

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



AÇIKLANABİLİR YAPAY ZEKA YÖNTEMLERİYLE MR
GÖRÜNTÜLERİNDEN BEYİN TÜMÖRÜ TESPİTİ

Muhammet Doğukan İLİ

Yüksek Lisans Tezi

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

ŞUBAT 2025

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

AÇIKLANABİLİR YAPAY ZEKA YÖNTEMLERİYLE MR
GÖRÜNTÜLERİNDEN BEYİN TÜMÖRÜ TESPİTİ

Tez Yazarı

Muhammet Doğukan İLİ

Danışman

Doç. Dr. Fatih ÖZYURT

ŞUBAT 2025

ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı: Açıklanabilir Yapay Zeka Yöntemleriyle MR Görüntülerinden Beyin
Tümörü Tespiti

Yazarı: Muhammet Doğukan İLİ

İlk Teslim Tarihi: 02.01.2025

Savunma Tarihi: 03.02.2025

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Fatih ÖZYURT Fırat Üniversitesi, Mühendislik Fakültesi	İmza Onayladım
Başkan:	Prof. Dr. Engin AVCI Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Fahrettin Burak DEMİR Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Açıklanabilir Yapay Zeka Yöntemleriyle MR Görüntülerinden Beyin Tümörü Tespiti” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

03/02/2025

Muhammet Doğukan İLİ



ÖNSÖZ

Yapılan tez çalışması boyunca herhangi bir zorlukla karşılaşılmamıştır. Araştırmanın tüm süreçlerinde bilgi ve tecrübelerini esirgemeyen Sayın Doç Dr. Fatih ÖZYURT’a teşekkürlerimi sunarım. Ayrıca bu süreç boyunca manevi desteklerini esirgemeyen aileme minnetimi sunarım.

Muhammet Doğukan İLİ
ELAZIĞ, 2025



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	viii
ABSTRACT	ix
ŞEKİLLER LİSTESİ	x
TABLolar LİSTESİ	xii
KISALTMALAR	xiii
1. GİRİŞ	1
2. BEYİN TÜMÖRÜ VE MANYETİK REZONANS GÖRÜNTÜLEME	4
2.1. Beyin.....	4
2.2. Beyin Tümörü	5
2.3. Tümör Türleri.....	6
2.3.1. İyi Huylu Beyin Tümörleri	8
2.3.2. Kötü Huylu Beyin Tümörleri.....	8
2.3.3. Beyin Tümörlerinin Sınıflandırılması.....	8
2.4. Beyin Görüntüleme Yöntemleri.....	10
2.4.1. BT (Bilgisayarlı Tomografi).....	10
2.4.2. MR (Manyetik Rezonans Görüntüleme).....	11
2.4.3. Pozitron Emisyon Tomografisi (PET).....	12
3. MAKİNE ÖĞRENMESİ	13
3.1. K En Yakın Komşu (KNN) Algoritması.....	14
3.2. Destek Vektör Makineleri (DVM)	15
3.3. Lojistik Regresyon	16
3.4. Yapay Sinir Ağları	17
3.5. Derin Öğrenme.....	19
3.6. Evrişimli Sinir Ağları (ESA).....	21
3.6.1. Evrişimli Katmanlar	22
3.6.2. Havuzlama Katmanları	23
3.6.3. Tam Bağlantılı Katmanlar	23
3.7. Transfer Öğrenme ile Hazır CNN'ler.....	23
3.7.1. LeNet 5.....	24
3.7.2. Visual Geometry Group (VGG-16).....	26
3.7.3. Residual Network (ResNet).....	27
3.7.4. MobileNetV2.....	27
3.7.5. InceptionV3.....	29
3.7.6. Yoğun Bağlı Ağlar (DenseNet)	31
3.7.7. AlexNet.....	32
3.7.8. YOLO (You Only Look Once).....	33
3.7.9. Xception	34
3.7.10. EfficientNet	36
3.7.11. R CNN, Fast R CNN ve Faster R CNN	37

3.7.12. U Net	41
3.8. Model Performanslarının Değerlendirilmesi.....	44
3.8.1. Doğruluk.....	45
3.8.2. Hassasiyet	45
3.8.3. Duyarlılık.....	45
3.8.4. Hassasiyet ile Duyarlılık Dengesi.....	45
3.9. Açıklanabilir Yapay Zeka	46
3.9.1. Sınıf Aktivasyon Haritaları.....	46
3.9.2. Cam Tekniklerinin Değerlendirilme Metrikleri.....	54
3.10. SHAP Tekniği.....	54
3.10.1. Shapley Değerleri ve Değerlerin Hesaplanması	55
3.10.2. SHAP Tekniğinin Temel Prensipleri	55
3.10.3. SHAP Tekniğinin Çalışma Prensipleri	56
3.10.4. SHAP Tekniğinin Avantaj ve Sınırlılıkları.....	57
3.11. LIME (Local Interpretable Model-Agnostic Explanations) Tekniği.....	57
3.11.1. LIME Tekniğinin Çalışma Prensibi.....	58
3.11.2. LIME Tekniğinin Avantajları ve Sınırlılıkları.....	58
3.12. Literatürde Yapılan Çalışmalar	59
3.12.1. Beyin Tümörüne Yönelik Yapılan Çalışmalar.....	59
3.12.2. Diğer Çeşitli Hastalıklara Yönelik Yapılan Çalışmalar.....	62
4. MATERYAL VE METOT	66
4.1. GradCAM	66
4.2. Lime	67
4.3. Shapley.....	67
4.4. Veri Seti ve Eğitim Süreci.....	67
5. BULGULAR VE TARTIŞMA	69
5.1. CNN Modeli Eğitim Bulguları.....	69
5.2. GradCAM Yöntemi ile Görselleştirme	72
5.3. LIME Yöntemi ile Görselleştirme	77
5.4. SHAPLEY Yöntemi ile Görselleştirme	81
6. SONUÇLAR.....	84
ÖNERİLER	86
KAYNAKLAR.....	87
ÖZGEÇMİŞ	

ÖZET

Açıklanabilir Yapay Zeka Yöntemleriyle MR Görüntülerinden Beyin Tümörü Tespiti

Muhammet Doğukan İLİ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü
Yazılım Mühendisliği Anabilim Dalı

Şubat 2025, Sayfa: xi + 98

Bu çalışma kapsamında açıklanabilir yapay zeka yöntemleriyle MR görüntülerinden beyin tümörlerinin tespit edilmesi amaçlanmıştır. Yapılan bu çalışmanın tıbbi süreçlere katkı sağlaması, karar destek sistemlerine yönelik yeni bir literatür kazandırması açısından önemli olduğu düşünülmektedir. Çalışma kapsamında CNN modellerinden GradCAM, LIME ve Shapley görselleştirme yöntemleri kullanılmıştır. Çalışmada oluşturulan modelde sınıflandırma 4 grup (No Tumor, Glioma, Meningioma, Pituitary) altında incelenmiştir. Çalışma sonucunda GradCAM, modelin genel odaklanma alanlarını belirlemekte etkili olmuş; LIME, modelin kararlarının detaylı bir açıklamasını sunmuş; Shapley ise modelin genel performansını ve eksikliklerini ortaya koymuştur. Bu tekniklerin birlikte kullanılması, modelin daha güvenilir ve etkili bir şekilde çalışmasını sağlamak için daha fazla veri sağlanmasına veya gerekli iyileştirmelerin yapılmasına olanak tanımaktadır.

Anahtar Kelimeler: Açıklanabilir yapay zeka, Derin öğrenme, Makine öğrenmesi, GradCAM, Beyin tümörü

ABSTRACT

Brain Tumor Detection from MRI Images with Explainable Artificial Intelligence Methods

Muhammet Doğukan İLİ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural & Applied Sciences
Department of Software Engineering

February 2025, Page: xi + 98

Within the scope of this study, it was aimed to detect brain tumors from MRI images with explainable artificial intelligence methods. It is thought that this study is important in terms of contributing to medical processes and providing a new literature on decision support systems. Within the scope of the study, GradCAM, LIME and Shapley visualization methods from CNN models were used. In the model created in the study, the classification was examined under 4 groups (No Tumor, Glioma, Meningioma, Pituitary). As a result of the study, GradCAM was effective in determining the general focus areas of the model; LIME provided a detailed explanation of the model's decisions; Shapley revealed the general performance and shortcomings of the model. Using these techniques together allows more data to be provided or necessary improvements to be made to ensure that the model works more reliably and effectively.

Keywords: Explainable Artificial Intelligence, Deep Learning, Machine Learning, GradCAM, Brain tumor

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2. 1. Beynin kesitsel görünümü	4
Şekil 2. 2. Beyin tümörü türleri	7
Şekil 2. 3. BT'nin çalışma prensibi	11
Şekil 3. 1. KNN algoritması örneği	14
Şekil 3. 2. Destek vektörleri	16
Şekil 3. 3. İnsanların sinir hücrelerinin yapısı	17
Şekil 3. 4. Yapay sinir hücrelerinin yapısı	18
Şekil 3. 5. Derin öğrenmeyle insan öğrenmesinin karşılaştırılması.....	20
Şekil 3. 6. ESA'nın mimarisi ile katmanları	22
Şekil 3. 7. LeNet ağı örneği	24
Şekil 3. 8. VGG-16	26
Şekil 3. 9. ResNet	27
Şekil 3. 10. MobileNet	28
Şekil 3. 11. MobileNet derinlemesine evrişim katmanlarının yapısı.....	28
Şekil 3. 12. InceptionV3 ağı.....	30
Şekil 3. 13. DenseNet yapısı.....	31
Şekil 3. 14. AlexNet ağı	33
Şekil 3. 15. YOLO ağ mimarisi	34
Şekil 3. 16. Xception modelinin mimarisi	35
Şekil 3. 17. EfficientNet mimarisi	36
Şekil 3. 18. R CNN çalışma yapısı	38
Şekil 3. 19. Fast R CNN mimarisi	39
Şekil 3. 20. Faster R CNN algoritması	40
Şekil 3. 21. U Net mimarisi	42
Şekil 3. 22. İkili karışıklık matrisi örneği.....	44
Şekil 3. 23. GradCam	47
Şekil 3. 24. GradCam++ mimarisi.....	49
Şekil 5. 1. Eğitimi yapılan CNN modelinin blok diyagramı	69
Şekil 5. 2. Epoch doğruluk grafiği.....	70

Şekil 5. 3. Model metrikleri.....	71
Şekil 5. 4. Karmaşıklık matrisi	71
Şekil 5. 5. GradCAM yöntemi görselleştirmesi (No Tumor)	72
Şekil 5. 6. GradCAM yöntemi görselleştirmesi (Glioma tümör).....	73
Şekil 5. 7. GradCAM yöntemi görselleştirmesi (Meningioma tümör)	75
Şekil 5. 8. GradCAM yöntemi görselleştirmesi (Pituitary tümör).....	76
Şekil 5. 9. LIME yöntemi görselleştirmesi (No Tumor).....	77
Şekil 5. 10. LIME yöntemi görselleştirmesi (Glioma Tümör).....	78
Şekil 5. 11. LIME yöntemi görselleştirmesi (Meningioma Tümör)	79
Şekil 5. 12. LIME yöntemi görselleştirmesi (Pituitary Tümör).....	80
Şekil 5. 13. SHAPLEY yöntemine ait bulgular	81

KISALTMALAR

Kısaltmalar

ABD	: Amerika Birleşik Devletleri
BT	: Bilgisayarlı Tomografi
CAM	: Class Activation Maps
CNN	: Evrişimli Sinir Ağları
DSÖ	: Dünya Sağlık Örgütü
DTI	: Difüzyon Tensor Görüntüleme
DVM	: Destek Vektör Makineleri
FN	: False Negative
FP	: False Positive
IARC	: Uluslararası Kanser Araştırmaları Ajansı
IDH	: İzositrat dehidrojenaz
KNN	: K En Yakın Komşu
MEG	: Magnetoensefalografi
MR	: Manyetik rezonans
MRS	: MR Spektroskopi
RELU	: Rectified Linear Unit
SE	: Status epileptikus
SPECT	: Single Photon Emission Computed Tomography
TN	: True Negative
TP	: True Positive
YOLO	: You Only Look Once
YZ	: Yapay zeka

1. GİRİŞ

Yapay zeka (YZ) günümüzde tıbbi gelişmeleri, günlük yaşamı ve ekonomik faaliyetleri destekleyen önemli bir teknolojidir. Son dönemlerde bilgisayarların işleme kapasitelerinde yaşanan gelişmeler ile büyük veri birikimleri YZ teknolojisini önemli bir konuma getirmiştir. Sağlık alanında YZ, ilaçların keşfedilmesi, hastaların izlenmesi, tıbbi teşhislerin ve tanılarının konulması, risk yönetimi, giyilebilir cihazlar, sanal asistanlar gibi birçok uygulama alanında sıklıkla kullanılır hale gelmiştir. Ayrıca YZ teknolojilerinin gelişmesiyle radyoloji, dermatoloji ve patoloji görüntüleme verilerine dayanan tıbbi çalışmalarda artmış ve YZ tekniklerinin bu alanlarda kullanılması hastaların tedavi ve teşhislerde önemli bir role sahip olmuştur [1]. Tıbbi görüntülemelerde YZ teknolojilerinin aktif bir şekilde kullanılmasının sebebi klinik açıdan daha fazla etkinliğin oluşturulabilmesi ve verimliliği artırmasıdır [2]. Ayrıca günümüzde hasta ve sağlık personeli sayılarının dengesiz bir dağılımının olması sağlık personellerinin hasta verileriyle daha az ilgilenmesini etkilemiş ve sağlık personellerinin üzerindeki yükleri artırmıştır. Buna ek olarak çok sayıda hastanın radyolojik görüntülerinin incelenmesi ve analiz edilmesi hem zor hem uzun bir zaman gerektirmektedir bu duruma bir de sağlık personellerinin iş yüklerinin artması eklenince daha da zorlu bir süreç meydana gelmektedir [3]. Genel olarak radyolojik iş yükü taleplerinin karşılanabilmesi için günlük 8 saatin, tek bir hastanın görüntüsünü yorumlamak için harcanan süre olduğu söylenebilmektedir. Bu durum sağlıklı sağlık personeli-hasta dengesinin kurulabilmesini ciddi düzeylerde olumsuz etkilemektedir [4]. Radyoloji, görsel algıya ek olarak belirsizlik içeren durumlarda karar vermeyi de kapsamaktadır. Özellikle hatalar bu tür kısıtlı şartlar altında kaçınılmaz olmaktadır. Tıbbi görüntüleme hastalar ve hastalıkların tespit edilmesi için önemli bir ihtiyaçtır. Tıbbi görüntüleme beyin tümörlerinin tespit edilmesi, kanserlerin tespit edilmesi gibi birçok alanda yaygın olarak kullanılmaktadır. Bu noktada tıbbi görüntülemeyle uyumlu çalışan YZ teknolojileri özellikle donanımlı radyologlara önceden taranmış görüntüler ile tanımlanmış özellikler sunabilmektedir [5]. Bu teknolojiler verimliliği artırırken, hataları minimize eder ve daha kısa sürelerde doğru bilgilerin sağlık personellerine ulaştırmaktadır. Bu sebeple tıbbi görüntüleme ve YZ teknolojilerinin uyum içerisinde çalışabilmesi ve sonuçların kullanılabilir olmasına yönelik çeşitli politikalar ve çabalar ortaya konulmaktadır. Bütün görüntü tabanlı radyolojik görüntülerin analizleri, görüntülerden radyolojik özelliklerin ölçülebilmesine ve değerlendirilebilmesine bağlıdır. Görüntülerden elde edilen özellikler mevcut klinik görevler karakterizasyon için önem arz etmektedir [6]. Tıp alanında matematik ile istatistiğin kullanılması 1960'lı yıllardan itibaren önerilmiştir [7]. Bilgisayar teknolojileri 1980'li yıllardan itibaren farklı alanlarda yaygın bir şekilde kullanılmaya başlanmıştır. Bu durumla birlikte zaman içerisinde YZ destekli otomasyonlar, radyolojiyi algısal özne konumunda nicel ve hesaplanabilir bir alana dönüştürmüştür [8]. Veri analizi teknolojilerinin hesaplama güçleri arttıkça yeni nesil bilgisayarların üretilmiş ve YZ

teknolojilerinin radyolojik alanlarda kullanılması yönünde önemli adımlar atılmıştır. Günümüzde beyin tümörlerinin tespit edilmesi ile sınıflandırılmasında YZ teknolojileri yadsınamaz bir öneme sahiptir. Hastaların cerrahi rezeksiyonları ile biyopsi sonrası tümörlü görüntülerin patolojik olarak incelenmeleri, gliomaların derecelendirilmeleri ve immünohistokimyasal türlerin tespit edilebilmesi en önemli belirteçler olarak verilebilmektedir. Ancak bu teknolojilerin zamansız örnekleme, zaman kaybı, örneklemede hatalar ve farklı histolojik değerlendirme gibi çeşitli yetersizlikleri de bulunmaktadır [9]. Bu kapsamda çeşitli glioma alt tiplerinin sınıflandırılmasında daha etkili yöntemlerin bulunması gerekmektedir. Bu noktada tümörlerin radyomik özellikleri ile genomik yapılarının analiz süreçleri önemli bir süreç olarak verilebilmektedir. Radyomik özelliklerden elde edilen çok sayıda bilgi, sağlık personellerine görüntü özellikleri ile tümörlerle ilişkili moleküller arasında bağ kurulabilmesinde katkı sağlamaktadır [10]. Radyomik veriler, sağlık personellerinin çıplak gözle anlayamadıkları hastalık özelliklerini ortaya çıkarabilme potansiyeline sahip özel bilgilerdir. Radyomiklerin temel sayıtları ayırt edici görüntüleme algoritmalarının hastalıkların durumlarını ölçmesi ve bireyselleştirilmiş tıp için önemli bilgiler sunabilmesidir. Bu teknolojiler, hastaları klinik karar vermeyi destekleyecek biçimlerde sınıflandırmak amacıyla eğitilmiş son teknoloji makine öğrenimi modelleridir ve ilgili modellerde girdi olarak kullanılmaktadır [11]. Bu özellikler genel olarak tomografik ve Manyetik Rezonans (MR) görüntüleme gibi çeşitli görüntüleme modalitelerindeki kombinasyonlara ve bunlarla ilişkili sinyal-görüntü özelliklerine göre elde edilen özelliklerdir. MR görüntülerinde üretilen radyolojik özellikler, gliomaların derecelerinin tahmin edilmesi amacıyla kullanılmakta ve yüksek performans göstermektedirler [12]. MR görüntülerine dayalı doku analizleri ve genomik alt tiplere sınıflandırmaları gibi beyin tümörünün tespit edildiği YZ algoritmalarının günümüzde çok sayıda kullanıldığı ve yüksek performansların elde edildiği söylenebilmektedir [13].

Görüntü işleme teknolojileri, insan gözüyle yapılan işlevleri bilgisayar ortamında çeşitli arayüz yazılımlarıyla hızlı bir şekilde gerçekleştirmektedir. Bu teknolojiler farklı modellerle kullanılabilmektedir ancak günümüzde sıklıkla derin öğrenme modeli kullanıldığı söylenebilmektedir [14]. Derin öğrenme modeli başarı düzeyi yüksel olduğu için otomotivden tıbbi araştırmalara kadar birçok farklı alanda kullanılmaktadır [15]. Açıklanabilir YZ, herhangi bir YZ modelinin karar verme süreçlerini daha anlaşılır ve şeffaf hale dönüştürmeyi amaçlamaktadır. Görüntü işleme algoritmalarıyla evrimsel sinir ağları (CNN) gibi çeşitli derin öğrenme modellerinde, açıklanabilir teknikleri, modelin bir görüntü üzerindeki kararını nasıl verdiğini görselleştirmek ve yorumlamak amacıyla kullanılmaktadır [16]. Görüntü işleme ve model açıklanabilirliği açısından en sık kullanılan yöntemler ise GradCAM, Shapley ve LIME'dir. GradCAM, CNN modellerin belirli sınıflandırma sonuçlarına ulaşırken bir görüntünün hangi bölgelerini dikkate aldığını görselleştirmektedir [17]. Shapley değerleri, bir özelliğin modelin kararına ne kadar katkıda bulunduğunu adil ve matematiksel olarak açıklamak amacıyla oyun


teorisine dayalı bir tekniktir. Görüntü işleme açısından Shapley değerleri, bir pikselin bir sınıflandırma kararına etkisini ölçmektedir. LIME, model bağımsız bir açıklama yöntemidir ve herhangi bir makine öğrenimi modelinin kararlarını açıklamak amacıyla kullanılmaktadır. Görüntü işleme açısından bir görüntünün küçük bölümleri üzerinde çalışmakta ve kararların yerel olarak nasıl alındığını açıklamaktadır [18].

