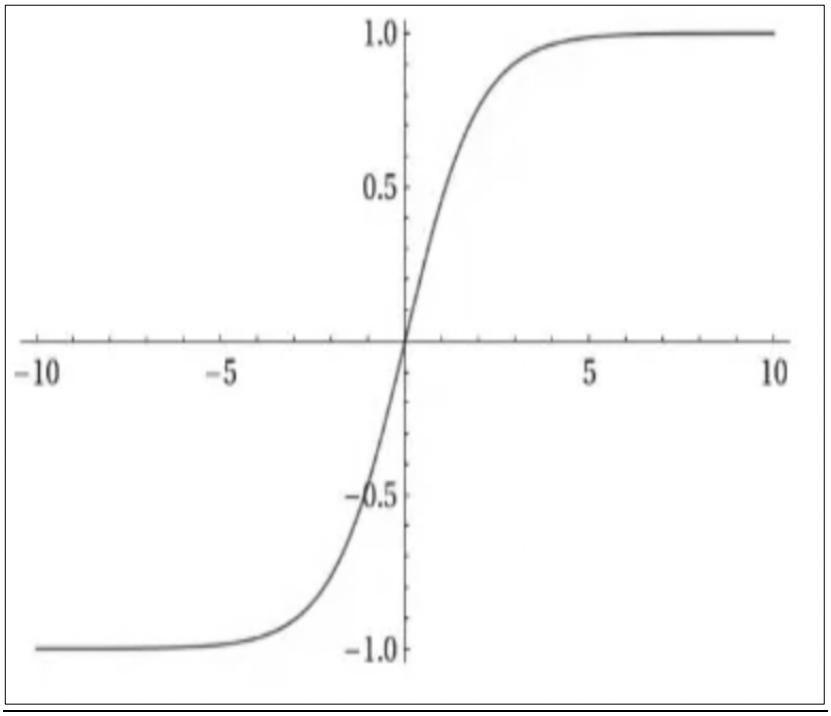


Şekil 2.13. ReLU aktivasyonu fonksiyonu [64]

Softmax aktivasyon fonksiyonu

Softmax aktivasyon fonksiyonu girdi değerlerini eşitlenmiş bir olasılık dağılımına dönüştürerek sınıflar arasında karşılaştırma yapmaktadır [65]. Böylece kıyaslama sonucunda hangi sınıfa ait olduğu belirlenir. [0-1] arasında değerleri normalleştirmek için kullanılmaktadır. Aktivasyon fonksiyonu özellikle çapraz-entropi kaybı ile ağırlıkları güncellerken kullanılmaktadır. Softmax aktivasyon fonksiyonunun hesaplanma formülü Eş. 2.10'da grafiği de Şekil 2.14'te gösterilmektedir.

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^{K} e^{z_i}} \tag{2.10}$$

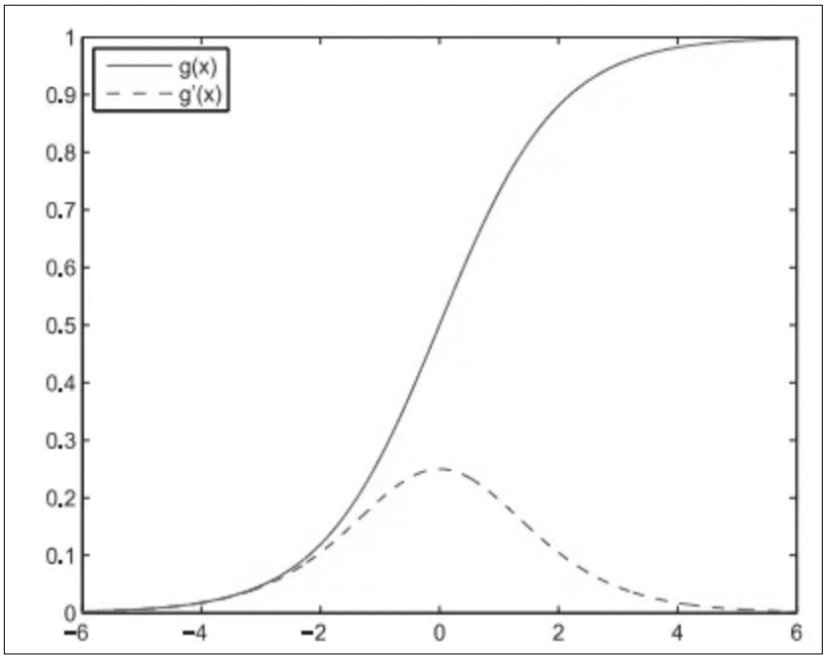


Şekil 2.14. Softmax aktivasyonu fonksiyonu [64]

Sigmoid aktivasyon fonksiyonu

Doğrusal olmayan aktivasyon fonksiyonudur ve ileri beslemeli sinir ağlarında kullanılır. Bu aktivasyon fonksiyonu bir modelin çıktı katmanında kullanılması halinde olasılık tabanlı çıktının tahminini yapar [66]. Çünkü [0,1] arasında değerler üretir. Sigmoid aktivasyon fonksiyonu geri besleme yaparken derin olmayan CNN modellerinde daha başarılı olmaktadır. Sigmoid aktivasyon fonksiyonunun formülü Eş. 2.11'de grafiği de Şekil 2.15'te gösterilmektedir.

$$\sigma = \frac{1}{1+\varepsilon^{-x}} \tag{2.11}$$



Şekil 2.15 Sigmoid aktivasyon fonksiyonu [64]

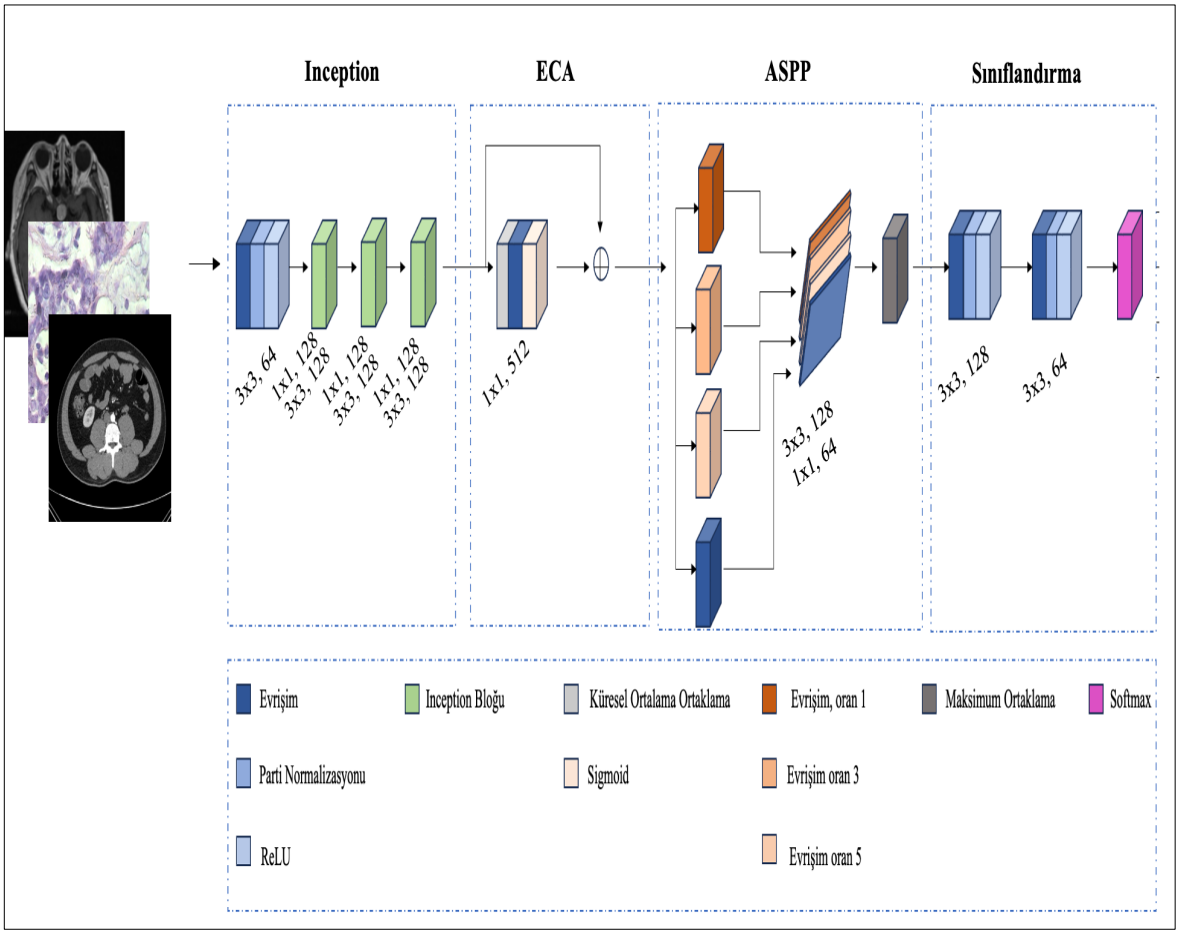
2.4. Tıbbi Görüntüler için Optimize Edilmiş Sinir Ağı

Bu çalışmada, modifiye edilmiş Inception bloğu, ECA bloğu ve ASPP bloğu kullanılarak tıbbi görüntülerin sınıflandırılması için hibrit bir model önerilmektedir. Modelin genel mimarisi Şekil 2.16'da gösterilmektedir. Modelde girdi görüntüsü 3x3'lük evrişim işleminden geçirildikten sonra oluşan özellik haritaları Inception bloğuna girdi olarak verilmektedir. Inception bloğu arka arkaya 3 kez tekrarlanmaktadır. Son Inception bloğundan çıkan özellik haritaları ECA bloğuna girdi olarak verilmektedir. Önce Inception bloklarının kullanılması sonra ise ECA bloğunun kullanılmasının amacı başlangıçta birçok özellik çıkartıp daha sonra önemli olan özelliklere odaklanmaktır. ECA bloğunun ardından ise ASPP blokları kullanılmaktadır. Bu bloğun amacı ise odaklanılan önemli özellikler arasındaki bağlamsal bilgiyi çıkararak daha da önemli özelliklere odaklanmaktır. Başka bir açıdan bakılacak olursa ECA bloğundan gelebilecek önemsiz özellikleri ASPP bloğunda filtreleyerek göz ardı edebilmektir.

ASPP bloğundan sonra özellik haritaları evrişim katmanı, parti normalizasyonu ve ReLU katmanlarına verilir ve bu işlem iki kez tekrarlanır. Bu katmanlardan sonra küresel ortaklama katmanı ve softmax katmanı gelerek sınıflandırma işlemi gerçekleştirilir.

GAP katmanı, her özellik haritasının ortalamasını alarak oluşan vektörü softmax katmanına vermektedir. Aynı zamanda daha az parametre sağlayan, daha düzenli ve genelleştirilmiş temsillerle beslemesine olanak sağlayan avantajlara sahiptir.

Yoğun katman, modelin öğrendiği özellikleri sonuçlarla ilişkilendirerek sınıflandırma işlemini yapmak için kullanılır. Modelde her etiketin olasılık dağılımını hesaplamak ve sınıflandırma yapmak için softmax katmanı kullanılır.

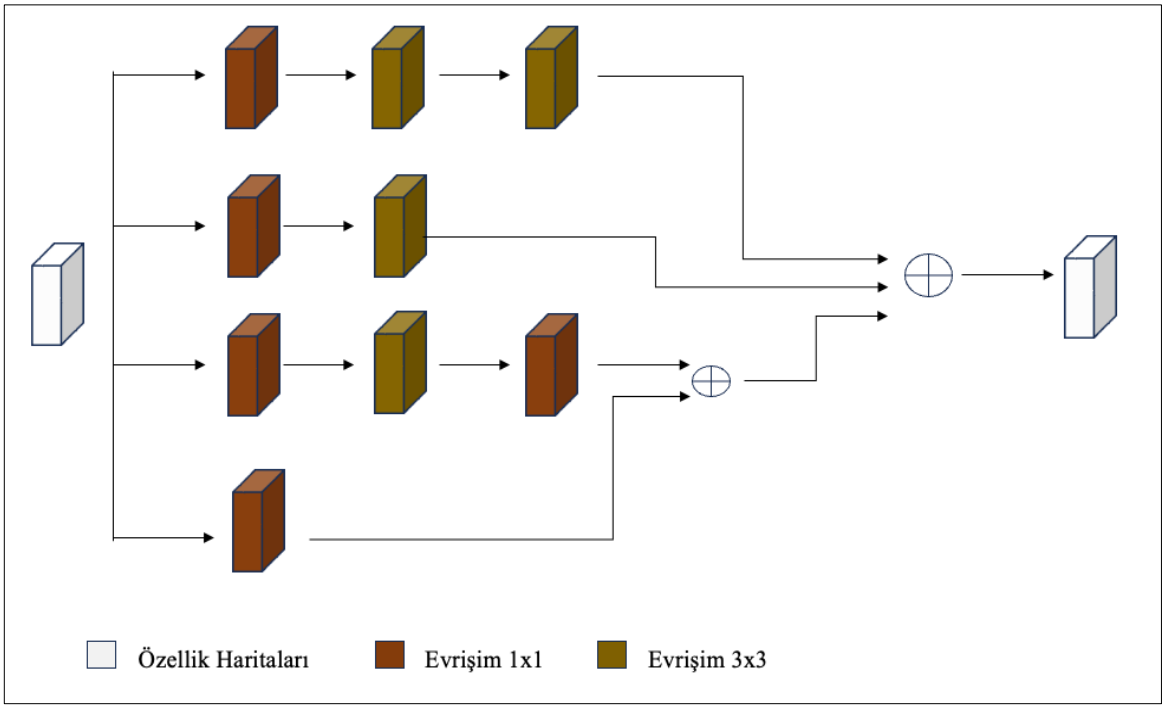


Şekil 2.16. Geliştirilen modelin genel yapısı

2.4.1. Inception bloğu

Inception bloğu özellik çıkarım modülünde daha derin özellikler çıkarmak için değiştirilmiştir. Orijinal Inception bloğundaki ortaklama katmanı kaldırılmış ve yerine 1x1 evrişim katmanı ve 3x3 evrişim katmanı eklenmiştir. Bu şekilde modifiye edildiğinde daha fazla özellik çıkarması sağlanmıştır. Çünkü ortaklama katmanında özellik çıkarımı işlemi gerçekleştirilmez. Bunlara ek olarak 1x1 evrişim + 3x3 evrişim + 1x1 evrişim katmanlarının

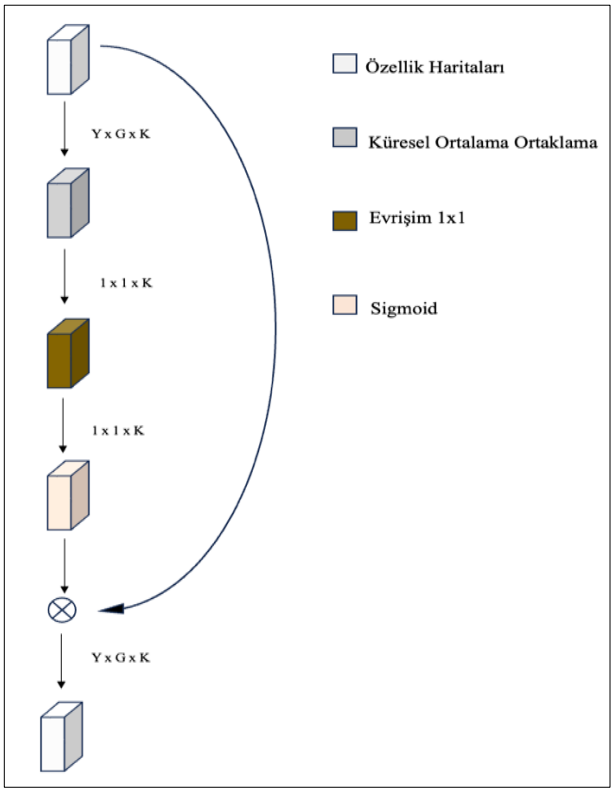
çıktısı 1x1 evrişim katmanının çıktısıyla birbirlerine eklenmiştir. Modifiye edilen Inception bloğu Şekil 2.17.'de gösterilmektedir.



Şekil 2.17. Inception bloğu

2.4.2. ECA bloğu

Modelde ECA bloğu SENet [49] modelinden esinlenilerek kullanılmıştır. ECA bloğunun amacı hesaplama süresini azaltmak, model için önemsiz olabilecek bilgileri göz ardı etmek böylelikle de öğrenme başarısını arttırmaktır. ECA bloğu ortalama ortaklama katmanı, 1x1'lik evrişim katmanı ve sigmoid aktivasyon fonksiyonundan oluşmaktadır. ECA bloğunun yapısı Şekil 2.18'de gösterilmektedir.



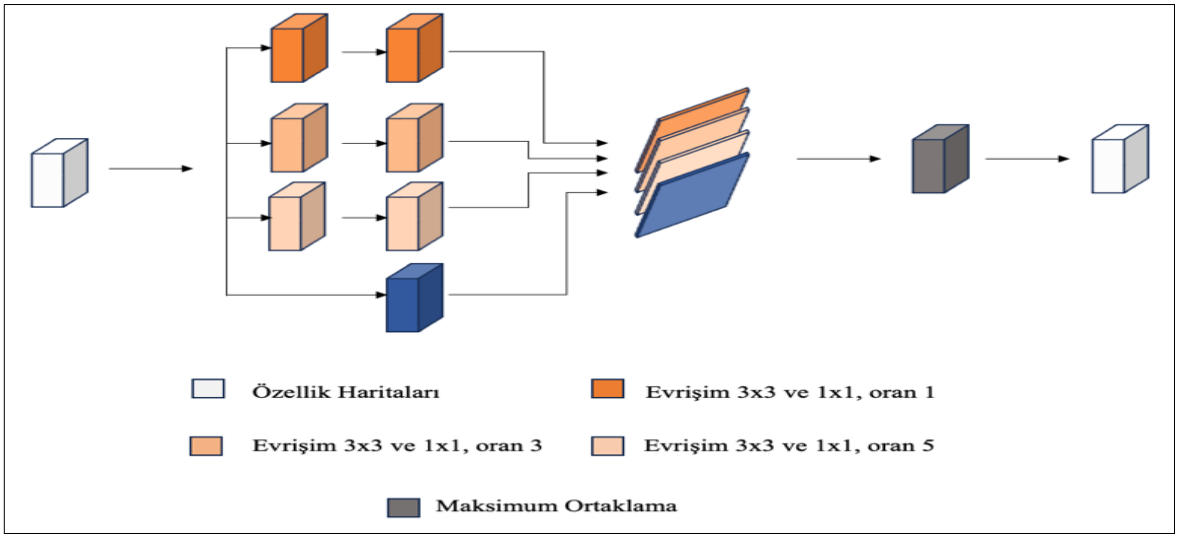
Şekil 2.18. ECA bloğu

Şekil 2.18'de görüldüğü üzere bir önceki katmandan gelen özellik haritaları ECA bloğuna girdi olarak verilmektedir. Bu özellik haritaları ilk önce küresel ortalama ortaklamaya girdi olarak verilmektedir. Küresel ortalama ortaklama katmanının amacı parametre sayısını azaltmak ve özellik haritasını tek bir vektör haline getirmektir. Bu katmanın çıkışında 1x1 vektör oluşur ve çıkan özellikler evrişim katmanına girdi olarak verilmektedir. Evrişim katmanındaki filtre boyutunun 1x1 olması özellik haritasının sayısını ve hesaplama karmaşıklığını azaltmak içindir. Filtre boyutunun 1x1 seçilmesi bir nevi tam bağlantı katmanı işlevi görmesidir. Tam bağlantı katmanından farkı ise evrişim katmanının kullanılmasıyla boyut azalırken öğrenmeye devam edip modelin başarısını arttırmaya çalışmasıdır. Evrişim katmanının çıktısı aktivasyon fonksiyonunun girdisine verilir. Bu bloğa girdi olarak verilen özellik haritaları ile aktivasyon fonksiyonunun çıktısı birleştirilerek geçiş katmanına ve bir sonraki yoğun bloğuna verilir.

2.4.3. Atrous uzamsal piramit ortaklama (ASPP) bloğu

Atrous Uzamsal Piramit Ortaklama [51] bloğu çok ölçekli bağlamsal bilgileri çıkarmak için kullanılır ve umut verici sonuçlar vermiştir. Bu çalışmada tercih edilmesinin nedeni

sınıflandırma görevi için bağlamsal bilgi çıkarımı yaparak başarılı olacağının düşünülmesidir. ASPP bloğundaki atrous evrişimleri normal evrişim katmanından farklı olarak, filtrelerdeki parametreler arasına sıfırlar eklenir. Bu, modeli verimli tutar ve parametre sayısını arttırmadan performansın artmasını sağlar [67] [68]. ASPP bloğunun yapısı Şekil 2.19'da gösterilmektedir.



Şekil 2.19. ASPP bloğu

ASPP bloğu ayrıca tüm evrişim katmanlarında 3x3 ve 1x1 boyutlarında filtreler içerir. Önce 3x3 filtreden geçirilen evrişim katmanları hemen ardından 1x1 filtreden geçirilir. Genişlemiş evrişim elde etmek için genişleme oranları kullanılmış ve bu oranlar sırasıyla 1,3 ve 5 olarak ayarlanmıştır. ASPP bloğundaki tüm evrişim işlemleri genişleme oranlarıyla kullanılmıştır. Sadece bir tanesi normal evrişim işleminden geçirilmiştir. Genişleme oranlarıyla kullanılan evrişim işlemleri seri bir şekilde işlemlerden geçirilmeyip paralel bir yapı göstermektedir. Bu sayede girdi olarak verilen özellik haritalarında farklı bölgelerdeki özelliklere dikkat ederek daha başarılı bilgi çıkarımının gerçekleşmesine imkân sağlamıştır. 3 genişlemiş evrişim ve 1 normal evrişim işlemleri gerçekleştirildikten sonra çıktılar birleştirilerek özellik haritaları oluşturulmuştur. Bir sonraki bloğa girdi olarak verilmiştir.

3. DENEYSEL ÇALIŞMA VE SONUÇLAR

Bu bölümde yapılan deneysel çalışma ve elde edilen sonuçlar hakkında bilgi verilecektir.

3.1. Deneysel Çalışma

Deneysel çalışmalar, Google Colab Pro üzerinde gerçekleştirilmiştir. Google Colab kullanıcılara GPU sağlayan bir platformdur ve kullanıcıların ihtiyaçlarına göre üç farklı seçeneği mevcuttur. Bu seçenekler GPU kaynak sınırına, daha yüksek bellek kapasitesine, çalışma süresine, arka planda yürütme imkanına göre değişmektedir. Google Colab Pro seçeneğinde 83,5 GB Sistem RAM, 40 GB GPU RAM, 166,8 GB Disk sunulmuştur ve çalışmalar bu kaynak sınırları ile gerçekleştirilmiştir. Geliştirilen model için kullanılan programlama dili Python'dır. CNN modellerinin oluşturulması için Tensorflow, Keras kütüphaneleri kullanılmıştır.

Eğitim ve test işlemleri yapılırken veri dağılımı için 10-kat çapraz doğrulama kullanılarak aşırı öğrenmenin önüne geçilmesi planlanmıştır. Seçilen diğer hiperparametreler Çizelge 3.1.'de verilmiştir.

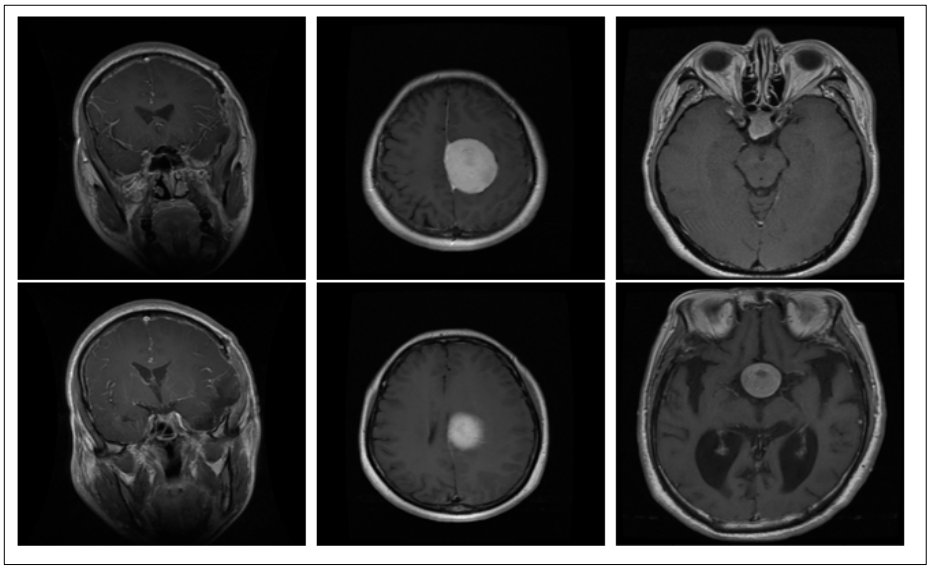
Çizelge 3.1. Çalışmada kullanılan hiperparametre bilgileri

Parametreler	Değerler
Epoch	30
k-kat çapraz doğrulama	10
Küme boyutu	32
Optimizasyon	Adam
Kayıp değeri	Kategorik Çapraz Entropi
Öğrenme oranı	0.001

3.1.1. Veri kümeleri

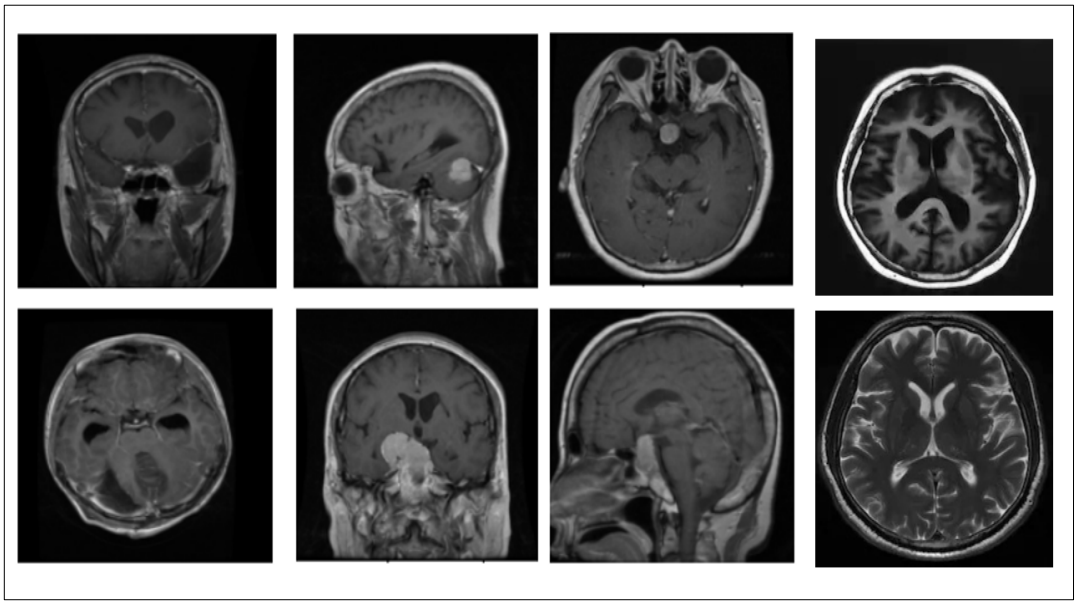
Model eğitimi ve testi için dört farklı veri kümesi kullanılmıştır. Veri kümeleri, açık kaynaklı beyin, böbrek ve meme kanseri görüntülerinden oluşmaktadır, ayrıca farklı çözünürlüklere sahiptir.