Bu çalışma kapsamında açıklanabilir YZ yöntemleriyle MR görüntülerinden beyin tümörünün tespit edilmesi amaçlanmıştır. Literatürde çeşitli hastalıkların teşhisinde YZ teknolojilerini kullanan ve yüksek performanslar elde eden çok sayıda çalışma bulunmaktadır [19-21]. Buna ek olarak literatürde beyin tümörünün teşhis edilmesinde çeşitli YZ teknolojilerinin kullanıldığı çok sayıda çalışmanın olduğu da söylenebilmektedir [22-25]. Literatür taramaları sonucunda açıklanabilir YZ yöntemleriyle MR görüntülerinden beyin tümörünü teşhis etmeye yönelik yapılan sınıflı sayıda çalışma olduğu gözlemlenmiştir [26-28]. Bu kapsamda literatüre ilgili alanda yeni ve güncel kaynak kazandırılması açısından yapılan çalışmanın önemli olduğu düşünülmektedir.

2. BEYİN TÜMÖRÜ VE MANYETİK REZONANS GÖRÜNTÜLEME

2.1. Beyin

İnsan beyni, insan vücudundaki en karmaşık yapıdır. Bunun sebebi bütün vücut fonksiyonlarında ve zihin üzerinde kontrol merkezi olmasıdır. Beyinde hafıza, duygular, hareket etme gibi farklı görevlerin yerine getirilmesi amacıyla bir arada çalışan trilyonlarca sinir hücresi bulunmaktadır. Beyin genel itibarıyla ön, omurilik, yan, kabuk gibi farklı ana bölmelere ayrılmaktadır. Bu ana bölmelerden her biri bireylerin yaşamlarını düzenlemelerine ve dış dünyayla etkileşimde kalmalarına katkıda bulunan çeşitli görevleri yerine getirmektedir [29]. Beyindeki sinir hücrelerinin iletişimi ile etkileşimleri, derin düşünme ve çalışma gerektiren karmaşık bir süreçten oluşmaktadır. Beyin anatomisinin kesitsel yapısının incelenmesiyle yapısının daha iyi anlaşılması ve içerisindeki çeşitli bölümlerin etkileşimlerinin görülmesi mümkündür. Beynin kesitsel görüntüleri, beyin içyapısını göstermektedir ve sinir hücreleri arasındaki ağları göstermektedir. Ayrıca hareket kontrolü, düşünme gibi çeşitli yaşamsal fonksiyonların düzenlenmesine de katkıda bulunmaktadır [30]. Şekil 2.1’de beyin kesitsel görünümü verilmiştir.



Şekil 2. 1. Beynin kesitsel görünümü [31]

İnsan beyninin anatomik görüntüleri aracılığıyla, beyin içyapısının ve derin bileşimlerinin detaylı bir şekilde keşfedilmesi mümkün olmaktadır. Beyni oluşturan sinir ağları ile dokuları, beyin karakterize olan karmaşıklığı ile organizasyonunu göstermektedir. Ayrıca fonksiyonel manyetik rezonans (MR) gibi çeşitli fonksiyonel görüntüleme yöntemleri, belirli rolleri üstlenirken beyin

aktivitesini izlemek için kullanılmaktadır. Bu durum beynin çeşitli zorluklar ve roller karşısında nasıl çalıştığının anlaşılmasına katkı sağlamaktadır [32]. MR görüntülerinin önemi yalnızca beynin fonksiyonlarını anlamak için değil aynı zamanda yapay zeka ile beyin tümörlerinin sınıflandırılması gibi çeşitli modern teknolojilerinde kullanılarak hastalıkların teşhis ve tespit edilmesinde de katkı sağlamaktadır. MR görüntüleri nörolojik rahatsızlıkların doğru ve etkin bir biçimde tanımlanması ile teşhis edilmesinde ve mevcut tümörlerin bertaraf edilmesinde de kritik bir öneme sahiptir. Günümüzde uygulanan gelişmiş teknolojiler, özellikle tedavi imkânlarının ve hastaların bakım süreçlerinin iyileştirilmesinde de rol oynayarak sağlık hizmetlerinin kalitelerinin artırılmasına etki etmektedir [33]. Bu gelişmiş teknolojik araçlar, bilim insanları ve özellikle doktorların beyni etkileyen farklı hastalıkları tanımlamasına, beynin fonksiyonlarının iyileştirilmesini ve çeşitli sağlık sorunlarının tedavi edilmesini amaçlayan tedavi uygulamaları ile tıbbi teknolojileri geliştirmelerine yardımcı olmaktadır [34].

2.2. Beyin Tümörü

Beyin tümörleri hastaların beyinlerinde ya da beyinlerinin çevrelerindeki hücrelerde oluşan anormal büyümeler sonucunda meydana gelmektedir. Bireylerin beyinlerinde veya beyinlerinin çevrelerindeki hücrelerde anormal büyümelerin olması hastaların nörolojik sistemlerinde aksamalara sebep olmakta ve hastalar için hayati öneme sahip olmaktadır [35]. Uluslararası Kanser Araştırmaları Ajansı (IARC), bütün kanserden kaynaklı ölüm oranlarında beyin tümörü sebebiyle meydana gelen ölümlerin yaklaşık %3 oranıyla 12. Sırada yer aldığını bildirmiştir. Amerika Birleşik Devletleri'nde (ABD) kaydedilen beyin tümörü vaka sayılarının 700.000'i aştığı, bu vakaların yaklaşık %40'lık payının erkeklerden ve %60'lık kısmının ise kadınlardan oluştuğu bildirilebilmektedir. Kanada Beyin Tümörü Vakfı'na göre Kanada da her gün yaklaşık 27 yeni beyin tümörü vakasının teşhis edildiği söylenebilmektedir. Beyin tümörü genel olarak tekrarlayan baş ağrıları, denge bozuklukları, konuşma bozuklukları, iştme problemleri, kişilik bozuklukları, sürekli yorgunluk ve sebepsiz mide bulantısı gibi belirtiler ile kendini göstermektedir [36]. Beyin tümörünün teşhis edilmesi ve tedavisi oldukça zorlu bir süreçtir. Beyin tümörleri çocukluk dönemi hastalıkları arasında ikinci sırada yer alırken 50 yaş ve üzeri dönem için çeşitli organ kanserlerinin beyne olan yayılımı da göz önüne alındığında üçüncü sırada yer alan tümör grubu olduğu söylenebilmektedir. Beyin tümörü hastalarının hayatta kalma süreci ile yaşadıkları rahatsızlıkların etkileri performans durumuna, bilişsel durumlarına, yaşlarına, oluşan tümörlerin boyutlarına ve tümörün tipine göre değişkenlik göstermektedir [37]. Beyin tümörü, bireylerin beyinlerinde var olan hücrelerin kontrolsüz artması sonucunda oluşan bir hastalıktır. Beyin tümörleri iki grupta verilebilmektedir. Bunlar iyi huylu beyin tümörleri (benign) ve kötü huylu (malignant) beyin tümörleridir. İyi huylu olan beyin tümörleri; bireylerin vücutlarının diğer yerlerine yayılmamakta ve genel olarak yavaş bir şekilde büyümektedirler. Kötü huylu beyin tümörleri; bireylerin

vücutlarının diğer yerlerine yayılabilmekte ve hızlı bir şekilde büyümektedirler [38]. Bireylerde beyin tümörlerinin belirtileri genel olarak tümörlerin büyüklüğüne, bulundukları bölgelere ve tümörün tipine göre farklılık göstermektedir. En sık görülen belirtiler arasında baş ağrıları, görme bozuklukları, denge bozuklukları, yürüme bozuklukları, kusma ve nöbetler verilebilmektedir. Beyin tümörlerinin teşhisi genel olarak beyin görüntüleme teknikleriyle yapılabilmektedir. Hastalara teşhis konulduktan sonra ilgili tümörün tipine ve gelişim evresine göre çeşitli tedavi planları uygulanmaktadır [39].

Beyin tümörlerinin tedavisi genel olarak cerrahi uygulama, radyoterapi uygulamaları ya da kemoterapi uygulamaları içerebilmektedir. Cerrahi uygulamalar; ilgili tümörün tamamen ya da bir kısmının çıkarılmasını amaçlamaktadır. Radyoterapi uygulamaları; ilgili tümör hücrelerini öldürmek amacıyla yüksek enerjili ışınların kullanıldığı tedavi tekniğidir. Kemoterapi uygulamaları ise; ilgili tümör hücrelerinin öldürülmesi amacıyla çeşitli ilaçların kullanıldığı tedavi tekniğidir. Beyin tümörlerinin tedavilerinde, hastaların yaşları, genel sağlık durumları ile tümörlerin özellikleri kritik bir öneme sahiptir. Bu bilgiler ışığında hastalara uygulanacak tedavi planları farklılaşabilmektedir [40].

Beyin tümörleri, bütün kanser türlerinin yaklaşık %3'lük bir bölümünü oluşturmaktadır. Her geçen yıl dünya genelinde 200.000'i aşkın beyin tümörü vakasının görüldüğü söylenebilmektedir. Beyin tümörleri her yaş grubunda görülebilmekte ancak sıklıkla 45-65 yaş arasında görülmektedir [41]. Beyin tümörlerinin oluşmaları konusunda kesin bir sebep söylenememektedir. Ancak çeşitli faktörler beyin tümörünün oluşma riskini artırabilmektedir. Bunlar başlıca şu şekilde sıralanabilmektedir;


1. Aşırı düzeylerde radyasyona maruz kalma,
2. Çeşitli kalıtsal hastalıklar,
3. Çeşitli kimyasallara maruz kalma,
4. Çeşitli virüsler [41].

Beyin tümörlerinin engellenmesi için kesin bir çözüm verilememektedir. Ancak bireylerin beyin tümörünün oluşma riskini artıran faktörlerden kaçınması, beyin tümörünün oluşma riskini azaltabilmektedir. Beyin tümörlerinin tedavilerinde özellikle son dönemlerde önemli gelişmeler kaydedilmiştir. Yeni tedavi tekniklerinin geliştirilmesi ve uygulanması, hastaların yaşam süreleri ile yaşam kalitelerinin artırılabilir [42].

2.3. Tümör Türleri

Beyin tümörleri oluştukları bölgelere göre birincil tümörler ya da ikincil tümörler olarak sınıflandırılmaktadır. Birincil tümörler doğrudan beyinde başlamakta, ikincil tümörler ise beyin dışında vücudun farklı yerlerindeki kanserlerin beyne sıçrama yapmasıyla meydana gelmektedir. Bireylerin DNA'larında mutasyonların olması sebebiyle olgunlaşan beyin tümörleri, kontrolsüz

biçimlerde bölünmekte ve anormal hücrelerin sayılarını artmasına sebep olmaktadır. Bu süreçler nörolojik fonksiyonlarda kalıcı hasarlara sebep olabilmektedir. Buna ek olarak zaman içerisinde bireylerin yaşamlarını kaybetmelerine de sebep olmaktadır [43]. Birincil beyin tümörleri ile ikincil beyin tümörleri, hücrelerin yüksek derecelerde anormal büyümesi ve bölünmesiyle merkezi sinir sistemine zarar verebilmekte ya da bireylerin işleyişlerini bozabilmektedir. Birincil beyin tümörleri beynin dokularında yayılma göstermemekte ve iyi huylu olarak nitelendirilmektedirler. Ancak ikincil beyin tümörleri akciğer, meme gibi çeşitli bölgelerdeki kanser hücrelerinin beyne yayılmasıyla meydana gelmekte ve bunlarda kötü huylu olarak nitelendirilmektedir [44]. Beyin tümörleri hem doğrudan beyin dokusundan kaynaklanan primer tümörler hem de çeşitli bölgelerden beyne sıçrayan metastatik tümörler sıklıkla nöbetlere sebep olmaktadır. Bu durumda nöbetlerin türlerinin, ilgili tümörün bulundukları bölgelere ve türlerine göre değiştiği söylenebilmektedir. Beyin tümörü olan vakaların yaklaşık %30-70'i ilgili hastalığın herhangi bir evresinde nöbetler geçirebilmektedir [45]. Şekil 2.2'de beyin tümörü türleri ve açıklamaları görülebilmektedir.



Şekil 2. 2. Beyin tümörü türleri [45]

Metastatik beyin tümörleri bulunan vakaların yaklaşık %40'lık bir bölümü hastalıkları boyunca nöbet geçirmektedirler. Bu nöbetlerin bir kısmı basit parsiyel nöbetlerken bir kısmı da karmaşık parsiyel nöbetlerdir. Basit parsiyel nöbetler; beynin belirli bir bölümünde başlamakta ve bilinç kayıplarına sebep olmamaktadır. Ancak karmaşık parsiyel nöbetler; belirli bir bölgede başlamakta ve bilinç kayıplarına sebep olmaktadır. Ayrıca beyin tümörü olan hastalarda sekonder jeneralize

nöbetlerde görülebilmektedir. Bu nöbet türü beyinde belirli bir noktada başlamakta ve zamanla beyine yayılarak genişlemektedirler. Status epileptikus (SE) ise uzun süren krizler ya da tekrarlayan nöbetler olarak nitelendirilmektedir. Bu nöbetler genel olarak beyin tümörü teşhisi konmuş vakalarda görülebilmektedir. Beyin tümörleri, iyi huylu ya da düşük dereceli (Derece 1 ve Derece 2) ve kötü huylu ya da yüksek dereceli (Derece 3 ve Derece 4) olarak sınıflandırılmaktadır [46].

2.3.1. İyi Huylu Beyin Tümörleri

Benign olarak da bilinen iyi huylu tümörlerde kanserli hücre bulunmamaktadır. Bu tür tümörler genel olarak ameliyat gibi çeşitli cerrahi operasyonlar ile hastalardan alınabilmektedir. Ayrıca bu tür tümörler nadiren tekrarlamaktadır. Çok nadirde olsa bazı vakalarda iyi huylu beyin tümörlerinin kötü huylu beyin tümörlerine dönüştüğü söylenebilmektedir. İyi huylu tümörler kanserli hücre içermemekte ve genel olarak daha az saldırgan hücreler olarak nitelendirilmektedirler. İyi huylu tümörler beyinden kaynaklanmakta, yavaş büyümekte ve bireylerin vücutlarının çeşitli bölgelerine yayılmamaktadırlar [47].

2.3.2. Kötü Huylu Beyin Tümörleri

Malignant olarak da nitelendirilen kötü huylu beyin tümörleri genel olarak daha tehlikeli yapıdadırlar ve çoğunlukla bireylerin yaşamlarında tehlikeli olarak nitelendirilmektedirler. Kötü huylu tümörler hızlı bir şekilde büyümekte ve çevrelerindeki sağlıklı dokulara yayılmaktadırlar. Bu tümörler kanserlidir ve hızlı bir şekilde büyüyerek sınırları belirsiz bir hale gelmektedir. Kötü huylu tümörler, primer malign tümör olarak beyin kendisinden kaynaklanmakta ya da sekonder malign tümör olarak vücudun farklı bölgelerinde başlayıp beyne doğru yayılabilmektedirler [47].

Türkiye’de beyin tümörlerinin insidansları hakkında belirli bir oran verilemese de Sağlık Bakanlığı tarafından 2018 yılında yayımlanan Kanser İstatistikleri Raporu’nda beyin ile sinir sistemi tümörlerinin farklı yaş gruplarında görüldüğü ortaya konulmuştur. Ayrıca beyin tümörlerinin çocukluk döneminde daha sık görüldüğü ve özellikle erkeklerde kadınlara kıyasla daha fazla rastlandığı da vurgulanmıştır [48].

2.3.3. Beyin Tümörlerinin Sınıflandırılması

Dünya Sağlık Örgütü (DSÖ), beyin tümörlerini histolojik özellikleri ile malignite derecelerine göre sınıflandırmıştır. DSÖ’nün 2016-2021 güncellemeleri sonucunda beyin tümörlerinin sınıflandırma sistemleri, ilgili tümörlerin genetik ve moleküler özellikleri de dikkate alınarak tekrardan yapılmıştır. Histolojik sınıflandırma kapsamında gliomalar; ependymona tümörü, astrocytoma tümörü ve oligodendroglioma tümörü gibi çeşitli tümörleri kapsamına almıştır. Gliomalar beyin tümörlerinin en yaygın türü olarak verilebilmektedir ve bireylerin merkezi sinir sistemlerinde

görülen tümörlerin yaklaşık %30'luk bir bölümünü oluşturmaktadırlar. Meningiomalar ise beyin zarlarından kaynaklanmaktadır. Meningiomalar genel olarak benign (iyi huylu) tümörlerdir, yavaş büyümektedirler ve cerrahi operasyonlar ile bertaraf edilebilmektedirler [49]. Sinir kılıfı tümörleri başlıca Neurofibroma ve Schwannoma olarak verilebilmektedir. Schwannomalar genel olarak işitme sinirlerini etkilemekte ve işitme kayıplarına sebep olan benign (iyi huylu) tümörlerdir [50]. Embriyonel tümörler; Medulloblastoma gibi çocukluk dönemlerinde sıklıkla görülen tümörlerdir. Bu tümör tiplerinden malign beyin tümörleri, çocuklarda daha sık görülebilmektedir. Ayrıca bu tümörler beyincikte yer almaktadırlar. Malignite derecesi toplamda dört kategoride verilebilmektedir. Bunlar; Grade 1, Grade 2, Grade 3 ve Grade 4'tür. Grade 1; iyi huylu tümörler olarak nitelendirilmektedir. Bu tümörler genel olarak yavaş büyümekte ve cerrahi operasyonlar ile tamamen bertaraf edilebilmektedir [49]. Grade 2; düşük düzeyli malign tümörlerdir. Grade 2 gliomalar ise biraz daha yavaş büyüyen ancak zaman içerisinde daha malign hale gelen tümör tiplerindendir [51]. Grade 3; orta dereceli malign tümörlerdir. Anaplastik gliomalar olarak da nitelendirilmektedirler. Ayrıca bu tümör tipleri daha hızlı büyümekte ve daha agresif tümörler olarak bilinmektedir [49]. Grade 4; yüksek dereceli malign ve agresif tümörlerdir. Glioblastomalar ise en agresif beyin tümörlerindendir ve genel olarak tanının konulmasının ardından hızlı bir biçimde ilerlemektedirler [51].

Moleküler özellikler ile genetik özellikler beyin tümörlerinin sınıflandırılmasında önemli bir role sahiptir. Bu sınıflandırma da tümörlerin genetik mutasyonları, epigenetik değişiklikleri ve moleküler belirteçler dikkate alınmaktadır. İzositrat dehidrojenaz (IDH) mutasyonları, gliomaların sınıflandırılmasında kritik öneme sahip belirteçlerden bir tanesidir. IDH mutant gliomalar, IDH wildtype gliomalara kıyasla daha iyi prognoza sahiptirler. 1 p/19q kodeksiyonları, oligodendrogliomaların tanılarında kullanılmaktadır. Genel olarak daha iyi tedavi yanıtlarıyla ve prognozlarla ilişkilidirler. 1 p/19q kodeksiyonlarının varlığı, oligodendrogliomaların kemoterapiye daha iyi yanıtların alındığını göstermektedir [51]. MGMT metilasyonları, glioblastomaların tedavi yanıtları ile prognozlarını etkileyen genetik belirteçlerden bir tanesidir. MGMT promotör metilasyonları, temozolomid tedavilerinde daha iyi yanıtların elde edildiği glioblastoma hastalarının belirlenmesinde kullanılmaktadır [50].