Figshare [55] adında ilk veri kümesi, üç beyin MR türüne sahip T1 ağırlıklı görüntülerden oluşmaktadır. MR görüntüleri 233 hastadan alınmış ve lezyonlu bölgeler hekimler tarafından tespit edilmiştir. Bu veri kümesindeki görüntüler .mat dosya uzantılıdır ve görüntü boyutları 512x512x1'dir. Veri kümesi sık rastlanan beyin tümörünün üç türünden oluşturulmuştur. Bu üç tümör türü; hipofiz, gliom ve meningiom'dur. 1426 gliom görüntüsü, 708 meningiom görüntüsü ve 930 hipofiz görüntüsü vardır. Toplamda 3064 MR görüntüsünden oluşmaktadır. Tümör türlerine ilişkin görüntüler Resim 3.1'de gösterilmektedir.



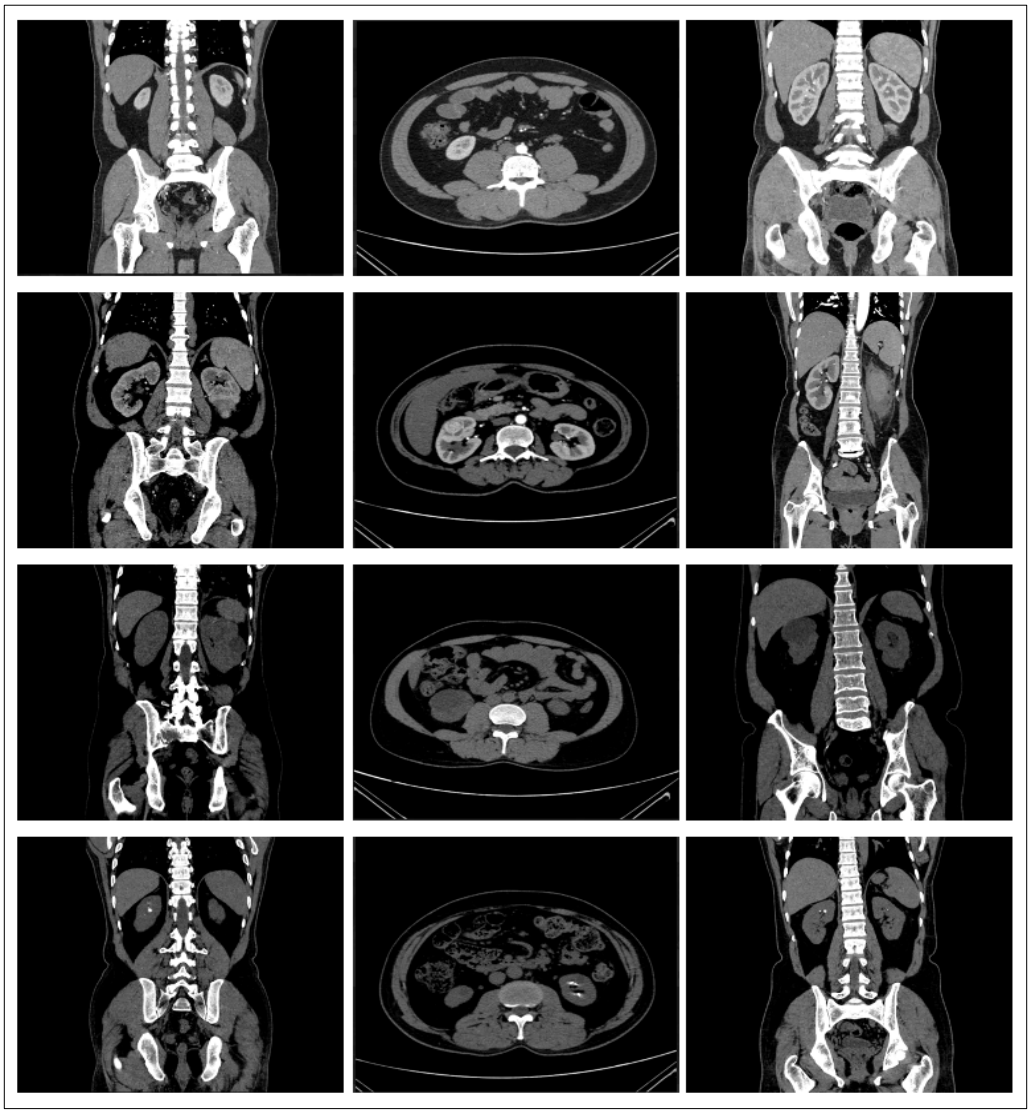
Resim 3.1. Figshare veri kümesi sırasıyla gliom, meningiom ve hipofiz

BT-large-4C [69] adındaki ikinci veri kümesi, dört beyin tümör türüne ait MR görüntülerinden oluşmaktadır. Bu görüntüler gliom, meningiom, hipofiz tümör türleri ve normal (tümör olmayan) etiketleri içermektedir. Veri kümesinde 926 gliom görüntüsü, 923 meningiom görüntüsü, 928 hipofiz görüntüsü ve 500 sağlıklı görüntüsü mevcuttur. Toplamda 3277 MR görüntüsü vardır. Ayrıca görüntüler .jpg formatındadır. BT-large-4C veri kümesindeki etiketlere ilişkin görüntüler Resim 3.2'de gösterilmektedir.



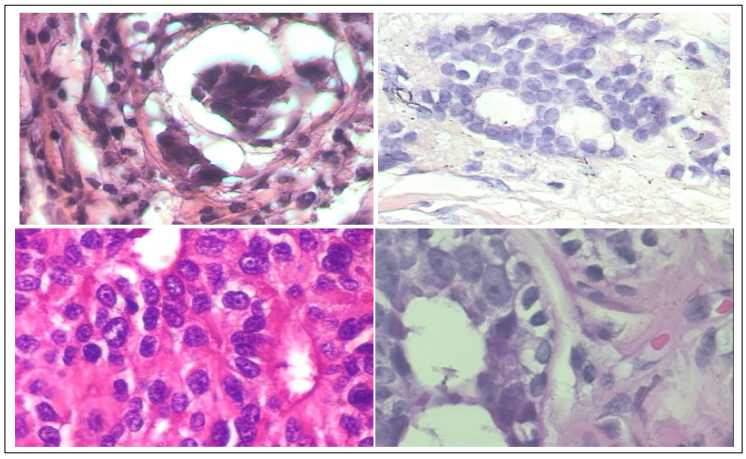
Resim 3.2. BT-large-4C veri kümesi sırasıyla gliom, meningiom, hipofiz ve normal

BT Kidney [70] üçüncü veri kümesidir. BT Kidney veri kümesi Dhaka Bangladesh'deki Dhaka Central International Medical College and Hospital (DCIMCH)'dan PACS (Picture archiving and communication system) aracılığıyla toplanmıştır. Tümör, normal (tümör olmayan), taş ve kist olmak üzere dört etikete sahip görüntülerden oluşmaktadır. Ayrıca görüntüler sagital-aksiyal kesitlerden, kontrastlı-kontrastsız görüntülemelerden, abdomen-ürogram bölgelerinden alınmıştır. Veri kümesi toplamda 12446 görüntüye sahiptir. Normal etiketine sahip 5077 BT görüntüsü, tümör etiketine sahip 2283 BT görüntüsü, kist etiketine sahip 3709 BT görüntüsü ve taş etiketine sahip 1377 BT görüntüsü vardır, ayrıca görüntüler .jpg formatındadır. BT Kidney veri kümesindeki etiketlere ilişkin görüntüler Resim 3.3'te gösterilmektedir.



Resim 3.3. BT Kidney veri kümesi. Satır 1 “normal”, 2 “tümör”, 3 “kist”, 4 “taş”

BreaKHis [71] veri kümesi meme tümörü histopatolojik görüntülerden oluşmaktadır. Veri kümesi iyi ve kötü huylu meme tümörü olarak iki sınıftan oluşmaktadır. 2014 yılında Brezilya’daki P&D Laboratuvarında klinik çalışmalarla 82 hastadan toplanmış ve açık kaynak halinde erişime sunulmuştur. Görüntüler .png formatındadır. 4x, 10x, 100x, 200x ve 400x büyütme faktörleri kullanılarak oluşturulan veri kümesinde toplam 7909 görüntü bulunmaktadır. 24 hastaya ait olan 2480 iyi huylu tümör görüntüsü ve 58 hastaya ait 5429 kötü huylu tümör görüntüsü mevcuttur. 400x büyütme faktöründe toplamda 1820 görüntü vardır ve bunların 588’i iyi huylu, 1232’si kötü huyludur. Görüntüler RGB’den oluşan 3 kanala, her kanalda 8 bit derinliğe sahiptir ve 700x460 piksel çözünürlüğü vardır. BreaKHis veri kümesindeki 400X büyütme faktörlü tümörlere ilişkin görüntüler Resim 3.4’te gösterilmektedir.



Resim 3.4. BreaKHis veri kümesi soldaki kötü huylu, sağdaki iyi huylu meme tümörü

3.1.2. Değerlendirme metrikleri

Model değerlendirme metrikleri modelin performansının ne kadar başarılı olduğunu anlamak için kullanılan sayısal sonuçlardır. Model değerlendirme metriklerinin hesaplanması için modelin yaptığı tahminlerin ve gerçek değerlerin bilinmesi gerekmektedir. Bu gerçek değerler ile tahmin edilen değerleri karmaşıklık matrisi ile göstermek anlaşılmayı kolaylaştırmaktadır. Karmaşıklık matrisi modelin ne kadar iyi bir performans gösterdiğini tablo olarak vermektedir. Genel tablo yapısı Çizelge 3.2.'de verilmektedir. Karmaşıklık matrisinde doğru pozitif, yanlış pozitif, doğru negatif ve yanlış negatif değerleri vardır. Bu değerler modelin eğitimi sırasında tahmin ettiği değerlerin gerçek değerlerle karşılaştırılmasının sayısal karşılıklarıdır [72]. Ayrıca karmaşıklık matrisi doğruluk, geri çağırma, kesinlik, f1-skor, MCC gibi performans metriklerinin hesaplanmasını da sağlamaktadır.

Doğru pozitif, gerçek değeri doğru olan ve model tarafından doğru olarak tahmin edilen örnek sayısıdır.

Yanlış pozitif, gerçek değeri yanlış olan ve model tarafından doğru olarak tahmin edilen örnek sayısıdır.

Doğru negatif, gerçek değeri yanlış olan ve model tarafından yanlış olarak tahmin edilen örnek sayısıdır.

Yanlış negatif, gerçek değeri doğru olan ve model tarafından yanlış olarak tahmin edilen örnek sayısıdır.

Çizelge 3.2. Karmaşıklık matrisinin gösterimi

Tahmin / Gerçek	Pozitif	Negatif
Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Doğruluk

Modelin bütün durumlarda ne kadar örneği doğru sınıflandırdığını veren yüzdelik bir sonuçtur [73]. Aşağıdaki Eş. 3.1'de doğruluk metriğinin nasıl hesaplandığı gösterilmektedir.

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \tag{3.1}$$

Hassasiyet

Modelin gerçekte pozitif olan değerleri ile ilgili tahmin yapılması durumunda kaç tanesinin doğru pozitif olduğunu bulmayı hedefler [73]. Aşağıdaki Eş. 3.2'de hassasiyet metriğinin nasıl hesaplandığı gösterilmektedir.

$$Hassasiyet = \frac{DP}{DP+YN} \tag{3.2}$$

Kesinlik

Model de pozitif olarak tahmin edilen değerlerin gerçekte kaç tanesinin pozitif olduğunu bulmayı hedefler [73]. Aşağıdaki Eş. 3.3'te kesinlik metriğinin nasıl hesaplandığı gösterilmektedir.

$$Kesinlik = \frac{DP}{DP+YP} \tag{3.3}$$

F1-skor

F1-skor, kesinlik ve geri çağırmanın harmonik ortalamasıdır. Yani modelin kesinliğinin ve sağlamlığının ölçüsüdür de denilebilir [73]. F1-skor da kesinlik ve geri çağırmanın değerleri ne kadar düşük olursa F1-skor başarısı da o kadar yüksek olur. Aşağıdaki Eş. 3.4'te F1-skor metriğinin nasıl hesaplandığı gösterilmektedir.

$$F1 - skor = \frac{2 * Kesinlik * Hassasiyet}{Kesinlik + Hassasiyet} \tag{3.4}$$

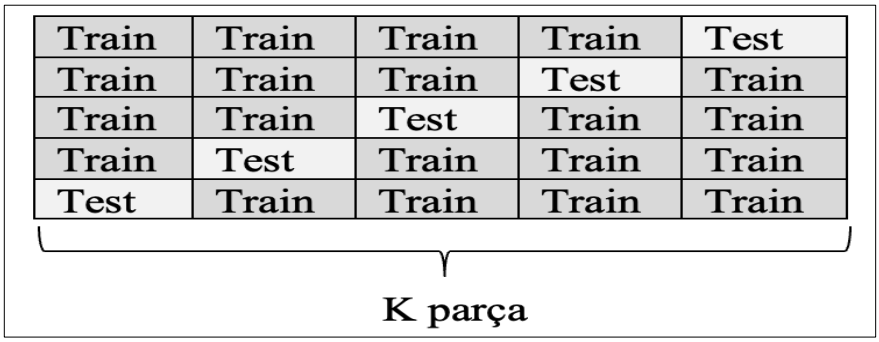
MCC (Matthews Korelasyon Katsayısı)

Sınıflandırma modellerinin performans değerlendirilmesinde en önemli metriklerden birisidir. Dengesiz veri kümelerinde modelin başarısını ölçmek için kullanılır. MCC değeri -1 ile +1 arasında sonuç vermektedir. +1'e yakın olduğunda modelin başarısı iyi, -1'e yakın olduğunda modelin başarısını kötü olarak yorumlanır [74]. Aşağıdaki Eş. 3.5'te MCC metriğinin nasıl hesaplandığı gösterilmektedir.

$$MCC = \frac{DN\ x\ DP - YN\ x\ YP}{\sqrt{(DP+YP)\ x\ (DP+YN)\ x\ (DN+YP)\ x\ (DN+YN)}} \tag{3.5}$$

K-kat çapraz doğrulama

Veri kümesinin k parçaya bölündüğünü ifade etmektedir [75]. K parçadan bir tanesi test için kullanılırken geri kalan k-1 parça eğitim için kullanılmaktadır. Bu sayede işlemler tekrarlanarak her parça hem test hem de eğitim için kullanılmaktadır. Şekil 3.1'de k-kat çaprazlama yöntemi için k'nın 5 seçilmesi durumunda oluşan eğitim ve test kümelerinin nasıl ayrıldığı gösterilmektedir.

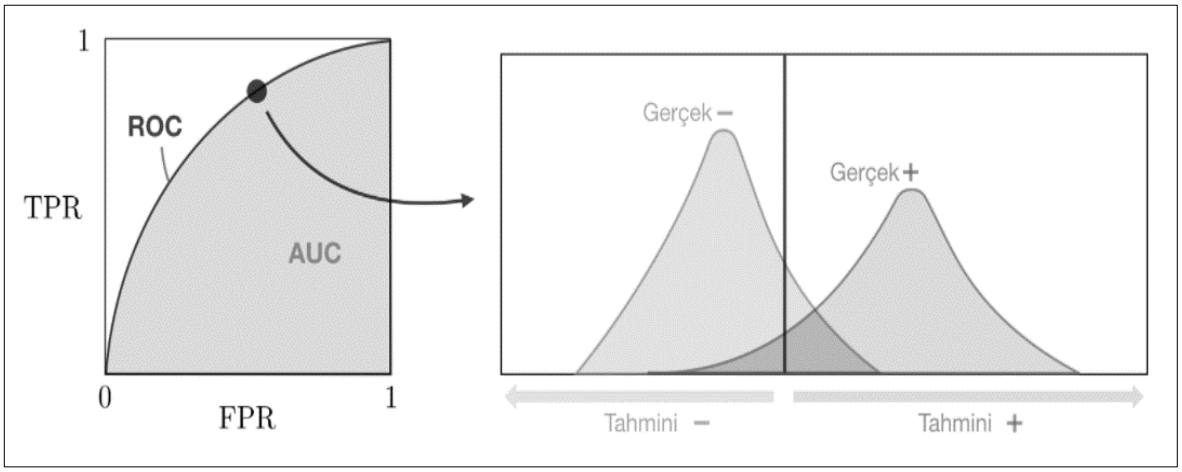


Şekil 3.1. K-kat çapraz doğrulama

ROC / AUC (Receiver Operating Characteristic / Area Under the Curve)

Sınıflandırma modellerinin performans değerlendirilmesinde kullanılan metriklerden biridir. ROC bir olasılık eğrisidir ve grafiksel olarak gösterilir. F1-skor metriğine benzer ancak F1-skor'daki özgüllük ve geri çağırma yerine burada gerçek pozitif oranı (TPR) ve yanlış pozitif oranı (FPR) olarak kullanılmaktadır. TPR, doğru pozitif değerlerin toplam pozitif değerler içindeki oranı ile bulunur. FPR, YP değerlerin toplam negatif değerler içindeki oranı ile bulunur. Eş. 3.6'da matematiksel ifadeleri gösterilmektedir. Şekil 3.2'de ROC/AUC eğrilerinin gösterimi mevcuttur. ROC eğrisi belirlenen eşik değerinde TPR ile FPR arasındaki ilişkiyi gösterir. AUC ise ROC eğrisinin altında kalan alandır. ROC eğrisi modellerin sınıflandırma yaparken ne kadar iyi bir ayrım yapabildiğini ifade eder. ROC/AUC eğrisi 1'e yaklaştıkça modelin performansı da artmaktadır [76]. İyi bir eşik değerinin seçilmesi performansı etkileyen bir durumdur. Örneğin yüksek bir eşik değeri seçildiğinde yanlış pozitif sayılarını ve gerçek pozitif sayılarını azaltır ya da düşük bir eşik değeri seçildiğinde yanlış pozitif sayılarını ve gerçek pozitif sayılarını artırır [73].

$$TPR = \frac{DP}{DP+YN} \text{ ve } FPR = \frac{YP}{YP+DN} \tag{3.6}$$



Şekil 3.2. ROC-AUC eğrisi

3.2. Deneysel Sonuçlar

Önerilen model dört farklı veri kümesi üzerinde eğitilmiş ve test edilmiştir. Tüm veri kümelerinde tabakalanmış 10-katlı çapraz doğrulama (stratified k-fold cross validation) yöntemi kullanılmıştır. Bu sayede, her bir etikete sahip görüntüler her katmanda eşit sayıda paylaşılmıştır. Veri kümelerinde önişleme adımı uygulanmamıştır, ayrıca görüntüler 224x224 çözünürlüğe sahip olacak şekilde yeniden boyutlandırılmıştır. Kayıp fonksiyonu olarak kategorik çapraz entropi kullanılmıştır. Bu bölümde verilen kayıp grafikleri tabakalanmış 10-katlı çapraz doğrulama ile elde edilen kayıp değerlerinin ortalaması alınarak elde edilmiştir.

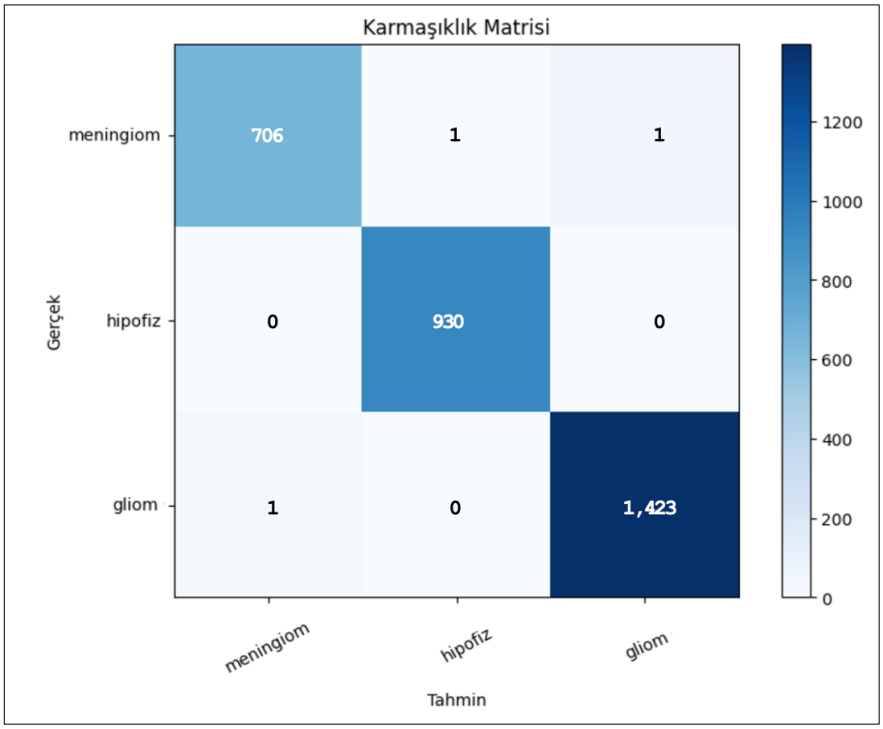
Kullanılan ilk veri kümesi Figshare'dir. Bu veri kümesinde üç farklı beyin tümörü türü etiketlidir. Bunlar meningiom, gliom, hipofiz'dir. Görüntüler 512x512 çözünürlüğe sahiptir ve .mat uzantılıdır. Görüntüler modele girdi olarak verilmeden önce .jpg formatına çevrilmiştir.

Kullanılan ikinci veri kümesi BT-large-4C'dir. Bu veri kümesinde üç farklı beyin tümörü türü ile normal beyin görüntüleri etiketlidir. Bunlar meningiom, gliom, hipofiz tümör türleri ve normal beyin (tümör olmayan) görüntülerinden oluşmaktadır.

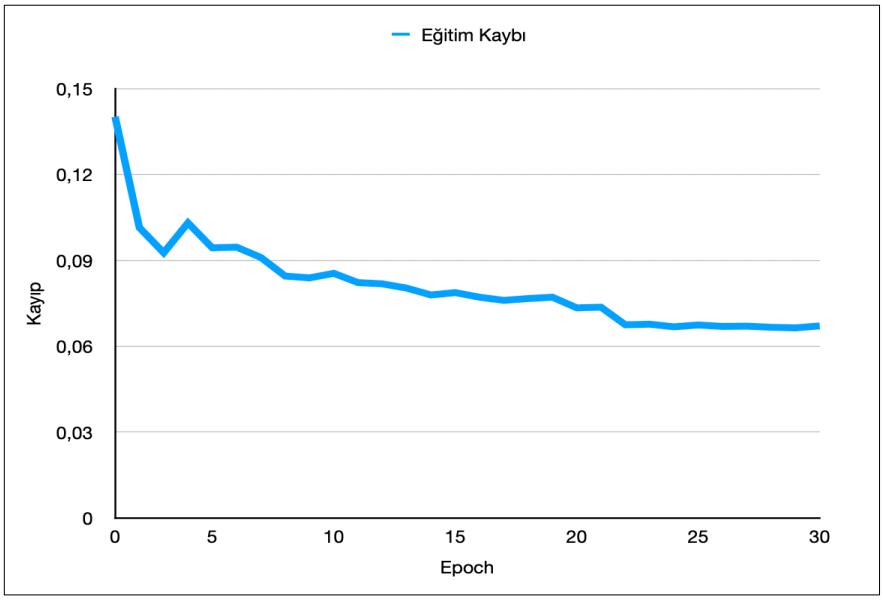
Kullanılan üçüncü veri kümesi BT Kidney'dir. Bu veri kümesinde normal, tümör, kist ve taş olmak üzere dört etikete ait görüntüler mevcuttur.

Kullanılan dördüncü veri kümesi BreaKHis'tir. Bu veri kümesinde farklı görüntüleme boyutları vardır. Ancak 400x görüntüleme boyutuna sahip olan görüntüler ile çalışma yapılmıştır. Bu kapsam da iyi huylu ve kötü huylu olmak üzere iki etikete ait görüntüler mevcuttur.