Klinik belirteçler ile radyolojik bulgular da beyin tümörlerinin sınıflandırılmasında kullanılmaktadır. Görüntüleme yöntemleri, tümörlerin yerlerini, boyutlarını ve çevre dokularla olan ilişkilerinin incelenmesinde kullanılmaktadır. Supratentorial (beynin üst kısmı) ile infratentorial (beynin alt kısmı) olarak iki kategoriye ayrılmaktadır. Supratentorial tümörler genel olarak serebral hemisferlerde yer almaktadır. İnfratentorial tümörler ise beyincik ile beyin sapında yer almaktadırlar [52]. MR ile bilgisayarlı tomografi (BT) görüntüleme teknikleri, tümörlerin heterojen yapılarını, kist oluşumlarını, nekroz alanlarını ve kontrast tutulumları incelemek amacıyla


kullanılmaktadır. Radyolojik görüntülemeler tümörlerin malignite dereceleri ile cerrahi rezek edilebilirlik durumunun değerlendirilmesi amacıyla kritik bir öneme sahiptirler [53].

2.4. Beyin Görüntüleme Yöntemleri

Bireylerin beyinlerinde oluşabilecek herhangi bir hasar durumunda ilgili hasarın mevcut durumuna göre beyin görüntüleme yöntemleri kullanılmaktadır. Bireylerin beyinlerinin beyin çeperlerinin zayıflaması, beyin çeperlerinin genişlemesi, beyinde baloncuk oluşması ve buna benzer durumlardan sebep meydana gelen kanamaların teşhis edilmesinde başlıca; H215O PET beyin anjiyografisi, BT anjiyografisi, MR görüntüleme ve MR anjiyografisi tekniklerinden biri kullanılmaktadır [54].

2.4.1. BT (Bilgisayarlı Tomografi)

BT'nin geliştirilmesi özellikle radyolojinin evrimsel sürecinde kritik bir öneme sahiptir. BT, bireylerin vücutlarının içyapılarının kapsamlı bir şekilde kesitsel görüntülerin üretilmesi amacıyla kullanılmaktadır. BT genel olarak bilgisayar teknolojilerini kullanarak vücut yapılarının kesitsel görüntülerini almaktadır. Bu süreç, radyolojik görüntüleme açısından önemli bir gelişim süreci olarak verilebilmektedir. BT teknolojisinin getirmiş olduğu yenilikler, doktorların mevcut hastalıkları daha doğru bir biçimde teşhis etmelerine ve gerekli tedavi planlarını etkin bir şekilde belirleyebilmelerine katkı sağlamıştır. BT teknolojisi, hastaların vücutlarının iç bölümlerini katman katman olarak incelemekte, daha önceki zamanlarda mümkün olmayan detayların görülmesini sağlamıştır. Radyolojinin hızlı bir şekilde gelişmesi ile modern tıbbın çeşitli alanlarında büyük avantajlar doğurmuştur. 1917 yılında J. Radon tarafından nesnelerin projeksiyonlarının çok boyutlu oluşturulabileceği teorisi ortaya atılmıştır. Klinik ortamlarda ilk kez BT, 1972 yılında G.N. Hounsfield tarafından X ışını ünitesi ile geliştirilmiştir. 1970'li yıllarda BT aracılığıyla beyin çeşitli kısımlarından farklı kesitler alınmış ve anatomik yapının oluşma süreçleri görüntüleme yöntemleriyle izlenmeye başlamıştır [55]. Şekil 2.3'de BT teknolojisinin çalışma prensibi görülebilmektedir.



Şekil 2. 3. BT'nin çalışma prensibi [56]

Şekil 2.3'den de görüldüğü gibi BT görüntülemenin temel prensibi, hastaların etrafında tam tur dairesel tarama yapılmasıyla çeşitli açılardan elde edilen 2D X ışını projeksiyonlarının kullanılmasıdır. Bu projeksiyonlardan elde edilen görüntüler geri çatma algoritmalarıyla kesitsel görüntüleme işlemi yapılabilmektedir. BT'nin en temel üç bileşeni bulunmaktadır. Bunlar; düzlemsel röntgen görüntüleme sistemlerinde olduğu gibi X ışını tüpü, hastalar ile dedektör sistemleridir [56].

2.4.2. MR (Manyetik Rezonans Görüntüleme)

MR tekniği, çoklu düzlemde görüntü alma kapasitesine sahip, iyonlaştırıcı radyasyon bulunmayan, çeşitli diziler kullanan lezyonları tespit etmektedir. Ayrıca bu teknik lezyonların tanımlanmasında da kullanılmaktadır. Hastalara yönelik doğru tanımlar için doktorun şüphelendiği hastalığa uygun protokoller hazırlanması gerekmektedir ve lezyonların farklı dizi görünümünün iyi bilinmesi gerekmektedir [57]. MR görüntüleme işleminde hastadan alınan sinyallerin yoğunluklarının doku tipine göre değişmesi, görüntüleme işleminin temel prensibini oluşturmaktadır. MR tekniğinde sürekli hidrojen kullanılmaktadır. Bunun en temel nedeni, tek proton içermesi ve insanların dokularında yoğun olarak bulunan elementlerden olmasıdır. Radyo dalgaları kullanıldığında ise hidrojen atomları manyetik alanların etkisiyle düzenli olarak hizalanmaktadır. Bu dizilimler esnasında elde edilen yoğunluklara göre bilgisayar ortamlarında görüntüler oluşturulmaktadır [58]. MR görüntüleme tekniğinin en temel avantajlarından bir tanesi de yumuşak doku kontrastlarını yüksek çözünürlüklerde sunuyor olmasıdır. Bu durum özellikle beyin, yumuşak doku ve kas-iskelet sistemlerinin incelenmesinde kritik bir öneme sahiptir. Buna ek olarak MR görüntülemenin non-invaziv bir teknik olduğu da söylenebilmektedir. Bu sebeple tekrarlanabilir olduğu, hastalıkların takiplerinin yapılabilir olduğu ve hastaların tedavilere vermiş oldukları yanıtların incelenebilir olduğu bildirilebilmektedir [59].

2.4.3. Pozitron Emisyon Tomografisi (PET)

PET özellikle tıbbi görüntülemelerde kullanılan nükleer tıp tekniklerinden bir tanesidir. Radyoaktif maddelerin yaymış olduğu pozitronların tespit edilmesini sağlamak ve bireylerin vücutlarının içindeki biyokimyasal süreçler ile fizyolojik süreçleri görselleştirmektedir [60]. PET genel olarak kanser tanısı, kalp hastalıklarının tanısı, nörolojik bozuklukların tanısında ve ilgili hastalıkların tedavi süreçlerinde yaygın olarak kullanılmaktadır. Bu yöntemde radyoaktif izotoplar vücut içerisine enjekte edilmektedir. Ardından vücut içine giren izotoplar, pozitronlar yaymaktadırlar. Pozitronlar, elektronlar ile etkileşime girmekte ve gama ışınlarını oluşturmaktadırlar. Gama ışınları PET tarayıcıları aracılığıyla tespit edilmektedir. Bu durum sonucunda hücresele seviyelerde metabolik aktiviteler yüksek çözünürlük ile görüntülenebilmektedir [61]. PET yönteminin en önemli avantajı, kanser hücreleri gibi yüksek metabolik aktivitelere sahip olan dokuların erken aşamalarda tespit edilmesini sağlamasıdır. Ayrıca kalp hastalıkları ile beyin hastalıklarının tanısında ve takip edilmesinde de kritik bir öneme sahiptir [62]. Bu noktada radyoaktif izotopların kullanılması ve yüksek maliyetli olması açısından dezavantajlı olduğu da söylenebilmektedir. Beynin yapısına bağlı olarak kullanılan çeşitli bilgisayarlı tıbbi yöntemlerde bulunmaktadır. Bunlar başlıca; MR Spektroskopi (MRS), Difüzyon MR, Difüzyon Tensor Görüntüleme (DTI), Single Photon Emission Computed Tomography (SPECT) ve Magnetoensefalografi (MEG) olarak verilebilmektedir [63].

Günümüzde beyin tümörünün teknolojinin de kullanılmasıyla farklı yöntemlerle teşhis ve tanı edildiği bilinmektedir. Bu kapsamda beyin tümörlerinin tespitinde geleneksel modellere ek olarak aktif olarak kullanılan teknolojik bir yöntem de makine öğrenmesidir. Bir sonraki bölümde makine öğrenmesiyle ilgili kapsamlı bilgiler sunulmuştur.

3. MAKİNE ÖĞRENMESİ

Arthur Samuel tarafından 1959 yılında makine öğrenmesi, bilgisayarlara açık bir biçimde program yapmadan öğrenme yeteneği veren bir çalışma alanı olarak tanımlanmıştır. Makine öğrenmesi, verilerin ayrıştırılması amacıyla algoritmaların kullanılması, eldeki verilerin öğrenilmesi ve ardından herhangi bir konu üzerinde tahminlerin yapılmasıdır. Makine öğrenmesinde manuel programlama yoktur. Makine öğrenmesinde model, mevcut bir veri seti kullanılarak eğitilmekte ve daha sonra yeni veriler üzerinde öğrenilen görevlerin yerine getirilmesi sağlanmaktadır [64]. Verilerden öğrenmenin etkin bir biçimde yapılabilmesi için örnek vakaların ya da modele girilen girdi parametrelerinin toplanması gerekmektedir. Bu özellik ile modelin eğitilmesi amacıyla kullanılacak olan verilerin yeterli boyutlarda ve yeterli kalitelerde olması gerekmektedir. Makine öğrenmesi yöntemleri, öğrenme süreçlerindeki görevleri, farklılıklardan bağımsız bir şekilde genel olarak bireylerin varoluşlarından beri biriktirdiği bilgiler ile deneyimlere dayanarak doğayı taklit etmeye çalışmaktadır. Makine öğrenme yöntemleri, insan beyni gibi çalışmakta ve insan evrimini ele alan süreçlerden, insanların bilgi edinme ile akıl yürütme teorilerinden ve insan davranışlarının temelindeki sosyolojik teoriden hareketle doğmuştur [65].


Makine öğrenimi, hesaplamalarda ve veri analizlerindeki uygulama alanlarının akıllı davranışlar sergilemelerini sağlayan yapay zeka türüdür. Makine öğrenmesi özellikle Endüstri 4.0'dan itibaren kullanılan önemli teknolojidir. Makine öğrenimi kapsamında hedeflenen uygulamaların yapılabilmesi için belli başlı görevlerin yerine getirilebilmesi amacıyla bilgisayar programı geliştirilmektedir [66]. Kullanılan makineler, kendilerine verilen görevleri yaparak performanslarını geliştirmektedirler. Özetle makine öğrenimi ile bilgisayarların, tecrübelerinden öğrenerek kararlar alması sağlanabilmekte ve mevcut verileri temel alarak tahminler yapabilmesi sağlanabilmektedir. Makine öğrenimi sağlıktan pazarlamaya, finanstan lojistiğe kadar birçok alanda kullanılmaktadır. Makine öğrenimi, kullanılan sektör veya alanlarda önemli düzeylerde yenilikler ve gelişmeler sunmaktadır [67].

Makine öğrenmesi genel olarak herhangi bir problemi, ilgili probleme at olan verileri esas alarak modelleyen bilgisayar algoritmalarına denilmektedir. Mevcut veri setleri ile kullanılan algoritmalarla oluşturulan modeller, en yüksek performansı vermek amacıyla kurulmaktadır. Bu kapsamda çeşitli makine öğrenmesi yöntemlerinin olduğu söylenebilmektedir. Bunlardan başlıcaları; K-en yakın komşu algoritması, karar ağaçları, k-ortalama algoritması, Naive Bayes sınıflandırıcı, lojistik regresyon, destek vektör makinaları ile yapay sinir ağlarıdır. Bunların bir bölümü tahmin ve kestirim yapmak amacıyla kullanılırken bir bölümü de kümeleme ve sınıflandırma yapmak amacıyla kullanılmaktadır [68]. Bu tekniklerde öğrenme stratejileri; denetimli, denetimsiz ve takviyeli olmak üzere üç kategoriye ayrılmaktadır. Denetimli öğrenmede, oluşturulan modelle, bir grup girdi değerine karşılık gelen değerlere ait hedef değerleri

verilmektedir. Ardından bunların arasındaki ilişki öğrenilmekte ve hedef değerlere en yakın çıktıların üretilmesi amaçlanmaktadır. Elde edilen en yüksek performanslı model, yeni girdi değerleri için en yakın çıktıyı vermektedir. Denetimsiz öğrenme, hedef değerleri olmadan yalnızca girdi değerleri arasındaki ilişkiyi ortaya çıkarmayı amaçlamaktadır. Modeldeki ilişkiler ile birbirine yakın değerler gruplandırılmakta yani kümeleme işlemi yapılmaktadır. Takviyeli öğrenmede ise hedef çıktıyı vermek için elde edilen çıkışın verilen girişe karşılık iyi veya kötü olarak değerlendirilmek amacıyla bir kriter kullanılmaktadır [69].

3.1. K En Yakın Komşu (KNN) Algoritması

Sınıflandırma algoritması olan KNN, çeşitli sınıflara ayrılmış veri noktaları bulunan veri tabanları kullanmaktadır. Ayrıca KNN algoritması kendisine verilen örnek veri noktalarını, sınıflandırma problemi olarak sınıflandırmaya çalışmaktadır. Genel olarak KNN temel veri dağılımlarını varsaymamaktadır. Bu sebeple “parametrik olmayan” olarak tanımlanmaktadır. KNN algoritmasının uygulaması oldukça kolaydır ve basit bir şekilde uygulama yapılabilir [70]. Ayrıca KNN algoritmalarında modellerin oluşturulması ucuz olduğu için sıklıkla kullanılan bir teknik olarak da verilebilmektedir. Buna ek olarak KNN algoritmasının çok modlu sınıfların oluşturulabilmesi amacıyla çok uygun bir teknik olduğu da söylenebilmektedir. Bu noktada KNN algoritmasının bilinmeyen verilerin sınıflandırılmasında biraz daha pahalı olduğu bilinmektedir [71]. Şekil 3.1’de KNN algoritması görülebilmektedir.




Şekil 3. 1. KNN algoritması örneği [72]

Şekil 3.1’de de görüldüğü gibi $K=3$ değeri için hesaplamalar yapılmış ve düğüme en yakın üç komşu belirlenmiştir. Belirlenen en yakın üç komşudan ikisi Sınıf 1 grubuna bir tanesinin ise Sınıf 2’ye ait olduğu söylenebilmektedir. Ayrıca iki tanesinin Sınıf 1’e ait olması sonucu test düğümünün de Sınıf 1’e ait olduğu görülebilmektedir [72].

3.2. Destek Vektör Makineleri (DVM)

Hiper düzlemler sonsuz sayıda çizgiler çizseler de bu durum sonucunda yüksek performanslar garanti edilememektedir. Bu sebeple DVM’lerin, sınıflandırmalar için kullanılan hiper düzlemlere paralel olduğu ve bu düzlemin bir tarafında yer aldıkları söylenebilmektedir. Bunlar genel olarak Destek Vektör Sınıflandırıcı olarak nitelendirilmektedir. Ancak bunlar regresyon için kullanılırsa Destek Vektör Regresyon algoritması olarak ifade edilmektedirler. DVM algoritmaları yüksek doğruluk vermektedirler. Ancak bu algoritmaların işleme süreleri oldukça uzundur [73]. Bu sebeple DVM’ler genel olarak küçük veri setleri için ideal bir yöntemdir. Temel prensipleri çeşitli sınıfların en iyi biçimlerde ayrıldığı optimal hiper düzlemin bulunmasını sağlamaktır. DVM algoritması yüksek boyutlu verilerde iyi ve etkin bir şekilde çalışabilmekte ve boyutluluk problemlerini en aza indirebilmektedir. Bu algoritmanın aşırı öğrenmelerinin diğer algoritmalara göre daha düşük olduğu da söylenebilmektedir. Doğrusal DVM algoritmaları doğrusal olarak ayrılan veri kümelerinde kullanılırken, doğrusal olmayan DVM algoritmaları ise doğrusal olarak ayrılamayan veri kümeleri için kullanılmaktadır [74]. DVM’ler mevcut veri setlerini en iyi biçimlerde ayıran optimal hiper düzlem bulmak amacıyla çeşitli biçimlerde çizilen hiper düzlemler arasından seçim yapmaktadırlar. Algoritmadaki karar sınırları ise herhangi bir sınıfın çeşitli destek vektörlerine dokunmaktadır. İki karar sınırı arasındaki mesafelere marjin denilmektedir. Marjinler, sınıflandırıcılardaki hata miktarlarını ifade etmektedir. Algoritmadaki marjinlerin sayısı ne kadar büyükse sınıflandırma hatasının o denli azalma olasılığının olduğu söylenebilmektedir. DVM algoritmalarındaki en temel amaç, hata miktarlarının en aza indirilmesi ve en iyi ayracın belirlenebilmesini sağlamaktır [75]. Şekil 3.2’de destek vektörleri örneği görülebilmektedir.



Şekil 3. 2. Destek vektörleri [76]


Şekil 3.2’den de görüldüğü gibi hatanın minimum düzeyde olduğu ve birbirine paralel olan iki destek vektörü seçilmektedir. Ayrıca düzlemler arasındaki uzaklıklar da en yüksek düzeylere çıkarılmaktadır. Ardından iki vektörün orta noktalarındaki “w” vektörü seçilmektedir. Daha sonra yeni “x” için “ $y=wx+b$ ” hesaplanmakta ve veri setinin sınıfına karar verilmektedir. Hesaplama sonucunda $y \leq 0$ ise verinin birinci sınıfta olduğu, $y > 0$ ise verinin ikinci sınıfta olduğuna karar verilmektedir [76].

3.3. Lojistik Regresyon

Veri setlerindeki sınıflandırma problemleriyle başa çıkılabilmesi amacıyla kullanılan yöntemdir. Lojistik regresyon, girdi değişkeninin değerlerine göre olayların olma olasılıklarını tahmin etmektedir. Lojistik regresyon genel olarak kategorik hedef değişkenlerinin tahminiyle ve lineer regresyon ise sürekli değişkenlerin değerlerini tahmin etmeyle ilgilenmektedir. Lojistik regresyon kullanıcılarına hesaplama verimliliği ve uygulama basitliği sunmaktadır. Ayrıca modellerin eğitim süreçlerinde düzenleme kolaylığı ile etkinlik kolaylıkları da sağlamaktadır. Bu sebeple birçok uygulama alanında avantajlı bir algoritmadır ve sıklıkla kullanılmaktadır. Lojistik regresyon sıklıkla endüstride karşılaşılan sorunların çözülmesi amacıyla kullanılmaktadır [77]. Bu algoritmaların çıktıları olasılık skoru vermektedir. Bu sebeple problemlerin çözülebilmesi amacıyla kullanılan özel performans metriklerinin belirlenmesi ve hedeflerin sınıflandırılması için kullanılacak bir kesimin elde edilmesi gerekmektedir. Lojistik regresyon, kullanılacak verilerdeki küçük gürültülerden ve çoklu doğrusallıklardan etkilenmemektedir. Bu doğrultuda Lojistik regresyonun karar yüzeylerinin lineer olmadığı söylenebilmektedir. Ayrıca doğrusal olmayan problemlerin çözülmesinde etkili bir rol oynayamamaktadır [78].


3.4. Yapay Sinir Ağları

Yapay sinir ağları genel olarak insan beyinde bulunan sinirlerin çalışma prensiplerini taklit etmektedir. Yapay sinir ağları, herhangi bir işlevi yapma tekniğini modellemek amacıyla oluşturulan sistemlerdir. Yapay sinir ağları genellikle ses tanıma, otomasyon, üretim süreçleri, görüntü işleme süreçleri ve spor sektörü başta olmak üzere çok çeşitli uygulamalarda kullanılmaktadır. 1943 yılında ilk sinir ağı modellemesi Walter Pitts ile Warren Mc Culloch tarafından yapılmış ve "The Logical Calculus of the Ideas Immanent in Nervous Activity" adlı makale de açıklanmıştır [79]. Şekil 3.3'de insanların sinir hücrelerinin yapısı görülebilmektedir.



Şekil 3. 3. İnsanların sinir hücrelerinin yapısı [80]

Şekil 3.3'den de görüldüğü gibi insan beyindeki sinir hücreleri dendrit, çekirdek, hücre gövdesi ve akson bölümlerinden oluşmaktadır. Yapay sinir ağları da insan beyinde bulunan dendrit, hücre gövdesi ve aksonlara benzeyen yapay birimlerden oluşmaktadır [80]. Şekil 3.4'de yapay sinir hücrelerinin yapısı görülebilmektedir.