Önerilen yöntemin Figshare veri kümesinde eğitilmesi ve test edilmesi sonucunda elde edilen karmaşıklık matrisi Şekil 3.3'te verilmiştir. Karmaşıklık matrisi sınıflandırma işleminin nasıl sonuçlandığı hakkında bilgi vermektedir. Matris incelendiğinde modelin hangi etiketleri ne kadar doğru tahmin ettiği veya hangi etiketlerde yanlış tahmin ettiği anlaşılmaktadır. Şekil 3.3 incelendiğinde en iyi tahmin yapılan etiketin hipofiz olduğu görülmektedir. Modelin hipofiz olarak tahmin ettiği değerlerin gerçekte de hipofiz etiketine sahip olduğu görülmektedir. Diğer bir deyişle modelin hipofiz görüntülerinin hepsini %100 doğrulukla etiketlemiştir. 1 görüntünün meningiom olarak tahmin edildiği ancak gerçekte gliom etiketine sahip olduğu matrise bakılarak anlaşılmaktadır. Meningiom etiketine sahip 2 görüntüden birinin hipofiz diğerinin ise gliom olarak yanlış tahminde bulunduğu yine karmaşıklık matrisine bakılarak anlaşılmaktadır.



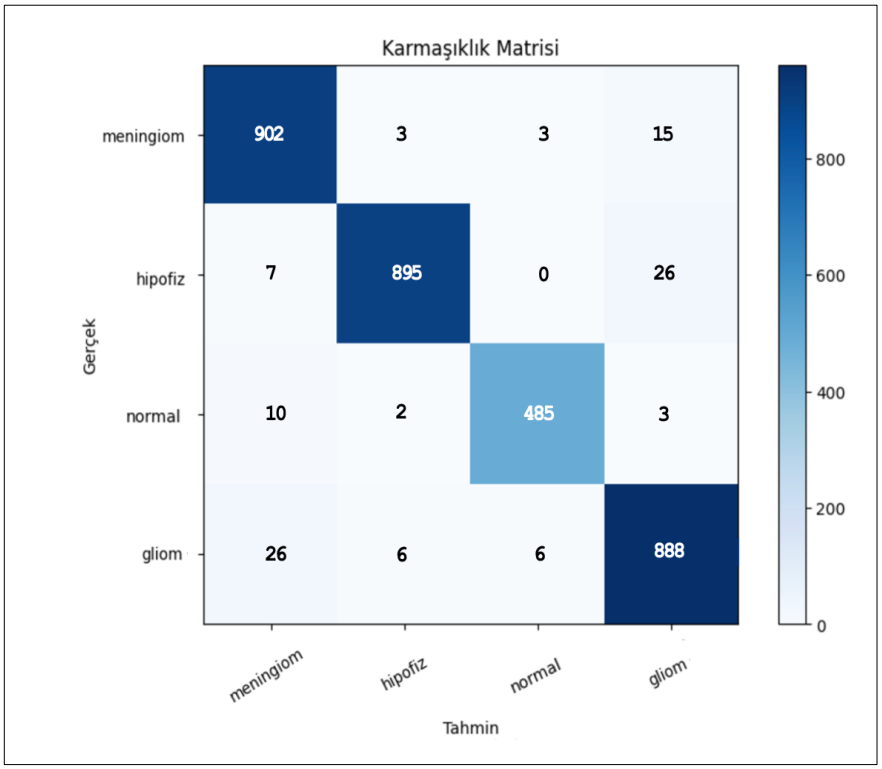
Şekil 3.3. Figshare veri kümesinin karmaşıklık matrisi



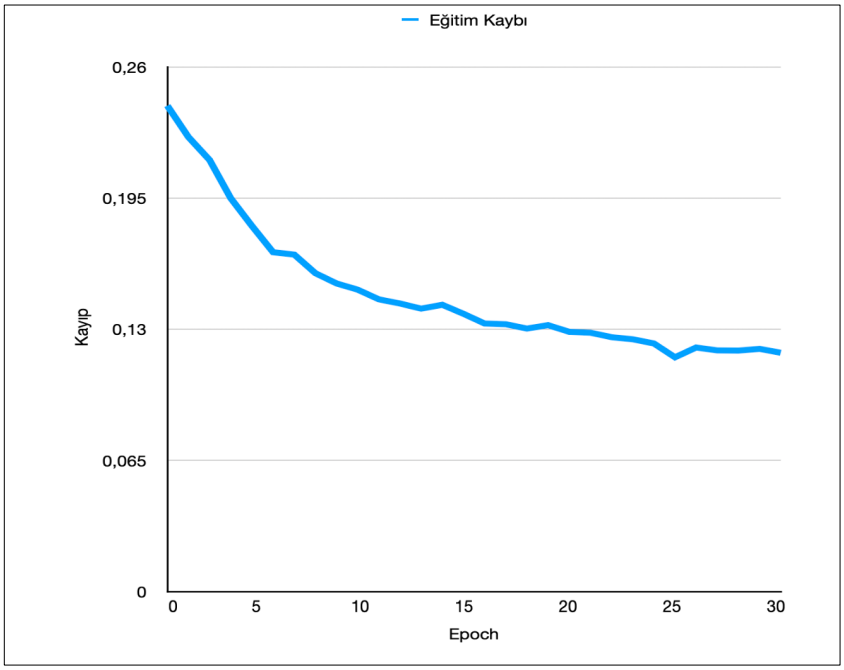
Şekil 3.4. Figshare veri kümesinin kayıp grafiği

Model eğitilirken kayıp oranı da dikkate alınır. Kayıp oranına bakılarak modelin yaptığı tahminlerin gerçek değerlerden ne kadar uzak olduğu bilgisi çıkarılır. Şekil 3.4'te kayıp grafiği verilmiştir. Grafiğe bakıldığında her bir epoch'da genel olarak gittikçe düşen bir kayıp eğrisi görülmektedir. Küçük dalgalanmalar olsa da ani bir yükselme ya da düşme olmadığı için eğitimin başarısız olmadığı yorumu çıkarılabilir. İlk epoch'larda 0,14'lerde başlayan değerler 30. epoch'a kadar 0,07 değerlerine kadar düştüğü görülmektedir.

Önerilen yöntemin BT-large-4C veri kümesinde eğitilmesi ve test edilmesi sonucunda elde edilen karmaşıklık matrisi Şekil 3.5'te verilmiştir. Şekil 3.5 incelendiğinde normal etiketine sahip görüntülerin diğerlerinden daha başarılı tahmin edildiği bilgisi matrise bakıldığında görülmektedir. Model gerçekte normal etiketine sahip olan görüntülerden 10'unu meningiom, 2'sini hipofiz ve 3'ünü gliom olarak yanlış tahminde bulunduğu görülmektedir. Diğerlerinden daha fazla yanlış tahminde bulunulan etiketin ise gliom olduğu yine matrise bakılarak anlaşılmaktadır.



Şekil 3.5. BT-large-4C veri kümesinin karmaşıklık matrisi

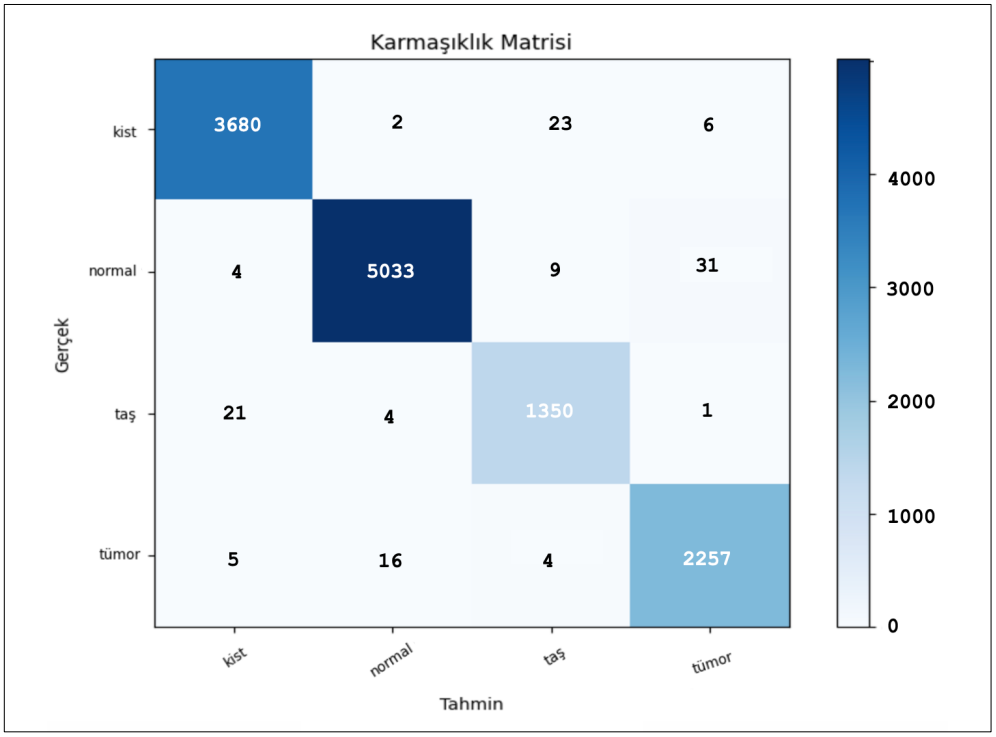


Şekil 3.6. BT-large-4C veri kümesinin kayıp grafiği

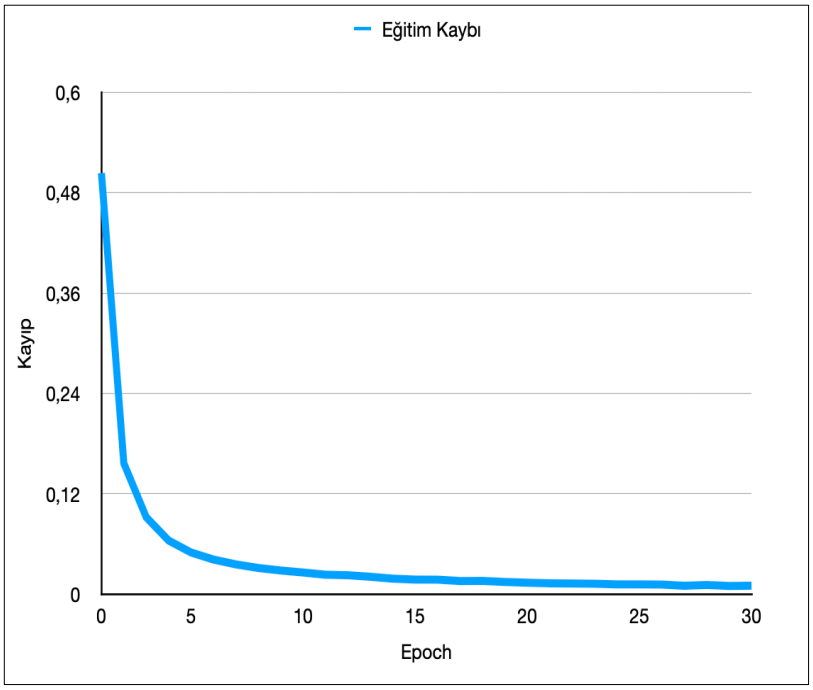
Şekil 3.6.'da kayıp grafiği verilmiştir. Grafiğe bakıldığında her bir epoch'da genel olarak gittikçe düşen bir kayıp eğrisi görülmektedir. Eğitim ilerledikçe kayıp değerinin genellikle azaldığı ve modelin daha iyi tahmin yaptığı bilgisi grafikten anlaşılabilmektedir. İlk

epoch'larda 0,22 olarak hesaplanan kayıp değeri 30. epoch'lara ilerledikçe 0,11 değerlerine düştüğü görülmektedir. Ayrıca modelin 26. epoch'dan sonra dalgalanmasının en az olduğu bölge olması ve optimal değere ulaşmaya başlaması da grafikten çıkarılabilmektedir.

Önerilen yöntemin BT Kidney veri kümesinde eğitilmesi ve test edilmesi sonucunda elde edilen karmaşıklık matrisi Şekil 3.7'de verilmiştir. Şekil 3.7 incelendiğinde tümör etiketine sahip görüntülerin diğerlerinden daha başarılı tahmin edildiği bilgisi matrise bakıldığında görülmektedir. Model gerçekte tümör etiketine sahip olan görüntülerden 5'ini kist, 16'sını normal ve 4'ünü taş olarak yanlış tahmin ettiği görülmektedir. Normal etiketine sahip görüntülerin ise diğer etiketlere sahip görüntülerden daha fazla yanlış tahminde bulunduğu bilgisi matrise bakılarak anlaşılmaktadır. Ayrıca tek başına değerlendirildiğinde normal etiketine sahip olan 31 görüntünün tümör olarak tahmin edildiği görülmüştür. Bunu kist olması gerekirken taş olarak tahmin eden 23 görüntü ve taş olması gerekirken kist olarak tahmin eden 21 görüntü takip etmektedir.