Şekil 3. 4. Yapay sinir hücrelerinin yapısı [81]

Şekil 3.4’den de görüldüğü gibi insan beyninde bulunan dendritler yapay sinir ağlarındaki girdileri, çekirdek düğümler yapay sinir ağlarındaki sinapslar ağırlıkları ve aksonlar ise yapay sinir ağlarındaki çıktıları ifade etmektedir [81]. Yapay sinir ağları toplamda üç katmandan meydana gelmektedir. Bunlar;


1. Girdi katmanları: Girdi katmanları yapay sinir ağlarındaki ilk katmandır. Bu katmanda veriler işlenmektedir. Modellerin işlevselliği açısından oldukça önemli bir katmandır. Bu ilk aşamada verilerin doğru bir biçimde işlenmesi yapay sinir ağlarının başarılı sonuçlar verebilmesi amacıyla etkin bir şekilde tasarlanmalıdır.
2. Gizli katmanlar: Yapay sinir ağlarının öğrenebilmesi ve doğru tahminlerin yapılabilmesi amacıyla gizli katman oldukça önemli bir bileşendir. Ağlarda çok sayıda gizli katmanlar bulunmaktadır. Ancak ağlarda çok sayıda gizli katmanın bulunması, verilerin hesaplanma güçlerinde artışlara ve aşırı öğrenme risklerini de doğurmaktadır.
3. Çıktı katmanları: Yapay sinir ağlarının mevcut verileri analiz etmesi ve bir çıktının üretilmesini sağlamaktadır. Çıktı katmanları yapay sinir ağlarının son katmanlarıdır ve mevcut problemlerin çeşitlerine göre farklı biçimlerde tasarlanabilmektedirler [82].

3.5. Derin Öğrenme

Derin öğrenme 1950’li yılların üçüncü çeyreğinde genel olarak makine öğrenmesi olarak adlandırılan yapay zekanın bir alt kümesi olarak ortaya çıkmıştır. Derin öğrenme özellikle son yıllarda birçok alanda devrim yaratmaya başlamıştır. Sinir ağları ise makine öğreniminin bir alt dalıdır ve derin öğrenme algoritmalarının öncüsü olan yapay zekanın bir kolu olarak verilebilmektedir. Derin öğrenme doğduğu andan itibaren neredeyse tüm uygulama alanlarında ileri düzeyli performanslar göstermiştir. Ancak sistemdeki tüm başarı, sistemin bir sonraki eksikliğini de ortaya koymaktadır. Derin öğrenmenin asıl doğuşu 2006 yılından sonra makine öğrenmesinin alt sınıfı olarak kabul edilmesiyle başlamıştır [83]. Öğrenme süreçleri, derin öğrenme için eğitim süreçleridir. Öğrenilen modelin belirli görevleri yerine getirebilmesi amacıyla model parametrelerinin sistemlere doğru girilmesi gerekmektedir. Yapay sinir ağları, parametre ağırlıklıdır ve doğru değerlerin ve doğru ağırlıkların girilmemesi sonucunda elde edilecek çıktılarında hatalı olabileceği söylenebilmektedir. Derin öğrenme özellikle öğrenme ile örüntü sınıflandırmaları için kullanılan hiyerarşik algoritmik mimarileri olan doğrusal olmayan veri işlem birimlerinin çeşitli evresinde giriş ve çıkış katmanlarının bulunduğu birkaç katmandan meydana gelmektedir [84]. Veri setlerine dayalı öğrenme teknikleri, temsili öğrenme olarak nitelendirilmektedir. Derin öğrenme esasen görev tabanlı çalışmaktadır. Bu yaklaşıma evrensel öğrenme yaklaşımı da denilmektedir. Derin sinir ağları olarak da nitelendirilen derin öğrenme, biyolojik görme ve beyin bilgi işleme süreçlerinin modellenmesiyle doğmuştur. Derin öğrenme, makine öğreniminin bir parçasıdır. Makine öğrenmesinin farklı alanlara göre uyarlanabilir olması sonucunda çeşitli makine öğrenimi sorununun çözülmesi amacıyla yaygın bir şekilde kullanılmaya başlamıştır. Derin öğrenme, özellik çıkarma ile dönüştürmek amacıyla çeşitli doğrusal olmayan işlem katmanını kullanmaktadır. Her ardışık katman, bir önceki katmandaki çıktıyı alarak girdi olarak kullanmaktadır [85]. Algoritmalar denetimli ya da denetimsiz olarak iki kategoriye ayrılmaktadır. Derin öğrenme kapsamında veriler birden fazla özellik seviyesinin öğrenilmesine dayanan bir yapıya sahiptir. Üst düzey özellikler, alt düzey özelliklerden türetilmekte ve hiyerarşik bir temsil meydana getirmektedir. Bu temsiller, soyutlamanın farklı seviyelerine karşılık gelen çeşitli temsil seviyelerini öğrenmektedir. Bu kapsamda derin öğrenmenin verilerin temsillerinden yola çıkarak öğrenme sürecini gerçekleştirdiği söylenebilmektedir. Herhangi bir görsel için temsil denildiğinde, piksel başına yoğunluk değerlerinin vektörü ya da kenar kümeleri veya özel şekiller gibi çeşitli özellikler düşünülebilmektedir. Bu özelliklerin bazıları verileri daha iyi temsil etmektedir. Derin öğrenme teknikleri, elle oluşturulan özellikler yerine verileri en iyi temsil eden hiyerarşik özellik çıkarımı için etkili algoritmaları kullanmaktadır [86].

Yapay zekanın gelişmesiyle ve veri miktarlarının artmasıyla birlikte daha karmaşık model yapıları ile yeni algoritmaların geliştirilmesi zorunlu hale gelmiştir. Bu kapsamda, derin öğrenme teknikleri bilgisayarların daha karmaşık problemleri daha etkin biçimlerde çözebilme kapasitelerini

artırmıştır. Özellikle 1980 yılının son çeyreğinde yapay zeka, yapay sinir ağları ve makine öğrenmesi konuları ilgi gören alanlar haline gelmiştir. Her ne kadar yapay sinir ağlarına olan ilgi 1980’li yıllarda fazla olsa da zaman içerisinde bu teknolojiye olan ilgi azalmaya başlamıştır. Ancak 2006 yılında Hinton ve arkadaşları tarafından “yeni nesil sinir ağları” olarak adlandırılan “Derin Öğrenme” ortaya konulmuştur. Derin öğrenmenin temeli ise yapay sinir ağlarına dayanmaktadır [87]. Derin öğrenmenin daha iyi anlaşılabilmesi amacıyla insan öğrenmesiyle karşılaştırılması önemli görülmektedir [79]. Şekil 3.5’de derin öğrenme ile insan öğrenmesinin karşılaştırılması analoji örneğiyle görülebilmektedir.




Şekil 3. 5. Derin öğrenmeyle insan öğrenmesinin karşılaştırılması [79]

Şekil 3.5(a)’dan da görüldüğü gibi ilköğretim öğrencisine ilk olarak Beyin Manyetik Rezonans Görüntüleme (MR) görsellerinden T1 ağırlıklı görüntü ile T2 ağırlıklı görüntüler verilmiştir. Ardından öğrenciden iki görüntüyü ayırt etmesi istenmiştir. Ancak öğrencinin beyin anatomisi ile MR hakkında bilgisinin olmaması sebebiyle iki görüntü hakkında verilen bilgiler yetersiz kalmıştır. Bu durum sonucunda teknik değiştirilmiş ve yeni teknik adımları planlanmıştır. İlk olarak öğrencinin önüne iki adet kutu konulmuş ve kutuların üzerine “0” ile “1” yazılmıştır. Ardından öğrenciden T1W1 görüntüsünü “0” yazan kutuya, T2W1 görüntüsünü de “1” yazan kutuya koyması beklenmiştir. İkinci aşamada, öğrenci yine tam olarak ne yapacağını bilmediği için rastgele bir kutu seçerek görüntüleri kutuların içine atmıştır. Üçüncü aşamada öğrencinin cevapları kontrol edilmiştir. Dördüncü aşamada öğrencinin cevaplarının doğruluğuna bakılmıştır. Öğrenciye aynı

uygulamanın birden fazla kez yapılması sonucunda öğrenci hangi görüntünün hangi numaralı kutuya atılacağını öğrenmiştir. Ancak bu noktada öğrencinin görüntülerdeki farkları anlamadan ya da tanımlarını bilmeden cevapları ezberlediği söylenebilmektedir. Öğrenilen mevcut bilgilerin geçerliliğinin değerlendirilebilmesi amacıyla öğrenciye yeni görüntüler verilmiş ve deneyden geçip geçemeyeceği test edilmiştir. Deney sonucunda öğrencinin seçimleri kontrol edilmiştir. Ancak bu uygulama da dördüncü aşama geçilmektedir. Deney, “eğitim süreci” ile “sınav doğrulama süreci” arasında doğruluk bakımından ciddi farklar varsa öğrencinin anlama durumunun yeni görüntülerle ayarlanamayacağı kabul edilmektedir. Şekil 3.5(b)’den de görüldüğü gibi bildirilen süreler derin öğrenme için geçerli olmaktadır. Derin öğrenme modelleri genel olarak insanların beyinlerindeki sinir ağlarına benzeyen çok sayıda parametreden meydana gelmektedir. Derin öğrenmede ilk olarak modele görüntü girilmektedir. İkinci aşamada cevap üretilmesi amaçlanmaktadır. Üçüncü aşamada üretilen cevap, kutu numarası olmamakta her kutunun istatistiğini yani olasılığını (sınıfını) vermektedir. Bu aşamada en yüksek olasılığa sahip model, cevap olarak alınmaktadır. Modelin çıktısıyla kayıp olarak sayılan ideal cevap arasında farkların boyutları ölçülmektedir. Bu ölçümler için kayıp fonksiyonları elde edilmektedir. Dördüncü aşamada modelin eğitim aşamasındaki kayıpların minimum seviyelere indirgenebilmesi amacıyla mevcut modelin parametreleri güncellenmektedir. Güncelleme işlemine ise “geri yayılım” adı verilmektedir. Model, mevcut veriler ile birden fazla eğitilmekte ve eğitimler esnasında gerçekleştirilen tekrarlar “epoch” adı verilmektedir. Ardından doğrulama sürecine geçilmekte ve bu aşamada kayıplar hesaplanmaktadır. Ancak bu noktada dördüncü adımın atıldığı söylenebilmektedir. İdeal sonuçlar, eğitim süreci ile doğrulama sürecinin doğruluğunun artırılmasıyla ve kayıpların ise minimize edilmesiyle sağlanmaktadır. Model, eğitim için kullanılan verilerin aşırı uyarlanmış olması ve doğrulama verilerinde ayarlamaların yapılamaması sonucunda eğitim ve doğrulama arasındaki kayıpların farkını artırmaktadır. Bu duruma “aşırı öğrenme” denilmektedir [88].

3.6. Evrişimli Sinir Ağları (ESA)

Evrişimli sinir ağları çeşitli alanlarda kullanılan derin öğrenme algoritmasıdır. Evrişimli sinir ağları genel olarak yüz ve ses tanıma, görüntü işleme ve sınıflandırma, nesnelerin tespiti gibi çeşitli alanlarda başarılı bir şekilde uygulanabilmektedir. ESA’lar, konvolüsyonel matematiksel işlemlere dayanmaktadır. ESA’ların temeli, Hubel ve Wiesel tarafından yapılan maymunların ve kuşların görsel kortekslerinin incelenmesi çalışmasıyla atılmıştır. Ardından Kunihiko Fukushima tarafından evrişimli sinir ağları alanında evrişim süreci ortaya konulmuştur [89]. Şekil 3.6’da ESA’nın mimarisi ile katmanları görülebilmektedir.



Şekil 3. 6. ESA'nın mimarisi ile katmanları [90]

Şekil 3.6'dan da görüldüğü gibi tüm sinir ağlarında olduğu gibi ESA'larda da katmanlar bulunmaktadır. Bu katmanlar, düzenlenebilir yapıda olup hiyerarşik temsilleri öğrenen nöron yapılarına dayanmaktadır. Katmanlar arasındaki nöronlar önyargılar ile ağırlıklarla birbirlerine bağlanmaktadır. İlk katman girdi katmanı olup verilerin işlendiği kısımdır. Son katman ise tahmin, sınıflandırma gibi çeşitli sonuçların elde edildiği çıktı katmanıdır. Aradaki katmanlar ise girdilerin öznetelik uzaylarını çıktılar ile eşleştirecek biçimde dönüştürmelerin yapıldığı gizli katmanlardan oluşmaktadır. ESA'lar örüntülerden yararlanabilmek amacıyla gizli katmanlarında en az bir adet evrişimli katman içermelidir [90].

3.6.1. Evrişimli Katmanlar

CNN mimarisinde önemli bileşenlerden bir tanesi evrişim katmanlarıdır. Bu katmanlar, konvolüsyon filtrelerinin yani Kernel'lerin koleksiyonlarından oluşmaktadır. Katmana girdi olarak N-boyutlu metrik olarak ifade edilen bir görüntü, filtrelerle konvolüsyon işlemine alınmakta ve ardından çıkış özellik haritası üretilmektedir. Konvolüsyon filtresi, matris olarak ifade edilen çekirdek tarafından belirlenmektedir. Bu çekirdek ağırlıkları CNN modelindeki ilk aşama olan eğitim sürecinde rastgele sayılar olarak atanmakta ve yapılan her eğitim sürecinde ayarlanarak önemli olan özelliklerin çıkarılmasının öğrenilmesi amaçlanmaktadır [89]. Buna ek olarak ağırlıkların başlatılabilmesi amacıyla kullanılan çeşitli tekniklerde bulunmaktadır. Bu ağırlıklar tüm eğitim süreçlerinde ayarlanmakta ve bu durum sonucunda önemli özelliklerin çıkarılabilmesi öğrenilmektedir. Evrişim işlemi, çoklu kanallı görüntülerinin CNN girdileridir ve geleneksel sinir ağlarına kıyasla vektör formunda değildirler [91]. Evrişim işlemi genel olarak çok kanallı görüntü formatında gerçekleşmektedir. Konvolüsyon işleminin daha iyi anlaşılabilmesi açısından 4x4 boyutlarındaki ve gri tonlarda olan bir görüntünün 2x2 boyutlarındaki rastgele ağırlıklandırılmış çekirdek örneği verilebilmektedir. Bu örnekte ilk olarak çekirdek, mevcut görüntünün tamamında yatay ve dikey olacak şekilde kaydırılmaktadır. Girdi görüntüsüyle çekirdek arasında nokta

çarpımları yapılmakta ve karşılık gelen değerler ilk olarak çarpılmakta ardından toplanarak tek skaler değeri elde edilmektedir. Bu işlem genel olarak kaydırma yapılamayacak düzeye gelinceye kadar tekrar edilmektedir. Ayrıca hesaplanan nokta çarpımlarının değerleri, çıktı özellik haritalarını temsil etmektedir [91].

3.6.2. Havuzlama Katmanları

Havuzlama katmanları genel olarak daha fazla katman karmaşıklıklarının azaltılabilmesi amacıyla örnekleme işleminin yapılarak boyutların azaltılmasını sağlayan işlemlerdir. Bu işlemler genellikle çözünürlüğün azaltılmasına benzemektedir. Havuzlama katmanları modeldeki filtre sayılarını etkilememektedir. Günümüzde kullanılan en yaygın havuzlama tekniği maksimum havuzlama tekniğidir [92]. Bu teknik, görüntüleri alt bölgelere ayırmakta ve yalnızca alt bölgelerin maksimum değerlerini döndürmektedir. Maksimum havuzlama tekniği genel olarak 2x2 boyutlarındaki görsellere uygulanmaktadır. Havuzlama işleme mevcut görüntülerin sol üst kısmında 2x2'lik bloklarına uygulandığında görüntüler iki birim kaydırılmakta ve sağ üst bölüme odaklanarak hareket etmektedirler. Ayrıca bu işlemin azaltma işleminin konum bilgilerini korumadığı da söylenebilmektedir. Bu kapsamda varlıklarının önemli olduğu bilgilerin bulunduğu modelde sadece azaltma işleminin uygulandığı bildirilebilmektedir. Modellerin etkinliklerinin artırılabilmesi amacıyla çeşitli boyutlarda ve çeşitli adımlı filtreler de havuzlama yapılabilir [93].

3.6.3. Tam Bağlantılı Katmanlar

Geleneksel sinir ağlarındaki nöronların düzenlenmesine benzeyen katman tam bağlantılı katmanlardır. Katmandaki tüm düğümler önceki katmanlar ile sonraki katmanlara doğrudan bağlanmaktadır. Havuzlama işlemindeki son karelerde bulunan bütün düğümler, tam bağlantılı katmanlardaki ilk katmana vektör olarak bağlanmaktadır. Tam bağlantılı katmanlar, ESA'lardaki en çok parametre kullanan katmanlar olarak verilebilmektedir [92]. Ayrıca modellerin eğitiminde uzun süreler ile yapılabilir. Tam bağlantılı katmanların eğitim süreçlerinde karmaşık hesaplamalarda çok sayıda parametre içermesi gerekmektedir. Bu durum tam bağlantılı katmanların en önemli dezavantajı olarak verilebilmektedir. Bu sebeple düğüm sayıları ile bağlantı sayılarının minimize edilmeye çalışılması gerekmektedir. Modelden kaldırılan düğümler ile bağlantılar "Dropout yöntemi" ile dengelenmeye çalışılmalıdır [93].


3.7. Transfer Öğrenme ile Hazır CNN'ler

Transfer öğrenme, mevcut bir problemin çözülebilmesi amacıyla çeşitli ortamların eski bilgilerinden faydalanma tekniğidir. Transfer öğrenme de bireylerin öğrenme biçimleri temel

alınmıştır. Bireyler mevcut bir sorunun çözülebilmesi için sıfırdan öğrenme sürecine girmeden mevcut donanım ve bilgilerinden öğrenme işlemi yürütülmekte ve sorunları çözmeye çalışmaktadırlar [94]. Bu noktada bir bireyin herhangi bir enstrüman çalmayı bilmesi başka bir enstrümanı çalma sürecini kolaylaştırmakta ancak herhangi bir enstrümanı çalmayı bilmeyen biri için yeni bir enstrüman çalmayı öğrenmesi zor olması örnek olarak verilebilmektedir. Evrişimli sinir ağlarındaki modellerde de özellikle çok büyük veri setlerinin kullanıldığı eğitim süreçleri günler ve haftalar alabilmektedir. Bu sürecin daha kısa zaman dilimlerinde yapılabilmesi için önceden eğitilmiş ImageNet modellerinin ağırlıklarının kullanılması kolaylık sağlamaktadır. Bu noktada en iyi performansa sahip modellerin kullanılarak eğitim süreçlerinin hızlandırılmasının önemli bir husus olduğu söylenebilmektedir [95].

3.7.1. LeNet 5

Yan Le Cunn tarafından geliştirilen LeNet-5 adındaki ESA modeli ile geri yayılım ve uyarlamalı ağırlıklar kullanılmış ve yapılan bu çalışmalar ile ESA'nın günümüzdeki başarısına katkılarda bulunulmuştur. Geliştirilen bu yapılar birbirini ardına dizilen katmanlardan meydana gelmektedir. Günümüzde kullanılan önemli ve büyük mimarilerin ise LeNet 5'in çeşitli modifikasyonları olduğu söylenebilmektedir [96]. Şekil 3.7'de LeNet ağı örneği görülebilmektedir.



Şekil 3. 7. LeNet ağı örneği [96]

Şekil 3.7'den de görüldüğü gibi LeNet ağı'nın mimarisi genel olarak şu şekilde verilebilmektedir;

- Giriş katmanı: 32x32 boyutlarında gri tonlamalı görüntü kabul edilmektedir.
- Evrişimsel katman C1: 5x5 çekirdek ile tanh aktivasyonlarıyla evrişim uygulanmaktadır.
- Alt örnekleme katmanı S2: 2x2 pencere üzerinde maksimum havuzlama yapılmaktadır.
- Evrişimsel katman C3: 5x5 çekirdek ile tanh aktivasyonlarıyla ikinci evrişim gerçekleştirilmektedir.