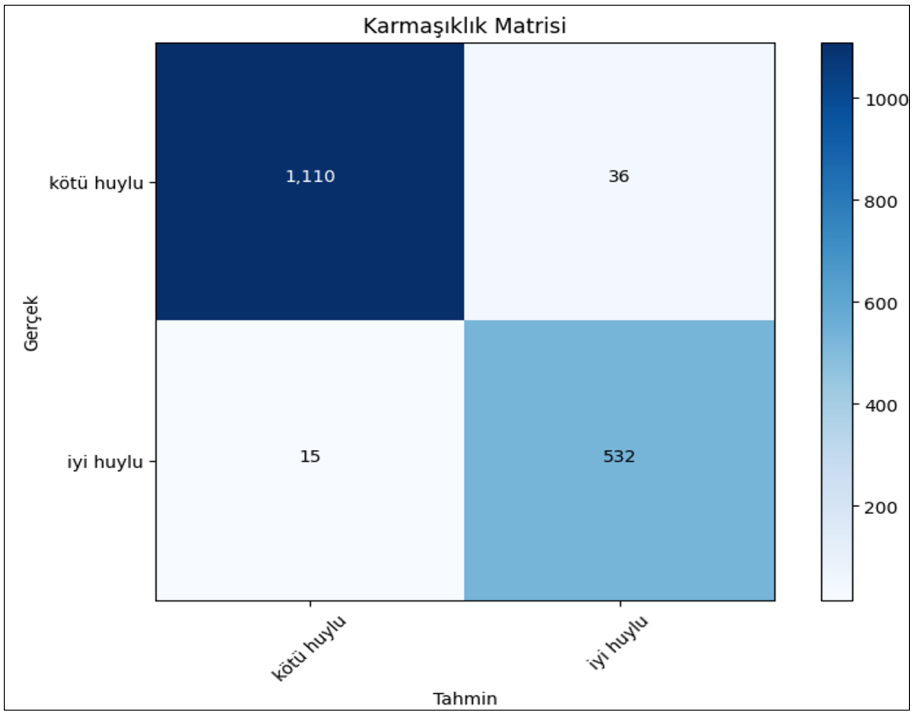
Şekil 3.7. BT Kidney veri kümesinin karmaşıklık matrisi



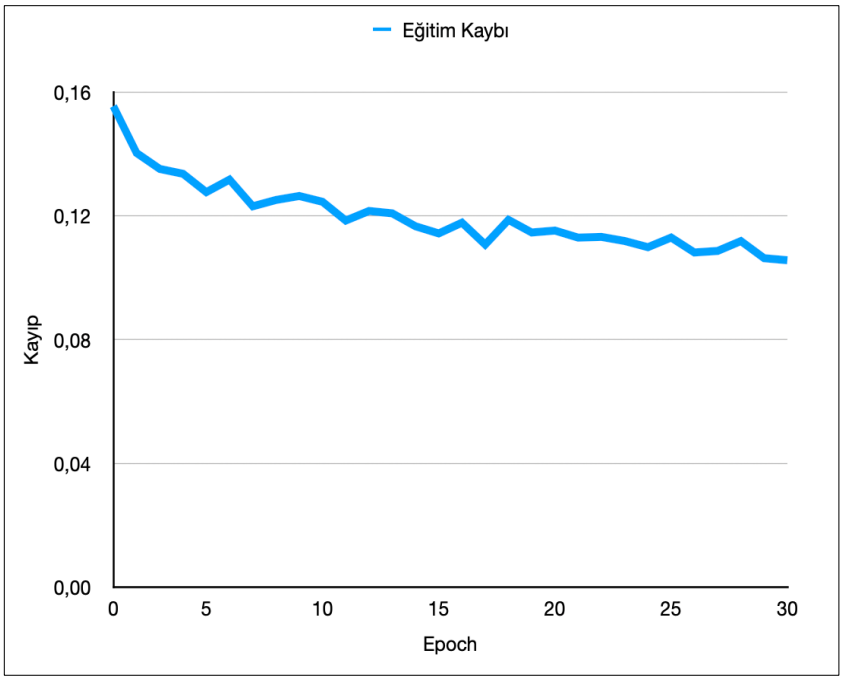
Şekil 3.8. BT Kidney veri kümesinin kayıp grafiği

Şekil 3.8.'de kayıp grafiği verilmektedir. 0,5 kayıp değeriyle başlayan grafik 30 epoch sonunda 0,01 değerlerine kadar düşmüştür. Grafiğe bakıldığında her bir epoch'da genel olarak gittikçe düşen bir kayıp eğrisi görülmektedir. Ayrıca 4. epoch'a bakıldığında bir kırılma olduğu ve optimal değere yaklaşıldığı görülmektedir. Diğer bir deyişle modelin kabul edilebilir bir seviyede kayıp değerine sahip olması nedeniyle genelleme yapabildiği bilgisi söylenebilir.

Önerilen yöntemin BreaKHis veri kümesinde eğitilmiş ve test edilmiştir. Yapılan tahminlerin doğru veya yanlış olduğu bilgisi Şekil 3.9'da karmaşıklık matrisinde gösterilmektedir. Matrise bakıldığında 36'sının kötü huylu iken iyi huylu olarak, 15'inin de iyi huylu iken kötü huylu olarak yanlış tahminde bulunduğu görülmektedir. Modelin iyi huylu tümörü tahmin etme de kötü huyludan daha başarılı olduğu söylenebilir.



Şekil 3.9. BreakHis veri kümesinin karmaşıklık matrisi



Şekil 3.10. BreaKHis veri kümesinin kayıp grafiği

Şekil 3.10'da kayıp grafiği verilmektedir. Grafiğe bakıldığında dalgalanmalı bir yapıda olduğu görülse de ani bir düşüş veya yükseliş yoktur. Genel olarak gittikçe düşen bir kayıp eğrisi görülmektedir.

Çalışmadaki blokların etkili bir şekilde çalıştığını ispatlamak amacıyla Figshare, BT-large-4C, BT Kidney ve BreaKHis veri kümeleri üzerinde ablasyon çalışması yapılmıştır. Bu ablasyon çalışmasında model üç farklı şekilde değerlendirilmiştir. İlk durumda modifiye edilmiş Inception bloğunu modele dahil etmeden ECA bloğu ve ASPP bloğu kullanılmıştır. Bu durumda model veri kümeleri üzerinde eğitildiğinde başarılı bir öğrenme işlemini gerçekleştiremediği gözlemlenmiştir. Öğrenme işlemini gerçekleştirememesinin nedeni olarak çok fazla özellik çıkarımı olmadan ECA bloğuna verilmesidir. Çünkü ECA bloğunda özellik çıkarma işlemi gerçekleşmeyip var olan özellik haritalarında önemli özelliklere odaklanma amacı taşımaktadır.

İkinci durumda ECA bloğunu dahil etmeden modifiye edilmiş Inception bloğu ile ASPP bloğunu kullanılmıştır. Bu durumda modelin ilk çalışmaya göre daha iyi sonuç verdiği gözlemlemiştir. Daha başarılı olmasının nedeni özellik haritalarının yeterince çıkarılmasıdır. Bu çalışmada ECA bloğu olmasa dahi ASPP bloğunda özellik çıkarımı ve seçimi olduğu için başarının çok düşmediği gözlemlenmiştir.

Üçüncü durumda ASPP bloğunu dahil etmeden modifiye edilmiş Inception bloğu ile ECA bloğunu kullanılmıştır. Bu durumda model ikinci ablasyon çalışmasında elde edilen değerlerle paralel bir sonuç verdiği gözlemlenmiştir. İkinci çalışmaya göre biraz daha başarılı olduğu istatistiksel sonuçlarda görülmektedir.

Bu üç durumda Figshare veri kümesi için elde edilen sonuç ile bütün blokların olduğu sonuçlar Çizelge 3.3.'te gösterilmektedir.

Çizelge 3.3. Figshare veri kümesi üzerinde yapılan ablasyon çalışmasıyla blokların verimliliğinin karşılaştırılması

Bloklar	Doğruluk	Kesinlik	Hassasiyet	F1-skor
ECA + ASPP	%75,8	%75,2	%76	%75,78
Modifiye edilmiş Inception + ASPP	%95,6	%96	%96,7	%96,2
Modifiye edilmiş Inception + ECA	%95,53	%95,3	%95	%95,3
Modifiye edilmiş Inception + ECA + ASPP	%99,84	%99,89	%99,88	%99,89

BT-large-4C veri kümesi için elde edilen sonuç ile bütün blokların olduğu sonuçlar Çizelge 3.4.'te gösterilmektedir.

Çizelge 3.4. BT-large-4C veri kümesi üzerinde yapılan ablasyon çalışmasıyla blokların verimliliğinin karşılaştırılması

Bloklar	Doğruluk	Kesinlik	Hassasiyet	F1-skor
ECA + ASPP	%71,08	%73,72	%70,95	%72,89
Modifiye edilmiş Inception + ASPP	%94,60	%96,53	%95,64	%96,1
Modifiye edilmiş Inception + ECA	%92,39	%95,59	%95,99	%95,7
Modifiye edilmiş Inception + ECA + ASPP	%98,05	%96,92	%96,76	%96,75

BT Kidney veri kümesi için elde edilen sonuç ile bütün blokların olduğu sonuçlar Çizelge 3.5.'te gösterilmektedir.

Çizelge 3.5. BT Kidney veri kümesi üzerinde yapılan ablasyon çalışmasıyla blokların verimliliğinin karşılaştırılması

Bloklar	Doğruluk	Kesinlik	Hassasiyet	F1-skor
ECA + ASPP	%76,15	%78,15	%73,56	%75,75
Modifiye edilmiş Inception + ASPP	%95,67	%96,22	%94,89	%95,48
Modifiye edilmiş Inception + ECA	%97,64	%97,20	%95,92	%96,44
Modifiye edilmiş Inception + ECA + ASPP	%99,5	%98,62	%98,83	%99,60

BreaKHis veri kümesi için elde edilen sonuç ile bütün blokların olduğu sonuçlar Çizelge 3.6.'da gösterilmektedir.

Çizelge 3.6. BreaKHis veri kümesi üzerinde yapılan ablasyon çalışmasıyla blokların verimliliğinin karşılaştırılması

Bloklar	Doğruluk	Kesinlik	Hassasiyet	F1-skor
ECA + ASPP	%66,59	%67,63	%65,7	%66,65
Modifiye edilmiş Inception + ASPP	%90,09	%91,05	%89,32	%90,16
Modifiye edilmiş Inception + ECA	%94,04	%94,56	%93,18	%93,86
Modifiye edilmiş Inception + ECA + ASPP	%96,98	%96,31	%97,05	%96,59

4. SONUÇ VE DEĞERLENDİRME

Sağlık sistemindeki en büyük problemlerden birisi hastaya tanıyı koyma sürecidir. Yanlış değerlendirmeler ve uygun seçilmeyen tıbbi görüntüleme yöntemleri nedeniyle tanı koyma süreci uzamaktadır. Ancak kanser olan hastalar için zaman kavramı çok daha önem arz etmektedir. Bu ve benzer nedenlerden dolayı hekimlere yardımcı olmak amacıyla yapay zeka tabanlı sistemler sağlık alanında önemli hale gelmiştir. Yapay zekanın bir alt alanı olan derin öğrenme modelleri kullanılarak sağlık alanında birçok çalışma yapılmaktadır. Literatürde tıbbi görüntülerin sınıflandırılmasıyla ilgili başarılı sonuçlar veren çalışmalar yapılmasına rağmen modeller karmaşık ağ yapısına sahip olabilmektedir. Zaman ve maliyet karmaşıklığı gerçek zamanlı işlemlerde bir sorun teşkil edebilmektedir. Bu nedenle bu tez kapsamında tıbbi görüntülerin sınıflandırılması için bir derin öğrenme modeli önerilmiştir. Bu önerilen modelin literatüre katkısı ve motivasyonu, ağın karmaşıklığını arttırmadan yüksek doğruluk verecek, düşük örnekleme sahip veri kümelerinde de başarı sağlayacak nitelikli bir modelin gerçekleştirilmesidir. Ayrıca bu model ile önişleme adımı olmadan da başarı sağlaması hedeflenmiştir. Önerilen model beyin, böbrek ve meme tıbbi görüntüleri üzerinde eğitilmiş ve test edilmiştir.

Geliştirilen model 6,599,683 parametre gerektirmektedir. Modelin genel yapısında GoogLeNet mimarisindeki Inception bloğunu daha fazla özellik çıkarımı olması için modifiye edilmiştir. Inception bloğu için yapılan çalışmalarda en iyi sonuç art arda üç kez tekrarlanması ile elde edilmiştir. Böylece model de üç Inception bloğu kullanılmıştır. Ardından SENet modelindeki sıkıştır-genişlet bloğundan esinlenilerek ECA bloğu eklenmiştir. ECA bloğu parametre sayısını arttırmadan daha önemli özelliklere odaklanılması için kullanılmıştır. Son olarak ise ASPP bloğuyla anlamsal detayların çıkarılması hedeflenmiştir. Önerilen model literatürdeki, Figshare ve BT-large-4C, BT Kidney ve BreaKHis veri kümeleri kullanılarak yapılan çalışmalarla karşılaştırılmıştır.

Literatürde Figshare veri kümesini kullanarak gerçekleştirilen çalışmalar ile geliştirilen modelin deneysel karşılaştırılması Çizelge 4.1.'de verilmiştir.

Çizelge 4.1. Figshare veri kümesini kullanan çalışmalar ile geliştirilen modelin karşılaştırılması

Referans	Model	Ön işleme / Veri arttırma	Doğruluk	Kesinlik	Hassasiyet	F1-skor
[55]	LDA ile bölütlenmiş tümör bölgesinde ROI'si çıkarılması ve sınıflandırılması	Tümör bölgesinin yuvarlak içine alınması	%91,28	-	-	-
[77]	Topluluk sınıflandırıcısı ile yoğunluk, doku ve şekil tabanlı özelliklerin sınıflandırılması (Rastgele Orman, K-En yakın komşu, Karar ağaçları)	Önişleme yapılmıştır, ancak ne yapıldığı belirtilmemiştir	%98,99	%97,63	%97,34	%97,47
[78]	MBTFCN (Res-bloklar, Res-strip-ortaklama dikkat modülü, ASPP)	Çevirme, ölçekleme, dönüştürme	%99,78	%99,76	%99,84	%99,80
[79]	Temel CNN modeli	Çevirme, ölçekleme, kaydırma, x-y ekseninde döndürme	%91,43	%92,3	%90,6	%90,6
[80]	CapsNet mimarisi	Önişleme yapılmamıştır	%90,89	-	-	-
[81]	Genetik Algoritması kullanana CNN modeli	Çevirme, ölçekleme, dönüştürme, y ekseninde döndürme, dönüştürme	%94,2	%94,3	%94,2	%94,24
[82]	Temel CNN modeli	Döndürme, gürültü ekleme, y ekseninde döndürme	%96,13	%96,06	%94,43	-
[83]	Fine-tuning yapılmış bir ResNet50 modeli	Çevirme, ölçekleme, dönüştürme, öteleme, zoom yapma, parlaklık iyileştirme	%99	%99	%99	%99
Önerilen Yöntem	Inception, ECA, ASPP	Önişleme yapılmamıştır	%99,84	%99,89	%99,88	%99,89

Çizelge 4.1'deki yapılan çalışmalar incelendiğinde önerilen modelin diğer çalışmalardan daha iyi bir sonuç verdiği gözlemlenmiştir. Çizelgeye bakıldığında önerilen modelin

doğruluk, kesinlik, hassasiyet, F1-skor ve MCC değerleri sırasıyla %99,84, %99,89, %99,88, %99,89 ve %99,83 bulunmuştur.

Literatürde BT-large-4C veri kümesini kullanarak gerçekleştirilen çalışmalar ile geliştirilen modelin deneysel karşılaştırılması Çizelge 4.2.'de verilmiştir.

Çizelge 4.2. BT-large-4C veri kümesini kullanan çalışmalar ile geliştirilen modelin karşılaştırılması

Referans	Model	Ön işleme / Veri Arttırma	Doğruluk	Kesinlik	Hassasiyet	F1-skor
[78]	MBTFCN (Artık bloklar, Artık strip-ortaklama dikkat modülü, ASPP)	Döndürme, ölçekleme, dönüştürme	%96,32	%96,10	%96,54	%96,3
[84]	Önceden eğitilmiş derin öğrenme modelleri topluluğu (ResNet, DenseNet, VGG, AlexNet, Inception V3, ResNeXt, ShuffleNet V2, MobileNet V2, MnasNet)	Döndürme, x-y ekseninde döndürme	%91,58	-	-	-
Önerilen Yöntem	Inception, ECA, ASPP	Önişleme yapılmamıştır	%98,05	%96,92	%96,76	%96,75

Çizelge 4.2'ye bakıldığında önerilen çalışmanın diğer çalışmalardan daha iyi sonuç verdiği görülmüştür. Diğer çalışmalarda ön işlem adımı olması ve önerilen modelde herhangi bir önişlem adımı olmaması karşılaştırıldığında daha iyi sonuç verdiği gözlemlenmiştir. Çizelgeye bakıldığında önerilen modelin doğruluk, kesinlik, hassasiyet, F1-skor ve MCC değerleri sırasıyla %98,05, %96,92, %96,76, %96,75 ve %95,72 bulunmuştur.

Literatürde BT Kidney veri kümesini kullanarak gerçekleştirilen çalışmalar ile geliştirilen modelin deneysel karşılaştırılması Çizelge 4.3.'te verilmiştir. Çalışmalar incelendiğinde görülmektedirki veri kümesindeki görüntü sayılarının çok olmasından dolayı bütün verileri kullanarak değil içerisinden dengeli veri seçimi ile bir çalışma yapılmıştır. Veri kümesi içerisinden görüntüler seçilirken nasıl bir seçim yapıldığı belirsizdir. Bu veri kümesi kullanılarak yapılan literatürdeki çalışmaların aksine tez çalışmasında bütün veri kullanılarak eğitilmiş ve test edilmiştir. Çizelgeye bakıldığında önerilen modelin doğruluk,

kesinlik, hassasiyet, F1-skor ve MCC değerleri sırasıyla %99,5, %98,62, %98,83, %99,60 ve %98,32 bulunmuştur.

Çizelge 4.3. BT Kidney veri kümesini kullanan çalışmalar ile geliştirilen modelin karşılaştırılması

Referans	Model	Ön işleme / Veri Arttırma	Doğruluk	Kesinlik	Hassasiyet	F1-skor
[17]	Temel CNN modeli	Önişleme yapılmamıştır	%99,3	%99,3	%99,3	%99,3
[70]	Swin Transformer, EANet, CCT, VGG16, Inception v3, ResNet50	Döndürme işlemi ile veri arttırma yapılmıştır. (1377 veri kullanılmış)	%99,30	%99,15	%99,15	%99,12
[85]	DenseNet-201 modeli, Rastgele Orman	Önişleme yapılmamıştır. (1377 veri kullanılmış)	%99,44	%99,45	%99,47	%99,42
[86]	Önceden öğrenilmiş VGG-19 modeli	Veri arttırma işlemi yapılmıştır. (1377 veri kullanılmış)	%96,37	%96,25	%96,5	%96,5
Önerilen Yöntem	Inception, ECA, ASPP	Önişleme yapılmamıştır.	%99,5	%98,62	%98,83	%99,60

Literatürde BreaKHis veri kümesi kullanılarak gerçekleştirilen çalışmalar ile geliştirilen modelin deneysel karşılaştırılması Çizelge 4.4.'te verilmiştir. Bu veri kümesindeki bütün veriler ile çalışma yapılmamıştır. Büyütme faktörü 400x olan veriler eğitilmiş ve test edilmiştir. Ayrıca 400x büyütme faktörü görüntülerini kullanarak yapılan çalışmalarla karşılaştırıldığında ortalama bir başarı sağladığı gözlemlenmiştir. Diğer bir ifadeyle kimi çalışmalardan daha iyi sonuç verirken kimi çalışmaların başarısını yakalayamadığı gözlemlenmiştir.

Çizelge 4.4. BreaKHis veri kümesini kullanan çalışmalar ile geliştirilen modelin karşılaştırılması

Referans	Model	Ön işleme / Veri Arttırma	Doğruluk	Kesinlik	Hassasiyet	F1-skor
[27]	BreastNet	Önişleme yapılmamıştır.	%95,88	-	-	-
[87]	RANet, ADSVM	Önişleme yapılmamıştır.	%93,35	%92,27	%92,76	%92,45
[88]	Otokodlayıcı-temeline dayalı Siamese çerçevesi	Önişleme yapılmamıştır.	%96,7	%95,7	%99,5	%97,6
[89]	KD-tabanlı öğrenci modeli	Önişleme yapılmamıştır.	%96,67	%96,46	%95,75	%96,06
[90]	Slim-G4	Önişleme yapılmamıştır.	%97,92	%97,05	%97,92	%97,46
Önerilen Yöntem	Inception, ECA, ASPP	Önişleme yapılmamıştır.	%96,98	%96,31	%97,05	%96,59

Çizelge 4.4.'e bakıldığında önerilen modelin doğruluk, kesinlik, hassasiyet, F1-skor ve roc-curve değerleri sırasıyla %96,98, %96,31, %97,05, %96,59 ve %97,06 bulunmuştur.

Tez çalışmasında önerilen modelde kullanılan bloklarının birbirleriyle entegrasyonu durumunda nasıl bir sonuç alınacağıyla ilgili bir ablasyon çalışması yapılmıştır. Blokların model için önemli olup olmadığını anlamak için sırayla bloklar çıkarılmış ve dört farklı veri kümesi üzerinde test edilmiştir. Sonuçlara bakıldığında modifiye edilmiş Inception bloğu, ECA bloğu ve ASPP bloklarının modelin doğru sınıflandırma yapabilmesi için birlikte kullanımının önemli olduğu gözlemlenmiştir. Bu çalışmanın devamı olarak önerilen modelin genelleyebilir olduğunu ispatlamak amacıyla tıbbi görüntüler dışında farklı veri kümeleriyle de değerlendirmek önemli olacaktır. Ayrıca eğitim sürecini hızlandıracak algoritmalar geliştirilmesi de hedeflenmektedir.

KAYNAKLAR

1. Jordan, J. T. and Gerstner E. R. (2023). Imaging of brain tumors. *Continuum (Minneap Minn),* 29(1), 171-193

2. Rees, J. (2003). Advances in magnetic resonance imaging of brain tumours. *Current Opinion in Neurology,*16(6), 643-650.

3. Schillaci, O., Filippi, L., Manni, C., and Santoni. R. (2007). Single-photon emission computed tomography/computed tomography in brain tumors. *Seminars in Nuclear Medicine,* 37(1), 34-47.

4. Ricardo McFaline-Figueroa, J., and Lee, E. Q. (2018). Brain tumors. *The American Journal of Medicine,* 131(8), 874–882.

5. Şimşek, A. B. ve Dicle, A. (2013). Primer beyin tümörü: Klinik özellikler, tedavi ve bakım. *Dokuz Eylül Üniversitesi Hemşirelik Yüksekokulu Elektronik Dergisi,* 6(2), 1-12.

6. Buerki, R. A., Horbinski, C. M., Kruser, T., Horowitz, P. M., James, C. D., and Vukas, R. V. (2018). An overview of meningiomas. *Future Oncology,*14(21), 2161-2177.

7. Watts, J., Box, G., Galvin, A., Brotchie, P., Trost, N., and Sutherland, T. (2014) Magnetic resonance imaging of meningiomas: a pictorial review. *Insights Imaging,* 5(1), 113-122.

8. Ortega-Martorell, S., Riley, P., Olier, I., Raidou, R. G., Casana-Eslava, R., Rea, M., and Palmieri, C. (2022). Breast cancer patient characterisation and visualisation using deep learning and fisher information networks. *Scientific Reports,* 12(1), 1-14.

9. Waks, A. G. and Winer, E. P. (2019). Breast cancer treatment: A review. *Jama,* 321(3), 288-300.

10. Sree, S. V., Ng, E. Y.-K., Acharya, R. U., and Faust, O. (2011). Breast imaging: A survey. *World Journal of Clinical Oncology,* 2(4), 171-178.

11. Liu, Y., Bellomi, M., Gatti, G., and Ping, X. (2007). Accuracy of computed tomography perfusion in assessing metastatic involvement of enlarged axillary lymph nodes in patients with breast cancer. *Breast Cancer Research,* 9(4), 1-7.

12. Schaub, J. A., Hamidi, H., Subramanian, L., and Kretzler, M. (2020). Systems biology and kidney disease. *Clinical Journal of the American Society of Nephrology,* 15(5), 695-703.

13. Alzu'bi, D., Abdullah, M., Hameidi, I., AlAzab, R., Gharaibeh, M., El-Heis, M., Almotairi, K. H., Forestiero, A., Hussein, A. M., and Abualigah, L. (2022). Kidney tumor detection and classification based on deep learning approaches: A new dataset in CT scans. *Journal of Healthcare Engineering,* 1,1-22.

14. Kazemi, Y. and Mirroshandel, S. A. (2018). A novel method for predicting kidney stone type using ensemble learning. *Artificial Intelligence in Medicine,* 84, 117-126.

15. Aksakallı, I. K., Kaçdıoğlu S., and Hanay, Y. S. (2021). Kidney x-ray images classification using machine learning and deep learning methods. *Balkan Journal of Electrical & Computer Engineering,* 9(2), 144-151.

16. Sudharson, S., and Kokil, P. (2020). An ensemble of deep neural networks for kidney ultrasound image classification. *Computer Methods and Programs in Biomedicine,* 197, 1-9.

17. Narmada, N., Shekhar, V., and Singh, T. (2022). *Classification of kidney ailments using CNN in CT images.* 2022 13th International Conference on Computing Communication and Networking Technologies (ICCCNT), Kharagpur, India, 1-5.

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

19. Wang, G., Li, W., and Huang, Y. (2021). Medical image fusion based on hybrid three-layer decomposition model and nuclear norm. *Computers in Biology and Medicine,* 129, 1-15.

20. Kasinathan, G., Jayakumar, S., Gandomi, A. H., Ramachandran, M., Fong, S. J., and Patan, R. (2019). Automated 3-D lung tumor detection and classification by an active contour model and CNN classifier. *Expert Systems with Applications,* 134, 112-119.

21. Moitra, D. and Kandal, R. K. (2020). Classification of non-small cell lung cancer using one-dimensional convolutional neural network. *Expert Systems with Applications,* 159, 1-10.

22. Banik, P. P., Saha, R., and Kim, K. (2020). An automatic nucleus segmentation and CNN model based classification method of white blood cell. *Expert Systems with Applications,* 149, 1-14.

23. Zhang, H., Chen, Y., Song, Y., Xiong, Z., Yang, Y., and Wu, Q. M. J. (2019). Automatic kidney lesion detection for CT images using morphological cascade convolutional neural networks. *IEEE Access,* 7, 83001-83011.