- Alt örnekleme katmanı S4: Diğer maksimum havuzlama katmanıdır.
- Tamamen bağlı katman C5: Tanh aktivasyonu ile S4 çıkışına bağlanmaktadır.
- Tam bağlantılı katman F6: Tanh aktivasyonu olan ikinci tam bağlantı katmanıdır.
- Çıkış katmanı: Modelin son sınıflandırma sonucunu oluşturmaktadır [96].

LeNet 5 ağı genel olarak CNN modellerinin görüntü tanıma görevlerinin gerçekleştirilebilmesi amacıyla etkinliğini belirlemeye çalışmaktadır. Bu yönüyle kullanıcılarına avantajlar sağlamaktadır. Evrişim, alt örnekleme ile tamamen bağlantılı katmanları kapsayan mimari ilkeleri, derin öğrenmedeki güncel gelişmeleri de etkilemiştir. LeNet 5 ağının ilk iki katmanı, modelde kullanılan giriş görüntüsünden mekânsal hiyerarşileri ve özellikleri çıkarman amacıyla tasarlanmış katmanlardır [97]. Denklem 3.1’de ağı ait evrişim işleminin formülü görülebilmektedir.

$$S(i,j)=(I \times K)(i,j)= \sum_m \sum_n K(m,n).I(i+m,j+n) \quad (3.1)$$

Denklem 3.1’deki “S(i,j)”; evrişim sonucunu, “I” giriş görselini ve “K” evrişim çekirdeğini ifade etmektedir. LeNet 5 ağı genel olarak bu evrişimli katmanları hiperbolik tanjant aktivasyon fonksiyonunu takip etmektedir. İlk iki katmanın ardından gelen iki katman ise genel olarak havuzlama katmanları olarak nitelendirilen alt örnekleme katmanlarıdır. Bu katmanlar modeldeki önemli özellikleri korumakta ve mekânsal boyutları ile hesaplama karmaşıklıklarını azaltmaya çalışmaktadırlar. Denklem 3.2’de havuzlama işlemi genel olarak maksimum havuzlamanın formülü görülebilmektedir.

$$O_{ij}=\max_m n.I(i+m)(j+n) \quad (3.2)$$


Denklem 3.2’de yer alan “O_{ij}” modelin havuzlama sonucunu, “I” ise modeldeki giriş özellik haritasını ifade etmektedir. Evrişim ile alt örnekleme katmanlarının ardından tamamen bağlantılı üç katman gelmektedir. Bu katmanlar, modelin önceki katmanlarından elde edilen özellikleri esas alarak karar verme işlemini gerçekleştirmektedir. Tamamen bağlantılı katman işlemi, ağırlıklı toplam ile aktivasyon fonksiyonunu içermektedir. Denklem 3.3’de tamamen bağlantılı katman işlemine ait formül görülebilmektedir.

$$y_k = \sigma(\sum_i W_{ki}x_i + b_k) \quad (3.3)$$

Denklem 3.3’de yer alan “y_k”; modeldeki k. nörona ait olan tamamen bağlı katman çıkışını, “W_{ki}”; modeldeki i. Giriş nöronunu k. çıkış nöronuna bağlayan ağırlığı, “X_i”; modeldeki i. Nöron girdisini, “B_k”; biası ve “σ”; modelin aktivasyon fonksiyonunu ifade etmektedir. LeNet ağı için verilen formüllerle birlikte yapılan kapsamlı açıklamalar, LeNet 5’in işlevselliğini destekleyen işlemlere yönelik bilgi vermekte ve sinir ağı mimarileri tarihindeki önemine katkıda bulunmaktadır.

3.7.2. Visual Geometry Group (VGG-16)

VGG-16 ile VGG-19 mimarileri 2014 yılında Karen Simonyan ile Andrew Zisserman tarafından yazılan “Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağlar” isimli makale de ifade edilmiştir. VGG kısaltması, Visual Geometry Group yani Görsel Geometri Grubu olarak nitelendirilmektedir. VGG-16 mimarisi toplamda 16 katmandan meydana gelmektedir. 16 katmanın 13’ü evrişimli, 3’ü ise tamamen bağlı katmanlılardan oluşmaktadır. Ayrıca 2015 yılında düzenlenen ImageNet yarışmasında hata oranı %7,3’e düşürülmüştür. Bu oran, insan hata oranını da geçerek büyük bir başarıyı ortaya koymuştur [98]. Şekil 3.8’de VGG-16 mimarisi görülebilmektedir.




Şekil 3. 8. VGG-16 [99]

Şekil 3.8’den de görüldüğü gibi VGG-16, 224x224 boyutlarında girdi almakta ve daha sonra beş katmanlı bir işlem uygulanmaktadır. Her katmanda küçük boyutlarda filtreler kullanılarak giriş görüntüsünün özelliklerinin çıkarılabilmesi amacıyla tasarlanmaktadır. VGG-16 da toplamda 138.355.752 parametre, üç yoğun katman ve beş adet evrişim bloğu bulunmaktadır. Ayrıca beş adet evrişim bloğunun içerisinde de evrişim katmanları ile havuz katmanları yer almaktadır [99]. Son blokta ise üç evrişim katmanı bulunmaktadır. VGG-16 mimarisinde toplamda beş tane havuzlama katmanı yer almaktadır. Mimarinin ilk beş bloğundan sonraki bloklar da 3B vektörü ile tamamen bağlı katmanlara eklenmiş 1B vektörüne dönüştürülmek amacıyla düzleştirme katmanı yer almaktadır. İlk sıradaki iki tamamen bağlı katmanlarda toplam 4.096 nöron bulunurken son bağlı katmanda da toplamda 1.000 nöron yer almaktadır [100].

3.7.3. Residual Network (ResNet)

Microsoft Research tarafından 2015 yılında geliştirilen Residual Network (ResNet) mimarisi, modellerdeki aşırı öğrenme problemlerinin çözülebilmesi amacıyla geliştirilmiştir. ResNet ağları, VGG ağlarından daha derin yapıdır ancak bu ağlar daha düşük karmaşıklıklara sahiptirler [101]. Şekil 3.9’da ResNet görülebilmektedir.




Şekil 3. 9. ResNet [102]

Şekil 3.9’den da görüldüğü gibi ResNet’de ağların içerisindeki çeşitli katmanlar, gelen verileri atlamakta ve doğrudan çıkışa bağlanmaktadır. Bu duruma “residual connection” yapısı denilmektedir. Bu yapı ile aşırı öğrenme problemleri indirgenebilmektedir. Ağlarda gelen verilerin direkt çıkışa bağlanmaları, ağların öğrenmesi istenen bağlantıları kolay bir şekilde almalarını sağlamaktadır. Ayrıca ağların öğrenme kapasiteleri de artırılabilir. ResNet ağları genel olarak derindirler ancak etkili sonuçlar ortaya koymaktadırlar. Buna ek olarak Batch Normalizasyon gibi çeşitli öğrenme oranlarını artıran faktör özellikleri de içermektedirler [102]. ResNet, VGG-19’den esinlenilerek geliştirilmiştir.

3.7.4. MobileNetV2

MobileNet, Google tarafından 2017 yılında geliştirilmiş ve mobil cihazlarda kullanılabilen bellek kullanımları az olan ve hafif sinir ağları olarak tasarlanmıştır. Mobilnet özellikle gömülü sistemlerde ve hızlı çözüm üretilmesinin amaçlandığı uygulamalarda sıklıkla tercih edilmektedir. MobileNet’in kullanıcılarına en önemli avantajı, düşük hesaplama maliyeti sağlamasıdır [103]. Şekil 3.10’da MobileNet görülebilmektedir.



Şekil 3. 10. MobileNet [103]

Şekil 3.10'dan da görüldüğü gibi toplamda 53 katmanı bulunmaktadır. Bunların 52'si evrişim iken bir tanesi tam bağlantılı katmandır. Ayrıca üç evrişim katmanına bağlı toplamda 16 adet tersine çevrilmiş blok, evrişim katmanı, darboğaz bloğu ve tam bağlantılı katmanlar yer almaktadır. MobileNet'in temel noktası derinlemesine ayrıştırılabilen evrişim katmanı ile noktasal ayrıştırılabilen evrişim katmanının olmasıdır. Bunlardan derinlemesine ayrıştırılabilen evrişim katmanında tüm kanalların ayrı bir şekilde işlenmesi sağlanabilmekte ve hesaplama maliyetleri düşürülebilmektedir. Noktasal ayrıştırılabilen evrişim katmanında ise 1x1 boyutlarında konvolüsyon işlemi yapılabilmektedir. Bu aşamada derinlemesine ayrıştırılabilen evrişim katmanının çıktıları işlenmekte ve çeşitli özellikler bir araya getirilebilmektedir [103]. Şekil 3.11'de MobileNet derinlemesine evrişim katmanının yapısı görülebilmektedir.




Şekil 3. 11. MobileNet derinlemesine evrişim katmanlarının yapısı [104]

Şekil 3.11'den de görüldüğü gibi MobileNet'in derinlemesine evrişim katmanları; giriş katmanı, derinlemesine evrişim, aktivasyon, 1x1 evrişim ve çıkış katmanından oluşmaktadır. Giriş katmanı; RGB görüntüleri ile başlatılmaktadır. Derinlemesine evrişim; tüm giriş katmanları ayrı ayrı olacak şekilde evrişim filtresinden geçirilmektedir. Tüm giriş katmanları yalnızca kendi filtreleriyle evrilmektedir. Giriş katmanında 3 kanal kullanılmışsa bu kapsamda her bir kanal için ayrı bir filtre

uygulanması gerektiği örnek olarak verilebilmektedir. Bu katmanda klasik evrişim katmanlarına kıyasla daha az hesaplama gerekmektedir. Bunun sebebi yalnızca tek bir kanal üzerinde işlem yapılıyor olmasıdır [104]. Derinlemesine evrişimin ardından genel olarak ReLU ya da daha hafif modülü olan ReLU6 aktivasyonu uygulanmaktadır. Bu aktivasyonlar, mevcut negatif değerlerin sıfırlanmasını ve yalnızca pozitif değerlerin sistemde kalmasını sağlamaktadırlar. 1x1 evrişim katmanında, kanal birleşimleri sağlanmakta ve daha fazla özelliğin çıkartılması amaçlanmaktadır. Daha fazla özelliğin çıkarılmasıyla ağı daha derin temsil öğrenmesi sağlanabilmektedir. 1x1 evrişim, girişten çıkan bütün derinlemesine evrilmiş özellikleri birleştirmekte ve çıktı kanal sayısını artırmaktadır. Çıkış katmanında ise softmax katmanları ile sonlandırılmaktadır. Softmax katmanları genel olarak sınıflandırma problemlerinde sıklıkla kullanılmaktadır. Derinlemesine evrişim katmanları hafiflik, hız ve daha az parametre kullanma açısından kullanıcılarına avantajlar sağlamaktadır [104].

3.7.5. InceptionV3

InceptionV3, InceptionV2 ağının temel alınmasıyla geliştirilmiştir. InceptionV3'ü InceptionV2'den ayıran en temel özelliği yalnızca evrişim katmanlarının değil aynı zamanda yardımcı sınıflandırıcı olarak küme normalizasyonunu ve tam bağlantılı katmanları kullanmasıdır. InceptionV3 ağının mimarisi, geleneksel 7x7 evrişim işlemini üç farklı 3x3 evrişim işlemine bölmesine dayanmaktadır. Inception kısmında her birinde 288 filtre bulunan 35x35 boyutlarında üç adet Inception modülü yer almaktadır. Izgara azaltma yönteminin kullanılmasıyla bu boyutlar 17x17 ızgaraya ve 768 filtreye indirgenmektedir. Ardından beş farklı faktörize Inception modülü ile 8x8x1280 boyutlarındaki ızgara oluşturulmaktadır. InceptionV3 ağının hesaplama maliyeti ise GoogleNet'e kıyasla 2.5 kat daha yüksektir ve VGGNet'den daha verimli bir ağıdır [105]. Şekil 3.12'de InceptionV3 ağı görülebilmektedir.




Şekil 3. 12. InceptionV3 ağı [106]

Şekil 3.12’den de görüldüğü gibi InceptionV3 ağı genel olarak 299x299x3 boyutlarında RGB görüntüleri ile çalışmaktadır. Görüntüler modelin giriş katmanından beslenmekte ve ardından boyutları uygun biçimlerde ayarlanmaktadır. İlk evrişim katmanı; evrişim ile maksimum havuzlama kombinasyonları ile başlamaktadır. Bu katmanda, düşük seviyeli özellikler çıkarılabilmektedir. İlk evrişim katmanı genel olarak 3x3 boyutlarında ya da 5x5 boyutlarında filtreler kullanmaktadır. InceptionV3’teki her Inception modülü, farklı evrişim filtrelerinin paralel çalıştığı bir yapıdadır. Bu modüller 1x1, 3x3 ve 5x5 evrişimler ile max pooling işlemlerini paralel olarak kullanmaktadır. Bu paralel evrişimler ile model, çeşitli ölçeklerdeki özellikleri aynı zamanda çıkarabilmekte ve en iyi özellikleri öğrenebilmektedir. Sınırlı boyutlu evrişimlerde, daha verimli hesaplamalar için çeşitli evrişimler faktörizasyonlarla daha küçük boyutlarda yapılabilmektedir. 5x5 evrişiminin iki ardışık 3x3 evrişimine indirgenmesi örnek olarak verilebilmektedir. Bu durum sonucunda işlem maliyetleri ciddi düzeylerde azaltılmış olmaktadır. 1x1 evrişimler hem kanal sayılarını azaltmakta hem de işlem maliyetlerini indirmek amacıyla sıklıkla kullanılmaktadır [106]. 1x1 evrişimler, daha büyük boyutlardaki özellik haritalarının boyutlarını indirgeyerek hesaplama maliyetlerini de optimize etmektedir. InceptionV3, bazı noktalarda max pooling katmanları aracılığıyla uzamsal boyutları küçültebilmekte ve daha soyut özellikler çıkarabilmektedir. Havuzlama katmanları özellikle derin ağlarda bilgi kayıplarının minimize edilmesi amacıyla kullanılabilir. Model genel olarak Global Ortalamalı Havuzlama’yı kullanarak özellik haritalarının tüm katmanlarındaki bütün piksel değerlerinin ortalamasını almaktadır. Bu durum modelin son katmanında daha az parametre ile kullanılmasını ve genel olarak aşırı öğrenmenin engellenmesini sağlamaktadır [106]. Global Ortalamalı Havuzlama işleminin ardından bir ya da iki tam bağlantılı katman gelmektedir. Bu katmanda modelin sınıflandırılabilmesi amacıyla gerekli yüksek seviyeli soyutlamalar yapılmaktadır. Modelin çıkış katmanında ise softmax fonksiyonu kullanılarak sınıflandırma işlemi yapılmaktadır. Model

ImageNet veri tabanı ile eğitildiğinde genel olarak 1.000 sınıf için çıktı vermektedir. InceptionV3 kullanıcılarına daha az parametre ile kullanım imkanı, verimli hesaplama ve bellek kullanımı, ağ derinliği, faktörize evrişimler ve düşük eğitim maliyetleri açısından avantaj sağlamaktadır [106].

3.7.6. Yoğun Bağlı Ağlar (DenseNet)

DenseNet, 2016 yılında Gao Huang ve arkadaşları tarafından ilk kez “Densely Connected Convolutional Networks” adlı makaleyle ortaya çıkarılmıştır. DenseNet mimarisi, özellik haritalarının birbirlerine bağlanması amacıyla yoğun bağlantılar kullanmaktadır. Bu noktada DenseNet mimarisinin daha fazla bağlantı ile öğrenme kapasitesi sağladığı söylenebilmektedir. Yoğun bağlantılar ile daha az parametre kullanılmakta ve daha iyi sonuçlar elde edilebilmektedir. DenseNet ağları, ağların derinliklerinden kaynaklı gradyan problemlerinin çözülmesi amacıyla tasarlanmıştır. Ağlardaki tüm katmanlar, önceki katmanlardan giriş almakta ve kendi özellik haritasını sonraki bütün katmanlara iletmektedir. Bu mimari, katmanlar arasındaki maksimum bilgi akışının elde edilmesini sağlamaktadır [107]. Özellik haritaları bütün katmanlarda birleştirilmekte ve bu durum sonucunda tüm katmanlar, önceki katmanların bütün bilgilerini öğrenebilmektedir. Ayrıca bu mimari ile parametre verimliliğinin sağlanabilmesi amacıyla gereksiz bilgilerin öğrenilmesi ortadan kaldırılmış olmaktadır. Bütün katmanların bağlantılı olması, DenseNet ağının öğrenme kapasitesi üzerinde önemli bir faktör olarak verilebilmektedir [108]. Şekil 3.13’de DenseNet yapısı görülebilmektedir.




Şekil 3. 13. DenseNet yapısı [108]

Şekil 3.13’den de görüldüğü gibi ilk olarak katmanlar arası yoğun bağlantılar kurulmaktadır. Tüm katmanlar, öncesi bütün katmanların çıktılarıyla beslenmektedir. Her katman, önceki katmanların

çıktılarıyla birleşmektedir. Bu durum sonucunda tüm katmanlar daha fazla bilgiye sahip olabilmekte ve öğrenme süreçleri daha verimli hale getirilebilmektedir. Tüm katmanların çıktıları, birleştirilen özellik haritalarına eklenmektedir. Bu durum sonucunda modelin tüm katmanları daha fazla özellik öğrenebilmektedir. Bu durum, modelin daha derinlikli özellik çıkarabilmesini sağlamakta ve daha iyi temsil öğrenmesini sağlamaktadır. Her blok genel olarak bir adet Bottleneck yapısına sahiptir. Bu yapılar, giriş kanal sayılarını 1x1 evrişimlerle azaltmakta, hesaplama ile parametre sayılarını verimli biçimde düşürmektedir. 1x1 evrişimler kanal boyutlarını azaltmak ve daha verimli öğrenme sağlamak için kullanılabilir. DenseNet ağları, birbirlerine bağlı birden fazla bloktan meydana gelmektedir. Her blok genel olarak n katmandan oluşmaktadır [108]. Her bloğun içerisinde katmanlar arasındaki bağlantılar yoğun biçimde gerçekleştirilmektedir. Modelin bloklar arası bağlantıları genel olarak bottleneck katmanları ya da geçiş katmanları ile yapılabilmektedir. DenseNet ağlarında bloklar arasında geçiş katmanları yer almaktadır. Bu katmanlar, bloklar arasındaki özellik haritalarını maksimum havuzlama ile küçültmek ve kanal sayılarını azaltmak amacıyla kullanılmaktadır. Geçiş katmanları, modelin verimliliğinin artırılmasında ve daha derinlemesine öğrenilmesinde avantaj sağlamaktadır. DenseNet ağları genel olarak son katman olarak Global Ortalama Havuzlama kullanılmaktadır. Bu işlemde tüm kanallar için bütün piksel değerlerinin ortalaması alınmakta ve boyutları küçültülmektedir. Daha sonra tam bağlantılı katman eklenmekte ve sonuçlar softmax ya da sigmoid ile sınıflandırılmaktadır [108]. DenseNet genel olarak kullanıcılarına daha iyi öznetelik paylaşımı ve hızlı öğrenme açısından, parametre verimliliği açısından, aşırı öğrenmenin azaltılması açısından ve daha derin modellerin eğitilebilmesi açısından avantajlar sağlamaktadır [108].

3.7.7. AlexNet

AlexNet ağı Krizhevsky ve arkadaşları tarafından 2012 yılında geliştirilmiştir. Yapılan geliştirmeler sonucunda AlexNet ağı, derin öğrenmenin tekrardan insanlar tarafından ilgi duyulan bir konu haline gelmeye başlamıştır. LeNet ağı ile karşılaştırıldığında AlexNet'in daha derin bir model olduğu söylenebilmektedir. Buna ek olarak AlexNet, ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını kazanmış ve büyük bir başarı elde etmiştir [109]. Şekil 3.14'de AlexNet ağının mimarisi görülebilmektedir.




Şekil 3. 14. AlexNet ağı [110]

Şekil 3.14’den de görüldüğü gibi AlexNet ağına mimarisi, beş tane evrimsel katmandan, üç tane maksimum havuzlama katmanından, üç tane tam bağlı katmandan ve bir tane sınıflandırma için kullanılan softmax katmanından meydana gelmektedir. Her bir evrişim ile tam bağlı katmanın ardından Relu aktivasyon fonksiyonu kullanılmaktadır [110].