24. Yıldız, O. (2019). Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study. *Journal of The Faculty of Engineering and Architecture of Gazi University,* 34(4), 2241-2260.

25. Pang, T., Wong, J., Ng, W. L., and Chan, C. S. (2021). Semi-supervised GAN-based radiomics model for data augmentation in breast ultrasound mass classification. *Computer Methods and Programs in Biomedicine,* 203, 1-8.

26. Li, H., Zhuang, S., Li, D., Zhao, J., and Ma, Y. (2019). Benign and malignant classification of mammogram images based on deep learning. *Biomedical Signal Processing and Control,* 51, 347-354.

27. Toğaçar, M., Özkurt, K. B., Ergen, B., and 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, 1-17.

28. Supriya, M. and Deepa, A. J. (2020). A novel approach for breast cancer prediction using optimized ANN classifier based on big data environment. *Health Care Management,* 3(23), 414-426.

29. Feng, H., Cao, J., Wang, H., Xie, Y., Yang, D., Feng, J., and Chen, B. (2020). A knowledge-driven feature learning and integration method for breast cancer diagnosis on multi-sequence MRI. *Magnetic Resonance Imaging,* 69, 40-48.

30. Toğaçar, M., Ergen, B., and Cömert, Z. (2020). Application of breast cancer diagnosis based on a combination of convolutional neural networks, ridge regression and linear discriminant analysis using invasive breast cancer images processed with autoencoders. *Medical Hypotheses,* 135, 1-10.

31. Lou, Q., Li, Y., Qian, Y., Lu, F., and Ma, J. (2022). Mammogram classification based on a novel convolutional neural network with efficient channel attention. *Computers in Biology and Medicine,* 150, 1-9.

32. Wang, Q., Wu, B., Zhu, P., Li, P., Zuo, W., and Hu, Q. (2020). *ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks.* The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, USA, 11531-11539.

33. Ramamurthy, K., Vaichole, T. S., Kulkarni, S. K., Yadav, O., and Khan, F. (2022). Eff2Net: An efficient channel attention-based convolutional neural network for skin disease classification. *Biomedical Signal Processing and Control,* 73, 1-11.

34. Jin, X., Xie, Y., Wei, X., Zhao, B. R., Chen, Z. M., and Tan, X. (2022). Delving deep into spatial pooling forsqueeze-and-excitation networks. *Pattern Recognition,* 121, 1-12.

35. Zhou, W., Liu, C., Lei, J., Yu, L., and Luo, T. (2022). HFNet: Hierarchical Feedback Network with multilevel atrous spatial pyramid pooling for RGB-D saliency detection. *Neurocomputing,* 490, 347-357.

36. Jie, F., Nie, Q., Li, M., Yin, M., and Jin, T. (2021). Atrous spatial pyramid convolution for object detection with encoder-decoder. *Neurocomputing,* 464, 107-118.

37. Zhu, Y., Wa, L., Xu, W., and Wang, S. (2021). ASPP-DF-PVNet: Atrous Spatial Pyramid Pooling and Distance-Filtered PVNet for occlusion resistant 6D object pose estimation. *Signal Processing: Image Communication,* 95, 1-9.

38. Ahmad, M., Prats, G., Bazalova, M., and Xing, L. (2014). X-Ray luminescence and x-ray fluorescence computed tomography: New molecular imaging modalities. *IEEE Access,* 2, 1051-1061.

39. Chan, R. W., Lau, J. Y. C., Lam, W. W., and Lau, A. (2019). Magnetic resonance imaging. *Encyclopedia of Biomedical Engineering,* 574-587.

40. LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature,* 521, 436–444.

41. Jiang, J., Trundle, P., and Ren, J. (2010). Medical image analysis with artificial neural networks. *Computerized Medical Imaging and Graphics,* 34, 617-631.

42. Yunhong, S., Shilei, Y., Xiaojing, Z., and Jinhua, Y. (2022). Edge detection algorithm of MRI medical image based on artificial neural network. *Procedia Computer Science,* 208, 136-144.

43. Nazir, S., Dickson, D. M., and Akram, M. U. (2023). Survey of explainable artificial intelligence techniques for biomedical imaging with deep neural networks. *Computers in Biology and Medicine ,* 156, 1-29.

44. Albawi, S., Mohammed, T. A., and Al-Zawi, S. (2018). *Understanding of a convolutional neural network*. 2017 International Conference on Engineering and Technology (ICET), Antalya, Türkiye, 1-6.

45. Kalchbrenner, N., Grefenstette, E., and Blunsom, P. (2014). A convolutional neural network for modelling sentences. *arXiv preprint arXiv:1404.2188,* 1-11.

46. Shea, K. and Nash, R. (2015). An Introduction to Convolutional Neural Networks. *arXiv preprint arXiv:1511.08458,* 1-11.

47. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015). *Going deeper with convolutions.* 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, USA, 1-9.

48. Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems,* 25(2), 82-97.

49. Hu, J., Shen, L., Albanie, S., Sun, G., and Wu, E. (2019). Squeeze-and-Excitation Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,* 1-13.

50. Roy, A., Navab, N., and Wachinger, C. (2018). Concurrent Spatial and channel 'Squeeze and Excitation' in fully convolutional networks, *arXix preprint arXix:1803.02579*, 1-8.

51. Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., and Yuille, A. (2017). DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence,* 40(4), 834–848.

52. Lazebnik, S., Schmid, C., and Ponce, J. (2006). *Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories.* IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06), New York, USA, 1-8.

53. He, K., Zhang, X., Ren, S., and Sun. J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence,* 37(9), 1904-1916.

54. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., and Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition,* 77, 354-377.

55. Cheng, J., Huang, W., Cao, S., Yang, R., Yang, W., and Yun, Z. (2015). Enhanced performance of brain tumor classification via tumor region augmentation and partition. *PLoS One,* 10(10), 1-13.

56. Soydaner, D. (2019). A comparison of optimization algorithms for deep learning. *International Journal of Pattern Recognition and Artificial Intelligence,* 34(13), 1-27.

57. Kingma, D. and Ba, J. (2015). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 1-15.

58. Sun, S., Cao, Z., Zhu, H., and Zhao, J. (2020). A survey of optimization methods from a machine learning perspective. *IEEE Transactions on Cybernetics,* 50(8), 3668-3681.

59. Mukkamala, M. C., and Hein, M. (2017). *Variants of RMSProp and Adagrad with logarithmic regret bounds.* In International Conference on Machine Learning, Sydney Australia, 1-16.

60. Vani, S. and Rao, T. V. M. (2019). *An experimental approach towards the performance assessment of various optimizers on convolutional neural network.* 3rd International Conference on Trends in Electronics and Informatics (ICOEI), Tirunelveli, India, 331-336.

61. Cui, Z., Fan, Q., and Jia, C. (2020). Momentum methods for stochastic optimization over time-varying directed networks. *Signal Processing,* 174, 1-13.

62. Parhi, R. and Nowak, R. D. (2020). The role of neural network activation functions. *IEEE Signal Processing Letters ,* 27,1779 - 1783.

63. Nair, V. and Hinton, G. E. (2010). *Rectified linear units improve restricted boltzmann machines.* Proceedings of the 27th International Conference on Machine Learning, Haifa, Israel, 1-8.

64. Internet: Ayten, B. (2021). Yapay sinir ağlarında aktivasyon fonksiyonları. URL: https://medium.com/databulls/yapay-sinir-ağlarında-aktivasyon-fonksiyonları-11002b8ac522. Son Erişim Tarihi: 10.03.2023.

65. Maharjan, S., Alsadoon, A., Prasad, P., Al-Dalain, T., and Alsadoon, O. H. (2020). A novel enhanced softmax loss function for brain tumour detection using deep learning. *Journal of Neuroscience Methods,* 330, 1-11.

66. Pappas, C., Kovaios, S., Moralis-Pegios, M., Tsakyridis, A., Giamougiannis, G., Kirtas, M., Kerrebrouck, J. V., Coudyzer, G., Yin, X., Passalis, N., Tefas, A., and Pleros, N. (2023). Programmable Tanh-, ELU-, Sigmoid-, and Sin-Based nonlinear activation functions for neuromorphic photonics. *IEEE Journal of Selected Topics in Quantum Electronics Photonic Signal Processing,* 29(6), 1-10.

67. He, K., Zhang, X., Ren, S., and Sun, J. (2014). *Spatial pyramid pooling in deep convolutional networks for visual recognition*. European Conference on Computer Vision (ECCV), 8691, 346-361.

68. Wang, Y., Liang, B., Ding, M., and Li, J. (2018). Dense semantic labeling with atrous spatial pyramid pooling and decoder for high-resolution remote sensing imagery. *Remote Sensing,* 11(1), 1-18.

69. İnternet: Bhuvaji, S., Kadam, A., Bhumkar, P., Dedge, S., and Kanchan, S., Brain Tumor Classification (MRI) Dataset, URL: https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri. Son Erişim Tarihi: 25.03.2023.

70. Islam, H., Hasan, M., Hossain, K., Alam, G., Uddin, Z. and Soylu, A. (2022). Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography. *Scientific Reports,* 12(1), 1-14.

71. İnternet: Laboratório Visão Robótica e Imagem, Breast Cancer Histopathological Database (BreakHis), Laboratório Visão Robótica e Imagem. URL: https://web.inf.ufpr.br/vri/databases/breast-cancer-histopathological-database-breakhis/. Son Erişim Tarihi: 05.04.2022.

72. Lavazza, L. and Morasca, S. (2023). Common problems with the usage of F-measure and accuracy metrics in medical research. *IEEE Access,* 11, 51515-51526.

73. Hossin, M. and Sulaiman, M. N. (2015). A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process (IJDKP),* 5(2), 1-11.

74. Chicco D. and Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics,* 21(6), 1-13.

75. Anguita, D., Ghelardoni, L., Ghio, A., Oneto, L., and Ridella, S. (2012). *The 'K' in K-fold cross validation.* ESANN 2012 proceedings, European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, Bruges, Belgium, 441-446.

76. Ferri, C., Hernández-Orallo, J., and Modroiu, R. (2009). An experimental comparison of performance measures for classification. *Pattern Recognition Letters,* 30(1), 27-38.

77. Bansal, T. and Jindal, N. (2022). An improved hybrid classification of brain tumor MRI images based on conglomeration feature extraction techniques. *Neural Computing and Applications,* 34(11), 1-18.

78. Shahin, A. I., Aly, W., and Aly, S. (2023). MBTFCN: A novel modular fully convolutional network for MRI brain tumor multi-classification. *Expert Systems With Applications,* 212, 1-12.

79. Paul, J. S., Plassard, A. J., Landman, B. A., and Fabbri, D. (2017). Deep learning for brain tumor classification. *Medical Imaging 2017: Biomedical Applications in Molecular, Structural, and Functional Imaging,* 10137, 253-268.

80. Afshar, P., Plataniotis, K. N., and Mohammadi, A. (2019). *Capsule networks for brain tumor classification based on MRI images and coarse tumor boundaries.* IEEE In ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing, Brighton, UK, 1368-1372.

81. Anaraki, A. K., Ayati, M., and Kazemi, F. (2019). Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *Biocybernetics and Biomedical Engineering,* 39(1), 63-74.

82. Sultan, H. H., Salem, N. M., and Al-Atabany W. (2019). Multi-classification of brain tumor images using deep neural network. *IEEE Access,* 7, 69215–69225.

83. Ismael, S. A. A., Mohammed, A., and Hefny, H. (2020). An enhanced deep learning approach for brain cancer MRI images classification using residual networks. *Artificial Intelligence in Medicine,* 102, 1-8.

84. Kang, J., Ullah, Z., and Gwak, J. (2022). MRI-Based brain tumor classification using ensemble of deep features and machine learning classifiers. *Sensors,* 21(6), 1-21.

85. Mohammed, A. and Abd, D. F. (2022). Kidney diseases classification using hybrid transfer-learning DenseNet201-based and Random Forest. *Kurdistan Journal of Applied Research (KJAR),* 7(2), 1-14.

86. Asif, S., Wenhui Y., Jinhai S., Ain Q. U., Yueyang, Y., and Jin, H.(2022). *Modeling a fine-tuned deep convolutional neural network for diagnosis of kidney diseases from CT images.* 2022 IEEE International Conference in Bioinformatics and Biomedicine (BIBM), Las Vegas, USA, *2571-2576*

87. Zhou, Y., Zhang, C., and Gao, S. (2022). Breast cancer classification from histopathological images using resolution adaptive network. *IEEE Access,* 10, 35977-35991.

88. Liu, M., He, Y., Wu, M., and Zeng, C. (2022). Breast histopathological image classification method based on autoencoder and siamese framework. *Information,* 13(3), 1-16.

89. Sepahvand, M., and Abdali-Mohammadi, F. (2022). Overcoming limitation of dissociation between MD and MI classifications of breast cancer histopathological images through a novel decomposed feature-based knowledge distillation method. *Computers in Biology and Medicine,* 145, 1-13.

90. Modarres, A., Esfahani, E. E., and Bahrami, M. (2023). GroupMixer: Patch-based group convolutional neural network for breast cancer detection from histopathological images, *arXiv preprint arXiv:2311.09846,* 1-10.



Gazili olmak ayrıcalıktır