3.7.8. YOLO (You Only Look Once)

YOLO modeli ile nesne tespitleri yapılabilmektedir. YOLO modeli, nesne tespiti yapan çeşitli uygulamalardan yalnızca bir tanesidir. YOLO, CNN tabanlı bir algoritmadır. Bu algorithmada nesne tespiti yapılırken hızlı bir şekilde analiz yapılmaktadır. Modelde kullanılan donanımlar ile modüllerde, algoritmanın hızı üzerinde etkili olmaktadır. Bu algoritma nesne tespiti yaparken girdi olarak modele yüklenen görselleri $X \times X$ matrislere bölmekte ve ardından nesne olup olmadığını kontrol etmektedir. Bu noktada eğer sisteme yüklenen görselde nesne varsa merkez noktasının kendi alanında olup olmadığının kontrolü de yapılmaktadır. Modeldeki nesne, kendi alanı içerisindeyse ilgili nesnenin sınıfı, yüksekliği ve genişliği tespit edilmektedir [111]. Şekil 3.15’de YOLO ağına mimarisi görülebilmektedir.



Şekil 3. 15. YOLO ağ mimarisi [112]

Şekil 3.15’den de görüldüğü gibi YOLO ağında toplamda 24 adet evrişimsel katman, dört maksimum havuzlama katmanı ve iki adet tamamen bağlı katman bulunmaktadır. Derin öğrenme algoritmalarından bir tanesi olan YOLO ağının kullanılmasıyla sınıflandırma işlemi yapılabilmektedir [112].

3.7.9. Xception


Xception, “Extreme Inception” ifadesinin kısaltmasıdır ve CNN için geliştirilmiş bir modeldir. Xception, Inception modelini temel alarak geliştirilmiş ve derin öğrenme ile görüntü işleme gibi çeşitli uygulama alanlarında kullanılmaktadır. Xception modeli, Google tarafından geliştirilen Inception V3 mimarisine dayanmakta ancak bu modelin daha derinleştirilmiş ve optimizasyonlar yapabilen yapısı bulunmaktadır [113]. Xception modelinin temel özellikleri şu şekilde sıralanabilmektedir;

- Derin konvolüsyonel ağlar: Bu modelde diğer Inception ağlarına benzer bir biçimde derin konvolüsyonel ağlar kullanılmaktadır. Bu ağlar ile mevcut görüntülerdeki özellikler

öğrenilmektedir. Ancak Xception modelinde özellikle daha iyi performans elde edilmesi için derin konvolüsyonlar ile geniş konvolüsyonlar arasındaki farklar kullanılmaktadır.

- Derin ayrık konvolüsyonları: Xception mimarisinin en önemli yeniliği, geleneksel konvolüsyonların yerine derin ayrık konvolüsyonların kullanılmasıdır. Bu durum ilgili modelin hesaplama maliyetlerini ve parametre sayılarını azaltmakta ve modelin daha verimli bir şekilde çalışmasını sağlamaktadır.
- Modülerleşme: Xception, Inception modelinin evrimidir. Ancak Inception ağının karmaşık yapısından daha basit ve modüler bir yapısı bulunmaktadır. Xception ağında, modüler yapıların ağırlıklı olarak derin ayrık konvolüsyonları kullanılmakta ve optimize edilmesi sağlanmaktadır.
- Performans: Xception ağı özellikle görüntülerin sınıflandırılması, nesne tanıma ve görüntü segmentasyonu gibi çeşitli görevlerde yüksek doğruluk oranları vermektedir. Ayrıca Inception ağına göre daha düşük hesaplama gücüyle daha iyi sonuçların elde edilmesine katkı sağlamaktadır [107].

Şekil 3.16’da Xception modelinin mimarisi görülebilmektedir.



Şekil 3. 16. Xception modelinin mimarisi [107]


Şekil 3.16’dan da görüldüğü gibi Xception modelinin mimari yapısında 36 adet evrişim katmanı, softmax, maksimum havuzlama, ortalama havuzlama ve doğrusal artık bağlantısı bulunmaktadır [114]. Xception modelinin mimari yapısı genel olarak şu şekilde verilebilmektedir;

- Giriş katmanı: Modelin başlangıcında bir dizi klasik konvolüsyonel katmanlar bulunmaktadır.

- Derin ayrık konvolüsyonları: Modelin temel yapısı, depthwise separable convolutions kullanmakta ve tüm katmanlarda derin özellikleri çıkarmaktadır.
- Global average pooling: Ağırlıklı özelliklerin çıkarılmasını ve ardından çıktıların boyutlarının küçültülmesini sağlamaktadır.
- Tam bağlantılı katmanlar: Modelde elde edilen sonuçlar genel olarak sınıflandırma ya da regresyon için tamamen bağlı katmanlar üzerinden geçirilmektedir [114].

3.7.10. EfficientNet

EfficientNet, Google tarafından 2019 yılında geliştirilen CNN modellerinden bir tanesidir. Bu model, CNN'leri yapılandırmış bir biçimde ölçeklendirmekte ve yüksek verimlilik ile yüksek doğruluk elde etmeyi hedeflemektedir. Model ile birlikte tanıtılan bileşik ölçeklendirme tekniği, ağ genişliği, derinliği ve çözünürlüğünü sabit ölçeklendirme katsayısıyla düzgün bir biçimde ölçeklendirmektedir. Bu yaklaşım, mevcut modeldeki ağ boyutlarının dengesinin, modelin performansı ile verimliliği üzerinde önemli bir etkiye sahip olduğu anlayışına dayanmaktadır [115]. EfficientNet modeli doğruluk ile verimlilik için optimize edilmiş temel ağ niteliğinde olan EfficientNet B0 üzerine uygulanmaktadır. Bu ağ, farklı doğruluk ve verimlilik arasındaki dengeyi veren model ailesinin elde edilmesini sağlamak amacıyla ölçeklendirilmektedir. Model ailesinin her yeni versiyonu, daha fazla parametreye sahiptir ve daha fazla hesaplama gerektirmektedir. Ancak genel olarak görüntü tanıma işlevlerinde daha yüksek doğruluk vermektedirler. EfficientNet ağı, MnasNet ile MobileNet V2 ağlarında kullanılanlara benzer, mobil görüş işlevleri için verimli ve etkili lineer darboğazları olan ters residueal blokları kullanmaktadır. Buna ek olarak kanallar arasındaki bağımlılıkların açık bir şekilde modellenmesindeki kanal bazlarında özellik tepkilerini adaptif olarak yeniden kalibre etmekte ve sıkıştırma ile uyarılma optimizasyonlarını kullanmaktadır. EfficientNet modelinin uygulamaları arasında nesne tespiti, transfer öğrenme, sınıflandırma ve segmentasyon bulunmaktadır. Şekil 3.17'de EfficientNet modelinin mimarisi görülebilmektedir [115].




Şekil 3. 17. EfficientNet mimarisi [115]

Şekil 3.17’den de görüldüğü gibi modelde ilk olarak ölçeklendirme yapılmaktadır. Modelin en önemli özelliği, ilgili modelin ölçeklendirilmesi amacıyla yeni bir yaklaşım olan Compound Scaling sunmasıdır. Genel olarak derin öğrenme modellerinin daha büyük ve güçlü hale getirilebilmesi amacıyla sadece derinlik ya da genişlik artırılmaktadır. Ancak bu modelde ilgili parametrelerin hepsinin (derinlik, genişlik, çözünürlük gibi) üzerinde optimize işlemi yapılmaktadır. Ardından bileşik ölçeklendirme yapılmaktadır [115]. Bu model çeşitli boyutlardaki ağlar arasında denge kurmak amacıyla Compound Scaling yaklaşımını kullanmaktadır. Bu durum mevcut ağı derinliğini, çözünürlüğünü ve genişliğini artırmakta ve ilgili modelin daha verimli bir şekilde çalışmasını sağlamaktadır. Bu yaklaşım ile modelin yalnızca bir parametresi değil tüm parametreleri orantılı bir biçimde artırmaktadır. Ayrıca modelin doğruluğu da artmakta, hesaplama ve parametre sayılarının da kontrol edilmesine katkı sağlamaktadır [116]. Modeldeki mikro içerik modülleri ile daha verimli özellik çıkarımı için MobilNet V2 ağına invert edilmiş şişirme yapıları ile bottleneck yapısı kullanılmaktadır. Bu yapı ile daha az hesaplama ve daha fazla özellik çıkarılabilmesine katkıda bulunmaktadır. Modelin başlangıç katmanında verimli bir konvolüsyon yapısı kullanılmaktadır. Modelin sonunda ise global average pooling ile tam bağlantılı katmanlarla sınıflandırma işlemi yapılabilmektedir. Bu noktada EfficientNet modelinin konvolüsyonel ağlarının tasarımı ile ölçeklendirilmesinde önemli bir yol kat edildiği ve farklı uygulama alanları için yararlı olan yüksek doğruluk ile yüksek verimliliğin elde edildiği de söylenebilmektedir [117].

3.7.11. R CNN, Fast R CNN ve Faster R CNN

R CNN, evrişimli sinir ağlarının bölge bazlı incelenmesi amacıyla ilk kez 2014 yılında Girshick ve arkadaşları tarafından geliştirilmiştir. R CNN modelinin temelinde bölge önerileri ile odak bölgesi yer almaktadır. Çeşitli ölçekteki pencerelerin CNN modelinden işlenmeden önce aynı boyutlarda olmaları önem arz etmektedir. Evrişimli sinir ağları genel olarak aynı boyutlardaki girdileri kabul etmektedirler. Modelin her ilgi bölgesi ilk olarak konvolüsyonel sinir ağlarından geçmekte ve destek vektör makinesiyle sınıflandırılmaktadır. Modelin ilgi bölgesinde bulunan nesnenin çizilmesi için lineer regresyon kullanılmaktadır [118]. R CNN’e yüklenen görseller ilk aşamada 2.000’nin üzerinde ilgi bölgesi belirlemektedir. Her bir ilgi bölgesi ilk olarak boyut eşitlenmesi işlemine sokulmakta ve ardından konvolüsyonel ağlar ile işlenmektedir. Destek vektör makinesiyle ilgi bölgesinde nelerin olduğu tespit edilmekte yani sınıfları belirlenmektedir. Lineer regresyonla ilgi bölgelerinin yerleri çizilmekte ve sınırları oluşturulmaktadır. Çok katmanlı işlem görmesi R CNN modelinin yavaş olmasına sebep olabilmektedir [119]. Şekil 3.18’de R CNN mimarisi görülebilmektedir.




Şekil 3. 18. R CNN çalışma yapısı [120]

Konvolüsyonel yapay sinir ağlarının kullanılması sebebiyle mükemmel düzeylerde nesne tespit doğruluğu elde edilebilmektedir ancak R CNN optimum bir yapıya sahip değildir. İlk olarak eğitim sürecinde çok aşamalı bir süreç bulunmaktadır. R CNN modelinde log kayıpları kullanılarak nesne sınıflandırma işlemi konvolüsyonel ağ üzerinden ayarlanmaktadır. Daha sonra konvolüsyonel ağ özelliklerini destek vektör makinesiyle oluşturmaktadır. Eğitim sürecinin son aşamasında ise sınırlayıcı kutular regresyon ile öğrenimi tamamlamaktadır. Modelin süresi eğitimin son aşamasıyla birlikte biraz daha uzamaktadır. Eğitimin zamanı bakımından maliyetli bir model olduğu söylenebilmektedir. Ciddi düzeylerde gigabayt veri depolama gereksinimi vardır. Modelin tespit etme aşamasında çoklu ve ayrı ayrı yapıldığı için yavaş bir işleyişinin olduğu da bildirilebilmektedir. Bunun sebebi her bir ilgi bölgesinin tek tek incelenmesidir [121].

Faster R CNN algoritması, konvolüsyonel sinir ağları bulunan temeli R CNN mimarisine dayanan, nesne tespitlerinde süreçlerin optimizasyonu ile daha hızlı hale getirildiği versiyonudur. Faster R CNN algoritmasını R CNN algoritmasından ayıran en temel özelliği; ilk aşamada görseller üzerinde çoklu bölge önerilerinde bulunmadan görselleri bütüncül bir şekilde konvolüsyonel sinir ağlarından geçirmesidir. Bu durum sonucunda asıl görsel ile benzerliği bulunan ve yüksek çözünürlüğü olan özellikler haritası elde edilmesidir. Modelde özellik haritalarının oluşturulmasının ardından bölge önerileri oluşturulmaktadır [122]. Fast R CNN algoritmasındaki gibi her bölgenin ayrı ayrı konvolüsyonel sinir ağına dahil edilerek incelenmesi yerine ilgili görsel ilk aşamadan itibaren konvolüsyonel sinir ağından geçirilmektedir. Bu modelde 2.000 bölge önerisi belirlenmesinden önce boyutlar eşitlenmekte ve ardından direkt bağlı ağ katmanı kullanılmaktadır. Modelde sınıflandırma işleminin yapılması için yeni bir model oluşturulmamakta bunun yerine lineer

sınıflandırıcılar ile softmax sınıflandırıcıları kullanılmaktadır. Ayrıca ilgili nesnelerin küçülen kutularla sınırlarının belirlenmesinde de lineer regresyon kullanılmaktadır [122]. Şekil 3.19’da Fast R CNN mimarisi görülebilmektedir.




Şekil 3. 19. Fast R CNN mimarisi [122]

R CNN algoritmasının eğitim süresi yaklaşık 84 saat iken Fast R CNN algoritmasının eğitim süresi yaklaşık 8,75 saattir. Bu noktada Fast R CNN algoritmasının R CNN algoritmasına kıyasla 9,6 kat daha hızlı eğitim sürecinin olduğu söylenebilmektedir. R CNN algoritmasının sonuç üretmesi yaklaşık 49 saniyedir. Faster R CNN algoritmasının ise sonuç üretmesi yaklaşık 2,3 saniyede tamamlanmaktadır. Bu noktada Faster R CNN algoritmasının R CNN algoritmasına göre 21,3 kat daha hızlı bir şekilde sonuç ürettiği söylenebilmektedir. Ancak süre olarak her ne kadar Fast R CNN algoritması avantajlı olarak görülse de sürecin mükemmelliği açısından Fast R CNN algoritmasının bölge önerisinde ve sınıflandırma süreçlerinde vakit kaybettiği de unutulmamalıdır [122].

Fast R CNN algoritmasında bulunan bölge önerisi darboğazı ile sınıflandırma darboğazına çözüm olarak yeni bir ağ geliştirilmek istenmiş ve Faster R CNN algoritması ortaya konulmuştur. Faster R CNN algoritması, Fast RCNN algoritmasına benzer şekilde görselleri alarak ilk olarak konvolüsyonel sinir ağlarından geçirmektedir. Daha sonra yüksek çözünürlüğü olan özellik haritası çıkarmaktadır. Faster R CNN algoritması, Fast R CNN algoritması gibi seçimli arama yapmakta ve ilgi bölgesi veya bölge önerisi çıkarmadan bölge önerisi ağı üretmektedir. Modeldeki bölge önerisi konvolüsyonel ağda gerçekleşmekte ve bu durum sonucunda ilgili modelin hızlı bir şekilde sonuç üretmesi sağlanmaktadır. Model tarafından üretilen öneri bölgesi, doğrudan bağlı katmandan

geçirilmekte ve sınıflandırma işlemi konvolüsyonel sinir ağları tarafından gerçekleştirilmektedir [123]. Şekil 3.20’de Faster R CNN algoritmasının mimarisi görülebilmektedir.




Şekil 3. 20. Faster R CNN algoritması [122]

Faster R CNN algoritmasındaki ilk aşama nesnelerin algılanmasını istenen görüntülerin alınması ve işlemeye hazır hale getirilmesidir. Ardından daha önceden eğitilmiş evrişimli sinir ağı, girdi olarak modele verilen görüntüyü özellik haritasına dönüştürmektedir. Bu ağ genel olarak VGG ve ResNet gibi derin mimariler ile yapılabilmektedir [122]. Şekil 3.20’de görülen bölge öneri ağı; modelin oluşturduğu özellik haritaları üzerinde çalışan bir ağıdır. Bu ağ ile olası nesne konumları önerilmektedir. Modelin önerdiği bölgeler daha sonra daha kapsamlı bir şekilde analiz edilmesi için seçilmektedir. Bölgenin düzeltilmesi ve özelliklerinin çıkarılması adımı; Region Proposal Network aracılığıyla önerilen bölgeler özellik haritalarından çıkarılmakta ve düzeltilmektedir. Bu aşamada modeldeki her bölge daha küçük boyutlara getirilmekte ve nesne algılama işlemi için

ilgili özelliklerin çıkarılma işlemi yapılmaktadır. Bölgeye özgü evrişimler adımı; her bölge için özellik haritasından özellikler seçilmektedir. Bu işlem de modeldeki her bölgeyi sabit boyutlara dönüştürme işlemi yapılmaktadır. Bu aşama sonucunda sonraki aşamalarda aynı boyutlarda girdi elde edilmesi sağlanmaktadır [122]. Nesnelerin sınıflandırılması ve yerlerinin tespit edilmesi aşamasında; modeldeki her bölge için nesne sınıflandırma ve yerlerinin tespit edilme işlemi gerçekleştirilmektedir. Bu işlem modelin her bölgesindeki nesnelerin sınıflarının tahmin edilmesi ve ilgili bölgelerin nerede olduklarının tespit edilmesini içermektedir. Sonuç üretme hızları karşılaştırıldığında R CNN algoritmasının 49 saniyede ürettiği sonuçları, Fast R CNN algoritmasının 2,3 saniyede ürettiği, Faster R CNN algoritmasının ise 0,2 saniyede ürettiği söylenebilmektedir. Bu kapsamda R CNN'den 255 kat, Fast R CNN'den ise 11,5 kat daha hızlı olduğu görülebilmektedir. Bu hız avantajı, Faster R CNN algoritmasının gerçek zamanlı nesne tespit edilmesine olanak sağladığı gerçeğini göstermektedir [122].

3.7.12. U Net

U Net, evrişimli sinir ağına dayanan derin öğrenme yaklaşımlarından bir tanesidir. İlk kez biyomedikal görüntüler üzerinde daha iyi bölütleme işleminin yapılabilmesine yönelik 2015 yılında Ronneberger ve diğerleri tarafından geliştirilmiştir [124]. Ayrıca 2015 yılında Uluslararası Biyomedikal Görüntüleme Sempozyumu'nda az sayıda görüntü kümesi kullanılmasıyla eğitim yapabildiği ve daha önce ortaya konulan sinirsel yapıların elektron mikroskopik yığınlar da bölütleme çalışmalarından daha iyi performans gösterdiği ortaya konulmuştur. Ronneberger vd. [124] tarafından yapılan çalışmalarda elektron ile ışık mikroskobu kaynağıyla oluşturulan 512x512 boyutundaki görüntülerden veri setleri üretilmiş ve Caffé kütüphanesinde yer alan veri setleriyle toplamda üç farklı veri seti kullanılarak bölütleme işlemleri yapılmıştır. Çalışmadaki veri setlerinde 30 tane elektron mikroskobu, 35 tane ışık mikroskobu ile 20 tane ışık mikroskobu görüntüsü kullanılmıştır. Modelin birinci veri setinde 0.0003529 çözgü hatası, ikinci veri setinde %92 IoU, üçüncü veri setinde %77.5 IoU değerleri elde edilmiş ve bu da modelin yüksek başarılı olduğunu göstermiştir [124]. Modelin bu denli yüksek başarıyla ulaşması sonucunda U Net mimarisi sıklıkla kullanılmaya başlanmıştır. Klasik evrişimli sinir ağı modellerinde yüksek başarıya ulaşılması ile veri setlerinin büyüklüğü arasında doğrusal ilişki bulunmaktadır. Bunun sebebi veri setlerinde kullanılan görüntülerin etiketlenmesi ve özellik haritalarının oluşturularak ilgili modele verilmesidir. Ayrıca modelin bu verileri etiket bilgisinden tanımlayarak işleme alması da durumu etkilemektedir. U Net modeli diğer derin öğrenme modellerine kıyasla bağlama dayalı öğrenme özelliği ile daha az veri setiyle hızlı sonuçlar üretebilmektedir [125]. Şekil 3.21'de U Net mimarisi görülebilmektedir.



Şekil 3. 21. U Net mimarisi [124]


Şekil 3.21’den de görüldüğü gibi U Net mimarisi adını modelin U şeklinde kurulmasından almıştır. Modelin temel olarak evrişim ağları modellerindeki gibi yapılarının olmasının yanı sıra farklılaştığı özelliklerde bulunmaktadır. Klasik evrişim blok yapıları U Net modelinde de korunmakta ve evrişim katmanları, aktivasyon katmanları ile havuzlama katmanları U Net mimarisinin kodlayıcı blok yapılarını oluşturmaktadır. Modeldeki kodlayıcı blokların karşı simetrisinde ise kod çözücü blok yapılarıyla tersine evrişim işlemi gerçekleştirilmektedir [124]. Modeldeki her iki yapıyı birbirine bağlayan ve U Net mimarisini diğer mimarilerden ayıran en önemli bağlantısı birleştirme ve bağlantı kurmak amacıyla kullanılan concatenate bağlantı yapısını sağlamasıdır. U Net mimarisi kodlama ve kod çözücü olmak üzere toplamda iki simetrik parçanın bottleneck adı verilen darboğaz bağlantısıyla birbirine bağlanması sonucunda meydana gelmektedir [126]. Temelinde klasik evrişim mimarisinde de olan katmanların birçoğunun U Net mimarisinde de kullanıldığı söylenebilmektedir. Buna ek olarak U Net mimarisinde farklı olarak yalnızca tam bağlantı katmanları kullanılmamaktadır. Evrişim mimarisinin temel yapısından farklı olarak kodlayıcı ile kod çözücü bloklarını birbirine bağlayan concatenate isimli bağlantılara sahiptirler. Encoder yapıları ise U Net mimarisinin ilk kısmında iki kez 3x3 normal evrişim işlemi, ReLu aktivasyonu ile aşağı yönlü iletilen veriler için 2x2 maksimum havuzlama işlemlerinden oluşmaktadır [96]. Bu adımda klasik U Net mimarisinde uygulanmayan batch normalizasyon ilgili modele entegre edilebilmektedir. Batch normalizasyonla derin sinir ağlarının eğitimlerinde optimizasyon sorunsuz bir şekilde yapılarak ilgili modelin hızlı ve kararlı eğitilmesinin yapılabilmesine katkı sağlayan bir yöntemdir [127]. U Net mimarisinde genel olarak konvolüzyon, aktivasyon ve batch normalizasyon ile işlemler yapılmaktadır. Bu uygulamalar sonucunda iki tane çıktı elde edilmekte ve bunlardan ilki alt basamaklarda yer alan evrişim bloğuna girdi niteliğinde bağlanırken, ikincisi

ise karşı kod çözücü bloğuna bağlam bilgisi olarak iletilmektedir. Bu özellik U Net mimarisinin en önemli özelliklerinden birisidir. Buna ek olarak modeldeki alt örnekleme aşamasına geçişte filtre sayıları (özellik sayıları) iki katına çıkarken görüntü boyutları ise maksimum havuzlama işlemi aracılığıyla yarı yarıya düşmektedir. Bu şekilde evrişim blokları halinde tekrar eden bir yapı oluşturulmuş olmaktadır. Maksimum ortalama işlemi görüntüleri 2x2 bloklara ayırtırmakta ve ilgili bloklardaki maksimum pikselleri alma amacıyla işlem gerçekleştirmektedirler. Bu kapsamda modelin her bloğundaki derece daha önemli bilgileri korumakta ve daha az önemli bilgileri atmaktadır [128]. Sonuç olarak modele verilen giriş görüntüsünden daha küçük ancak daha anlamlı bilgileri içeren özellik haritalarına sahip olan veri kümeleriyle temsil görüntüler üretilmektedir. Bu aşamalar toplamda beş katman boyunca devam ettirilmektedir. Modelin girdi boyutlarına bağlı olacak şekilde bu durum farklılaşabilmektedir. Klasik U Net mimarisinde ilgili görüntülerin boyutları ise sırasıyla; 128x128 piksele, 64x64 piksele, 32x32 piksele, 16x16 piksele ve 8x8 piksele düşmektedir. Modelin beşinci katmanında darboğaz adı verilen yapılar ile kodlama ve kod çözücü bloklar birbirine bağlanmaktadır. Modelin kodlama aşaması tamamlandığı için havuzlama işlemi kod çözücü bloklarda yapılamamaktadır. Decoder yapısı, decoder katmanında görüntüler adım adım genişletilmeye başlanmaktadır. Yukarı yönlü görüntü boyları tekrar katmanlar arasında iki katına çıkarılacak olan tersine evrişim işlemine sokulmakta ve model sonucunda görüntü orijinal boyutlarına geri döndürülmektedir [129]. Modelin kodlama bloklarından gelen aynı düzeylerde üretilen yüksek çözünürlüklü özellik haritaları ile kod çözücü bloklarında yer alan düşük çözünürlüklü özellik haritaları birleştirilmektedir. Bu aşama modelin hem detaylarını hem de bağlam bilgilerini korumakta ve bölütleme performansını yükseltmektedir. Bu durum sonucunda modeldeki her pikselin hangi sınıfa ait olduğunun tahmin edilebilmesi amacıyla kapsamlı özellik haritaları üretilmektedir [130]. U Net mimarisinde evrişim sinir ağlarının en önemli bağlantı yapılarından olan tam bağlantılı katman kullanılmamakta bunun yerine özellik vektörlerini istenen sayılarda sınıfa eşlemek amacıyla 1x1 evrişim uygulanmaktadır. 5 düzeyli klasik bir U Net mimarisinde, kodlayıcı bloklarda 10 evrişim katmanı, darboğaz blok içerisinde iki evrişim katmanı, kod çözücü bloklarda sekiz evrişim katmanı ve bir adet çıkış katmanı bulunmaktadır. Özetle bu mimari de toplamda 21 tane evrişim işleminin gerçekleştiği söylenebilmektedir [130]. Modelin ürettiği her çıktıyla her pikselin sınıfı belirlenmekte ve son aşamada bölütleme maskesi üretilmektedir. Bu kapsamda 1x1 evrişimle her piksel için sınıfsal istatistikler hesaplanabilmekte ve her piksel için ayrı ayrı sınıflandırma yapılabilmektedir. U Net mimarisinin kullanıldığı modellerde sınıf sayılarına bağlı olarak son katmanda kullanılan aktivasyon fonksiyonu değişmektedir. Bu doğrultuda eğer modelde çok sınıflı veri seti kullanılıyorsa modelin son katmanında softmax aktivasyon fonksiyonunun kullanıldığı, eğer modelde iki sınıflı veri seti kullanılıyorsa bu kapsamda da sigmoid aktivasyon fonksiyonunun kullanılacağı

söylenilmektedir. Son olarak modelde kullanılan benzerlik metrikleriyle modelin sonuçlarının değerlendirildiği ve buna göre ilgili modelin başarısının elde edildiği bildirilebilmektedir [131].

3.8. Model Performanslarının Değerlendirilmesi

Özellikle tıbbi görüntülerin kullanıldığı derin öğrenme uygulamalarında, modelin performansının değerlendirilmesi, etkinliğinin ve klinik ortamlarda kullanılabilir olma durumunun anlaşılabilmesi amacıyla yadsınamaz bir öneme sahiptir. Bu amaçla genel olarak farklı metrikler kullanılabilmekte ve her bir modelin performansına yönelik çeşitli çıktılar elde edilebilmektedir. Model performanslarının değerlendirilmesinde doğruluk, hassasiyet, duyarlılık ve F1 skorlarına bakılmaktadır. Günümüzde modellerin sınıflandırma işlemleri için kullanılan çeşitli veri bilimi modelinin doğruluk sonuçları elde edilebilmektedir. Ancak elde edilen doğrulukların ne kadar gerçeği yansıttığı ne kadar gerçeği yansıtmadığı bilinmemektedir. Bu sebeple çeşitli yöntemler geliştirilmiştir. Bunlardan bir tanesi de karışıklık matrisidir. İkili karışıklık matrisleri kolay anlaşılabilir [132]. Şekil 3.22’de ikili sınıflandırma için karışıklık matrisi örneği görülebilmektedir.



Şekil 3. 22. İkili karışıklık matrisi örneği [133]

Şekil 3.22’den de görüldüğü gibi karışıklık matrisi ile tahmin edilen değerlerin gerçek değerlere göre karşılaştırması yapılmaktadır. Matris verileri 1 (True), 0 (False) olacak şekilde sınıflandırılmaktadır. Şekil 3.22’de görülen TP (True Positive); 1 olarak sınıflandırılan ve gerçekten 1 olan değerlerin sayısını, FP (False Positive); 1 olarak sınıflandırılan ve gerçekte 0 olan değerlerin sayısını, TN (True Negative); 0 olarak sınıflandırılan ve gerçekten 0 olan değerlerin sayısını ve FN (False Negative); 0 olarak sınıflandırılan ve gerçekte 1 olan değerlerin sayısını ifade etmektedir [133].

3.8.1. Doğruluk

Doğruluk, sezgisel metriklerden bir tanesidir. Model tarafından gerçekleştirilen bütün tahminler arasında doğru tahminlerin oranları ölçülmektedir [133]. Denklem 3.4’de Doğruluğa ait hesaplama formülü görülebilmektedir.

$$\text{Doğruluk} = \frac{\text{Doğru tahminlerin sayısı}}{\text{Toplam tahmin sayısı}} \quad (3.4)$$

3.8.2. Hassasiyet

Hassasiyet diğer bir adıyla Pozitif Tahmin Değerleri, modeldeki pozitif sınıftaki gerçek pozitiflerin tahminlerinin oranının ölçülmesi amacıyla kullanılmaktadır İlgili modelin negatif bir örnek etiketlemesini engelleme yeteneğine odaklanmaktadır. Bu durum özellikle tıbbi uygulamalarda yanlış hastalık teşhislerinin konması ve yanlış tedavi yöntemlerinin uygulanmasının engellenmesi bakımından kritik bir öneme sahiptir [133]. Denklem 3.5’de hassasiyete ait hesaplama formülü görülebilmektedir.

$$\text{Hassasiyet} = \frac{\text{Gerçek pozitifler}}{\text{Gerçek pozitifler} + \text{Yanlış pozitifler}} \quad (3.5)$$

Denklem 3.5’deki formülden hesaplanan hassasiyet oranının yüksek olması, düşük yanlış oranının olduğunu göstermekte ve yanlış negatifleri dikkate almamaktadır.

3.8.3. Duyarlılık

Duyarlılık, model tarafından doğru biçimlerde tespit edilen gerçek pozitiflerin oranını ölçmektedir. Özellikle tıbbi uygulamalarda pozitif bir vakanın kaçırılması, hasta bakımı ve tedavi uygulamaları için olumsuz sonuçlar doğurabilmektedir [133]. Denklem 3.6’da duyarlılığa yönelik hesaplama formülü görülebilmektedir.

$$\text{Duyarlılık} = \frac{\text{Gerçek pozitifler}}{\text{Gerçek pozitifler} + \text{Yanlış negatifler}} \quad (3.6)$$

Yüksek hassasiyet, ilgili modelin pozitif vakaların tespit edilmesinde etkili olduğunu ortaya koymaktadır. Ancak yanlış pozitiflerin sayıları hakkında bilgi vermemektedir.

3.8.4. Hassasiyet ile Duyarlılık Dengesi

Genel olarak hassasiyet ile duyarlılık arasında bir denge bulunmaktadır. Modellerin hassasiyetlerinin artırılabilmesi genellikle duyarlılığın azaltılması ile gerçekleştirilebilmektedir. Bu durumun tam terside söz konusudur. Hassasiyet ile duyarlılık arasındaki denge, Hassasiyet-

Duyarlılık Eğrisi ile görselleştirilebilmekte ve analiz edilebilmektedir. Bu metrikler arasındaki denge Hassasiyet ile duyarlılığın harmonik ortalaması olan F1 skoru ile incelenmektedir [133]. Denklem 3.7’de F1 skorunun formülü görülebilmektedir.

$$F1 \text{ skoru} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (3.7)$$

3.9. Açıklanabilir Yapay Zeka


Açıklanabilir yapay zeka, YZ modellerinin çalışma prensiplerini ve model tarafından alınan kararların bireylerin anlayabilecekleri biçimlerde sunulmasını amaçlamaktadır. Bu amaç doğrultusunda modellerin işleyişleri, kullanılan veriler ile üretilen sonuçlar açık ve net biçimlerde ortaya konmaktadır. Bu teknoloji genel olarak kullanıcıların yapay zeka (YZ) sistemlerine olan güvenlerini artırmakta ve bu sistemlerin yaygın bir şekilde kullanılmasını sağlamaktadır. Özellikle risklerin fazla olduğu alanlarda ve önemli yasal düzenlemelerin bulunduğu sektörlerde açıklanabilirlik yadsınamaz bir öneme sahiptir [134].

3.9.1. Sınıf Aktivasyon Haritaları

Class Activation Maps (CAM), bilgisayarla görme görevlerinde kullanılan evrişimli sinir ağıları modellerinin karar süreçlerini kullanıcıların algılayabilecekleri biçimlerde görselleştirildiği yöntemidir. CAM, herhangi bir görüntüdeki belirli bölgelerin, herhangi bir sınıfı tanımlamasında ne kadar etkili olduğunu ortaya koymaktadır. CAM yöntemi genel olarak modelin neden belirli bir kararı aldığını açıklamakta ve modelin iç sistemlerini daha iyi anlamak için kullanılmaktadır [135].

Gradient-weighted Class Activation Mapping (GradCam):

GradCam, herhangi bir olgunun ya da sınıfın tahmin edilmesi amacıyla önemli bölümlerin belirginleştirilmesini sağlayan ve ısı haritalarının oluşturulmasında kullanılan tekniklerden biridir. GradCam tekniğinin kullanıldığı modeller sonucunda karar verme sürecinde en etkili bölgeler belirtilmekte ve nitel açıklamalar yapılabilmektedir [136]. Şekil 3.23’de GradCam mimarisi görülebilmektedir.



Şekil 3. 23. GradCam [137]

Şekil 3.23’den de görüldüğü gibi GradCam yönteminin ilk aşamasında; giriş görüntüsü modelden geçirilmekte ve ileri yönlü geçiş sağlanmaktadır. Ayrıca modelin son evrişim katmanındaki öznetelik haritaları elde edilmektedir. Elde edilen haritalar, görüntülerdeki önemli aktivasyonları göstermektedir. Daha sonra geriye yönlü geçişler ile belirli sınıf skorları kapsamında elde edilen öznetelik haritalarının gradyanları hesaplanmaktadır. Hesaplanan gradyanlarla mevcut tüm öznetelik haritasının hedef sınıflara etkileri gösterilmektedir. Bu durum sonucunda üretilen her harita için bir ağırlık faktörünün belirlenmesi sağlanabilmektedir [137]. Ağırlıkların elde edilmesinde, Global ortalama Havuzlama işlemi yapılmaktadır. Sınıflara özel önem ağırlıkları, konvolüsyonel katmanların özellik haritalarından daha derinlere inerek mevcut ağırlık yerel doğrusallığını ortaya koymaktadır. Bu işlem sonucunda istenen sınıflara yönelik özellik haritalarının ne kadar önemli olduğu tespit edilebilmektedir. Rectified Linear Unit (RELU) işleminin uygulanması ile modeldeki sınıflara yönelik yerelleştirme haritası oluşturulabilmektedir. Böylelikle yalnızca olumlu etkileri olan bölgeler görselleştirilmiş olmaktadır [137]. Hedef sınıf c ’nin k nöronu önem ağırlığı Denklem 3.8’deki gibi hesaplanmaktadır.

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (3.8)$$

Denklem 3.8’de görülen “ α_k^c ”; hedef sınıf c ’nin k nöronu önem ağırlığını simgelemektedir. “ y^c ”; c ’nin softmax katmanından önceki skorunu, “ A_{ij}^k ”; i, j konumundaki özellik haritasındaki aktivasyonunu k nöronu için simgelemektedir. “ Z ” ise normalleştirme sabitidir.


Sınıf Ayırt Edici Yerelleştirme Haritası ise her öznitelik haritasının gradyanlarındaki ortalama alınarak hesaplanmaktadır. Ayrıca modeldeki tüm haritaların hedef sınıflara katkısı da bu aşamada hesaplanabilmektedir. Modelde hesaplanan ağırlıklar, öznitelik haritalarıyla ilk olarak çarpılmakta daha sonra toplanmaktadır. Toplama işleminin sonucunda bir adet ısı haritası meydana gelmektedir. Oluşturulan haritalara ReLU aktivasyon işlemi uygulanmakta ve yalnızca pozitif etkileri vurgulayan değerlerle işleme devam edilmektedir [137]. Denklem 3.9’da ReLU aktivasyon fonksiyonuna ait denklem görülebilmektedir.

$$L_{GradCam}^c = \text{ReLU}(\sum_k \alpha_k^c A^k) \quad (3.9)$$

Denklem 3.9’daki “ $L_{GradCam}^c$ ”; c sınıfındaki ayırt edici yerelleştirme haritasını simgelemektedir. Model tarafından üretilen ısı haritası 0-1 arasında normalize edilmekte ve giriş görüntüsünün boyutlarına uyacak biçimlerde büyütülmektedir. Daha sonra oluşturulan harita giriş görüntüsünün üzerine konumlandırılmaktadır ve modelin tahmin ederken hangi bölgelere yoğunlaştığı açık bir biçimde görselleştirilmiş olmaktadır [138].

Gradient-weighted Class Activation Mapping++ (GradCam++):

GradCam++ yöntemi derin öğrenme modellerinin karar süreçlerinin açıklanmasında ve modellerin dikkat etmeleri gereken bölgeleri görselleştirmek amacıyla kullanılmaktadır. GradCam++ yöntemi GradCam yönteminin geliştirilmiş versiyonudur. Bu yöntem, modellerin sınıf tahminlemesini daha kapsamlı yapmakta ve daha açıklayıcı bir şekilde sonuç sunabilmektedir [139]. Kullanılan modellerin belirli sınıflar için önemli gördüğü görüntü alanlarını daha etkili biçimlerde gösterilmesi amacıyla pozitif kısmi türevleri ağırlıklı olarak birleştirmektedir. Bu durum sonucunda modellerin odaklandıkları bütün alanlar, dengeli biçimlerde ön plana çıkarılabilmekte ve nesnelerin bulundukları alanların daha doğru biçimlerde tespit edilebilmesi sağlanabilmektedir [138]. Şekil 3.24’de GradCam++ mimarisi görülebilmektedir.



Şekil 3. 24. GradCam++ mimarisi [140]

Şekil 3.24’den de görüldüğü gibi giriş görüntüleri CNN modeliyle çeşitli katmanlardan geçirilmektedir. Bu modelde tüm katmanlarda farklı öznetelikler oluşturulmaktadır. Son evrişim katmanında oluşturulan öznetelik haritaları, GradCam++ tekniğinin temelini meydana getirmektedir. Oluşturulan haritalar, mevcut görüntülerin farklı alanlarının çeşitli özelliklerini ortaya koymaktadır. Modelin son katmanında belirli sınıf için sınıf skorları olan “y” ile “c” hesaplanmaktadır. Bu skorlar modelin ilgili sınıfa yönelik gerçekleşme olasılığını vermektedir [140]. Denklem 3.10’da modeldeki sınıf skoruna yönelik son evrişim katmanındaki tüm öznetelik haritalarının gradyanlarının hesaplanmasına yönelik formül görülebilmektedir.

$$\alpha_c^k = \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \frac{\partial^2 y^c}{\partial (A_{ij}^k)^2} \quad (3.10)$$

Denklem 3.10’daki “ $\frac{\partial y^c}{\partial A_{ij}^k}$ ” ifade modeldeki gradyanları temsil etmektedir. Gradyanlar, belirli sınıf skoru için tüm öznetelik haritasının önemlerini vurgulamaktadır. GradCam++ tekniğinin en önemli farklarından bir tanesi de pozitif kısmi türevlerin ağırlıklı kombinasyonlarını kullanmasıdır. Model içerisinde kurulan tüm öznetelik haritaları için ağırlıklar hesaplanmaktadır. Ayrıca bu ağırlıklar “ α_{kc} ” ile ifade edilmektedir. Modelden elde edilen ağırlıklar, her bir haritanın sınıf skoruna ait katkısını belirlemektedir. Modeldeki bu hesaplama esnasında sadece pozitif gradyanlara dikkat

edilmektedir. Bu teknik, kullanılan modelin belirli sınıflara ait olduğunu düşündüğü bölgeleri vurgulama amacıyla kullanılmaktadır. Model içerisinde hesaplanan ağırlıklar ile öznitelik haritaları birleştirilmekte ve sınıflara özgü belirginlik haritaları üretilmektedir. Bu haritalar ise kullanılan modellerin giriş görüntülerindeki hangi alanlara dikkat edildiğini göstermektedir [140]. Denklem 3.11’de belirginlik haritasının hesaplanmasına yönelik formül görülebilmektedir.

$$L_{GradCam++}^C = \text{ReLU}(\sum_k \alpha_k^C A^k) \quad (3.11)$$

ReLU fonksiyonunda modeldeki negatif değerlerin sıfıra indirgenmesi sağlanmaktadır. Elde edilen belirginlik haritası ile modellerin kararlarının insanlar tarafından daha açık bir şekilde yorumlanabilmesi amacıyla normalize edilmekte ve görselleştirilmektedir. Bu haritalarda genel olarak giriş görüntülerinin üzerine yerleştirilmekte ve mevcut modelin dikkat ettiği bölgelerin belirgin bir şekilde görülmesini sağlamaktadır [140].

EigenCam:

EigenCam, derin öğrenme modellerinin karar süreçlerinin görselleştirilmesi amacıyla kullanılan ve GradCam yöntemine benzer nitelikli olan yöntemdir. EigenCam tekniği, evrişimli sinir ağlarının son katmanlarındaki öznitelik haritalarının kovaryans matrisleri ile bu matrislerin temel bileşenlerini kullanarak, mevcut modelin belirli sınıflarını tahmin etme süreçlerinde hangi alanların etkili olduğunu göstermektedir. Bu teknik oluşturulan modellerin kararlarının daha kapsamlı anlaşılabilmesini ve daha az gürültü ile görselleştirmelerin yapılabilmesini sağlamaktadır. EigenCam tekniğinin temel çalışma prensibi, mevcut modelin son evrişim katmanında bulunan öznitelik haritaları ile bu haritaların kovaryans matrislerinin incelenmesine dayanmaktadır [141]. Tekniğin ilk aşamasında giriş görüntüleri modele verilerek işlenmektedir. Tekniğin son evrişim katmanında ise oluşturulan öznitelik haritaları “ A^k ” ile elde edilmektedir. Modelde oluşturulan haritalar, ilgili modelin görüntülerdeki hangi bölgelere odaklandığını göstermektedir. Bu aşamadan sonra öznitelik haritaları kullanılarak çeşitli haritaların birbirleriyle ilişkilerinin ve varyanslarının gösterildiği kovaryans matrisi “ C ” hesaplanmaktadır. Modeldeki öznitelik haritalarının kovaryans matrislerinin tespit edilmesi, mevcut modelin en çok varyansının olduğu bileşenlerin tespit edilebilmesi için önemlidir. Bu matrisler özellikle geniş veri kümeleriyle karmaşık modeller için önemli bilgiler sunabilmektedir. Kovaryans matrisi C , öznitelik haritasındaki her bir kanalın “ F_k ” kovaryansını sembolize etmektedir ve Denklem 3.12’deki formül ile hesaplanmaktadır [142].

$$C = \frac{1}{N-1} \sum_{i=1}^N (F_i - \mu)(F_i - \mu)^T \quad (3.12)$$

Denklem 3.12’de yer alan “ μ ” ifadesi modeldeki öznitelik haritasının ortalamasını ifade ederken, “ N ” örnek sayısını ifade etmektedir. Kovaryans matrisinin özdeğerleri ile özvektörleri de hesaplanmaktadır. Özdeğerler; kovaryans matrisinin bileşenlerinin önem derecelerini gösterirken,

özvektörler; bileşenlerin yönlerini göstermektedir. Modeldeki en büyük özdeğerlere sahip olan vektörler, en büyük varyansı taşıdıkları için seçilmektedir. Ayrıca bu özvektörler son evrişim katmanındaki öznitelik haritaları ile çarpılarak modeldeki her haritanın önemli bileşenlerine göre ağırlıklandırılması yapılmaktadır. Ağırlıklandırılmış öznitelik haritaları daha sonra birleştirilmekte ve bir adet ısı haritası üretilmektedir. Üretilen ısı haritası, kullanılan modelin tahminlemesinde odaklandığı bölgeleri ortaya çıkarmaktadır. Modelde elde edilen ısı haritası ReLU fonksiyonuyla normalize edilmektedir [142]. Denklem 3.13’de normalize edilmiş formül görülebilmektedir.

$$L_{EigenCam}^C = ReLU(\sum_k \lambda_k e_k^T A^k) \quad (3.13)$$

Denklem 3.13’de görülen “ λ_k ”; özdeğerleri, “ e_k ” ise özvektörleri sembolize etmektedir. Model kapsamında oluşturulan ısı haritaları 0-1 arasında normalize edilmekte ve giriş görüntülerinin boyutlarına kadar genişletilebilmektedir. Daha sonra modelden elde edilen haritalar giriş görüntülerinin üzerine konumlandırılmaktadır. Bu durum sonucunda kullanılan modelin tahminleme esnasındaki en çok hangi alanlara odaklandığı net biçimde görselleştirilmektedir [142]. EigenCam tekniği öznitelik haritasının önemli bileşenlerini kullanmakta ve daha az gürültü içeren görselleştirmeler oluşturmaktadır. Gradyanlar ya da sınıf skorlarına bağlı olmadıkları için geri yayılım gereksinimleri bulunmamaktadır. Ayrıca bütün evrişimli sinir ağlarında sorunsuz bir şekilde kullanılabilirler. Bu teknikte yeniden eğitim süreçlerine veya mimari değişikliklere gereksinim duyulmamaktadır. EigenCam tekniği, evrişim katmanlarında öğrenilen temsillere dayandığı için adversaryal gürültülerden etkilenmemekte ve mevcut temsillerin modelin temel bileşenlerini kullanması ile sınıf aktivasyon haritaları oluşturulabilmektedir. Bu özellikleri ile EigenCam tekniği özellikle adversaryal gürültülere karşı dirençli bir formdadırlar. Bunun sebebi ise bu tür gürültülerin genel olarak sınıflandırma katmanlarında daha fazla sayılarda etki göstermeleridir [143].

ScoreCam:

Gradyanlar bazı modellerde çeşitli bozulmaları içerebilmekte ve her daim öznitelik haritalarındaki tüm konumların katkılarını doğru biçimlerde ifade edememektedir. Bu sorunun çözülmesi amacıyla gradyanlara olan bağımlılıkların azaltılması gerekmektedir. Bu noktada ScoreCam yöntemi ideal bir uygulama alanına sahiptir [104]. ScoreCam tekniğinde öncelikle “ A^k ” giriş boyutuna ölçeklendirilmekte ve maske “ H^k ” oluşturulmaktadır. Modelde oluşturulan maske, girişte ilgilenilen özellikleri korumaktadır. İkinci olarak “ H^k ” ile X noktasal çarpımı modeldeki ağda işlenmektedir. Bu işleme sonucunda “ A^k ”nın çıktıya olan katkıları elde edilebilmektedir. Elde edilen bu katkılar, ScoreCam tekniğinin nöron önem ağırlığı olan “ W_k^C ” ile sembolize edilmektedir [144]. Denklem 3.14’de nöron önem ağırlığının formülü görülebilmektedir.

$$w_k^c = f(XoH^k) - f(X) \quad (3.14)$$

ScoreCam tekniğinin ağırlığı, bozulma tabanlı yaklaşımlar ile elde edilen türevler olarak verilebilmektedir. Bu işlem sonucunda modeldeki gradyanların eksiklikleri belirli düzeylerde aşılabilmektedir [104]. Denklem 3.15’de öznitelik haritalarının lineer kombinasyonlarında kullanılan ReLu fonksiyon formülü görülebilmektedir.

$$M_{ij}^c = ReLU(\sum_k W_k^c A_{ij}^k) \quad (3.15)$$

XGradCam:

XGradCam, aksiyom tabanlı GradCam olarak da nitelendirilmektedir. XGradCam tekniğinde duyarlılık ile korunum olmak üzere iki adet aksiyom kullanılmaktadır. Duyarlılık aksiyomu; modeldeki önemli özelliklerin çıkarılmasının modelin tahmin edilmesindeki önemli değişikliğe sebep olması gerektiğini göstermektedir [145]. Denklem 3.16’da duyarlılık aksiyomunun formülü görülebilmektedir.

$$S_c(F^l) - S_c(F^l / F^{lk}) = \sum_{x,y} w_c^k F^{lk}(x, y) \quad (3.16)$$

Denklem 3.16’da yer alan “ $S_c(F^l)$ ”; 1. katmandaki özellik haritasının tamamının kullanılması sonucunda sınıf c için tahmin edilen skoru ifade etmektedir. “ $S_c(F^l / F^{lk})$ ”; k. özellik haritasının çıkarılması ile modelin sınıf skoru üzerinde oluşturduğu farkların, ilgili haritanın tahmin edilmesi için ne kadar önemli olduğunu ifade etmektedir. Korunum aksiyomu ise modeldeki bütün özellik haritalarının toplamalarının ilgili modelin sınıf tahminlemesine eşit olmasını gerçekleştirmektedir. Bu durum toplam aktivasyonlarının ilgili modelin tahmin skoruyla orantılı olduğunu göstermektedir [145]. Denklem 3.17’de korunum aksiyomuna ait formül görülebilmektedir.

$$S_c(F^l) = \sum_{x,y} (\sum_{k=1}^K (w_c^k F^{lk}(x, y))) \quad (3.17)$$

Korunum aksiyomları ilgili modellerin tahmin skorlarının yalnızca belirli sınıfa odaklanan özellik haritalarıyla açıklanmasını sağlamaktadır. Özetle sınıf skorları sadece ilgili modelin karar verdiği belirli alanlardan geldiği söylenebilmektedir. XGradCam tekniği GradCam’e benzeyen, sınıf tahmini yapabilen CNN katmanlarındaki özellik haritalarının sınıf skorlarına olan etkilerini analiz edebilmektedir [145]. Ancak XGradCam tekniğinde duyarlılık aksiyomları ile korunum aksiyomlarının sağlanabilmesi amacıyla optimizasyon süreci uygulanmalıdır. Modelde ağırlıkların tespit edilmesinde her özellik haritasının sınıf skorlarına olan etkilerinin en iyi biçimlerde hesaplanması için matematiksel modeller kullanılmaktadır. Modelde ağırlıkların hesaplanabilmesi amacıyla optimizasyon sorunlarının çözülmesi gerekmektedir [145]. Denklem 3.18’de optimizasyon sorunlarının çözülebilmesine yönelik formül görülebilmektedir.

$$\emptyset(W_c^k) = \sum_{k=1}^K |S_c(F^l) - S_c(F^l / F^{lk}) - \sum_{x,y} W_c^k F^{lk}(x,y)| + |S_c(F^l - \sum_{x,y} \sum_{k=1}^K W_c^k F^{lk}(x,y))| \quad (3.18)$$

Denklem 3.18’de görülen optimizasyon sorunlarının çözülebilmesi için kullanılan formül, duyarlılık aksiyomları ile korunum aksiyomlarının maksimum düzeylerde sağlanabilmesini amaçlamaktadır [145].

LayerCam:

Modellerin çeşitli ağ işlemlerinden elde edilen dikkat haritaları, kapsamlı nesne yerleştirme bilgilerinin sağlanabilmesi amacıyla birleştirilmektedir. Ayrıca geriye yayılım gradyanları da modeldeki dikkat haritalarının üretilmesi amacıyla kullanılmaktadır. Modeldeki herhangi bir öznitelik haritasında bulunan her bir mekânsal konum için pozitif gradyanlar, “ A_{ij}^k ” ile çarpılmakta ve modelde yeni öznitelik haritası olan “ $\hat{A}_{ij}^k$ ” üretilmektedir [146]. Denklem 3.19’da modelde yeni öznitelik haritasının üretilme formülü görülebilmektedir.

$$\hat{A}_{ij}^k = ReLU\left(\frac{\partial y^c}{\partial A_{ij}^k}\right) \cdot A_{ij}^k \quad (3.19)$$

LayerCam tekniği belirli katmanlardaki bütün “ A_{ij}^k ”leri doğrusal biçimde birleştirmekte ve yeni değerleri oluşturmaktadır [146].

GradCam Element-wise:

GradCam Element-wise, GradCam tekniğinin uyarlamasıdır. Bu yöntem, GradCam’e göre daha fazla kapsamlı açıklama içermektedir. Ayrıca açıklamaların daha net biçimlere getirilebilmesi amacıyla piksel bazlı işlemler kullanılmaktadır. GradCam Element-wise tekniği, GradCam tekniğinin sunduğu görsel haritaları daha kapsamlı biçimlerde iyileştirmek amacıyla geliştirilmiştir. Ayrıca aktivasyon haritaları ile gradyanların piksel düzeylerinde birleştirmekte ve açıklamaları daha kapsamlı oluşturmaktadır [147]. GradCam tekniği, sınıf tahminlemesine etki eden alanları gösteren ısı haritaları sağlarken oluşturduğu haritalar çok ayrıntı vermemektedir. GradCam Element-wise tekniği ise eleman bazında çarpma işlemi yapmakta ve bu sebeple her pikselde aktivasyon haritaları ile gradyanları birleştirmektedir. Bu durum sonucunda daha net ve yüksek çözünürlükte açıklamalar üretilmektedir. Özetle GradCam Element-wise tekniği ile GradCam tekniği arasındaki en temel fark GradCam tekniğinin oluşturduğu genel görselleştirmeleri daha detaylı ve daha ayrıntılı bir şekilde geliştirmesi ve piksel seviyesinde keskin açıklamalar üretebilmesidir [147].

3.9.2. Cam Tekniklerinin Değerlendirilme Metrikleri

Cam yöntemleri yalnızca arka plan ve yalnızca ilgili alan olmak üzere iki teknikle değerlendirilebilmektedir.

Yalnızca Arka Plan

Modelde ilgili piksellerin maskelenmesiyle, modelin sınıflandırma skorunda düşüşler gözlemlenebilmektedir. Bu metrikte modelin sadece arka plana odaklanması ve burada nasıl davrandığının değerlendirilmesi yapılmaktadır. Modeldeki ilgili nesneler ya da nesnelerin maskeleri uygulanabilmektedir. Bu durum sonucunda ilgili model yalnızca arka planı görebilmekte ve daha sonra modelin sınıflandırma performansındaki değişimler analiz edilebilmektedir. Model, arka plana odaklanıp sınıflandırma yeteneğinde belirgin biçimlerde düşüşler gösteriyorsa bu durum sonucunda M1 metriği düşük değerle sonuçlanmaktadır. Bu noktada modelin ilgili nesneleri tanımlamak amacıyla gerçekten nesne özelliklerine odaklandığı söylenebilmektedir [148].

Yalnızca İlgili Alan

Modeldeki arka plan maskelendiğinde ve yalnızca modeldeki ilgili pikseller kaldığında modelin sınıflandırma skorunda değişimler gözlemlenebilmektedir. Bu metrik, sadece ilgili nesnelerin vurgulandığı senaryoları inceleyebilmektedir. Bu kapsamda, arka plan maskelenmekte ve sadece modelin ilgili nesnesinin görüntüleri kalmaktadır. Modelin bu aşamda sınıflandırma performansındaki değişimler değerlendirilebilmektedir. Model sadece ilgili nesnelere odaklanarak mevcut performansını artırabiliyorsa M2 metriğinde yüksek değerlere ulaşılabilir. Bu durum modelin gerçek anlamda ilgili nesneyi tanımlamak amacıyla önemli özelliklere odaklandığını ortaya koymaktadır [148].

3.10. SHAP Tekniği

Açıklanabilir yapay zeka, makine öğrenimi ile yapay zeka modellerinin (özellikle opak modeller) insanlar tarafından anlaşılabilir olmasını sağlamaktadır. Derin öğrenme ve karmaşık ağaç tabanlı teknikler başta olmak üzere YZ modellerinin birçoğu, karmaşık ve anlaşılması zor yapılardır. Bu kapsamda ilgili modellerin neden belirli kararlar aldığının anlaşılması zorlaşabilmektedir. SHAP (SHapley Additive exPlanations) tekniği, bu tür zor kararların şeffaflaştırılmasını ve yorumlanabilir olmasını sağlayan güçlü yöntemlerden birisidir. SHAP tekniği özellikle modeldeki özelliklerin, ilgili modelin tahminine ne kadar katkı sağladığını anlamaya yönelik global ve yerel açıklamalar yapabilen yöntem olarak verilebilmektedir. SHAP, Shapley değerleri olarak nitelendirilen kavramdan türetilmiştir. Bu kavramın temeli oyun teorisine dayanmaktadır [149].

3.10.1. Shapley Değerleri ve Değerlerin Hesaplanması

Shapley değerleri, oyun teorisinin bir parçasıdır. Bu değerler, kullanıcının ya da özelliğin bir modele katkısının nasıl değerlendirileceğini belirlemektedir. Oyun teorisi kapsamında, her özellik ya da kullanıcının toplam ödüle ne kadar katkı sağladığının hesaplanması amacıyla Shapley değerleri kullanılmaktadır. Shapley değerleri, her kullanıcının katkısının eşit ve adil bir biçimde dağıtılmasını sağlamaktadır. Makine öğretiminde her özellik, ilgili modelin tahmin edilmesine belirli düzeylerde katkılar sağlamaktadır. Shapley değerleri ise bu katkıyı adil bir biçimde hesaplamak amacıyla kullanılmaktadır. SHAP tekniği, Shapley değerlerini model içerisinde kullanarak, bir modelin tahmin edilmesinde her bir özelliğin ne kadar etkisinin olduğunu anlaşılmasını sağlamaktadır [150].

Shapley değerlerinin hesaplanması için modeldeki her özelliğin farklı kombinasyonlarının göz önüne alınması gerekmektedir. Bu durum modeldeki her özelliğin katkısını, diğer özelliklerin varlığını veya yokluklarının dikkate alınmasıyla hesaplanmaktadır. Modeldeki bir özelliğin Shapley değeri, ilgili özelliğin her mümkün kombinasyona katkısının ortalaması olarak verilebilmektedir [151]. Denklem 3.20’de Shapley değerlerinin formülü görülebilmektedir.

$$\phi_i(\vartheta) = \sum_{S \subseteq N/\{i\}} \frac{|S|!(|N|-|S|-1)!}{|N|!} [\vartheta(S \cup \{i\}) - \vartheta(S)] \quad (3.20)$$

Denklem 3.20’de yer alan “ $\phi_i(\vartheta)$ ”; modelin özellik i’sinin Shapley değerini, “N”; modeldeki tüm özelliklerin kümesini, “S”; modeldeki i özelliğini içermeyen alt kümeyi ve “ $\vartheta(S)$ ” ise S’nin tahminini ifade etmektedir. Modeldeki Shapley değerinin yüksek olması, modeldeki bir özelliğin ilgili modelin tahminine daha fazla katkı sağladığını göstermektedir. Modeldeki Shapley değerinin düşük olması ise modeldeki özelliğin ilgili modelin tahminine daha az katkı sağladığını göstermektedir [151].

3.10.2. SHAP Tekniğinin Temel Prensipleri

SHAP, Shapley değerlerini kullanarak, modeldeki her bir özellik için ilgili modelin tahmin edilmesine olan katkısını hesaplamaktadır. SHAP tekniğinin dört adet temel prensibi bulunmaktadır [152]. Bunlar;

1. Eşitlik (Fairness): SHAP tekniği, modeldeki tüm özelliklerin katkılarını, ilgili modelin tahminine etkisi üzerinden eşit veya adil biçimde hesaplamaktadır. Bu durum modelin nasıl çalıştığının kullanıcılar tarafından daha iyi anlaşılmasını sağlamaktadır. Ayrıca modeldeki her özelliğin tahmin üzerindeki etkisinin ölçülebilmesinde de katkı sağlamaktadır.
2. Katkı (Additive): SHAP tekniği, modelin tahmininin her özelliğin katkılarının toplamı olarak ifade edilebilmesini sağlamaktadır. Modelin tahmini, bütün özelliklerin Shapley

değerlerinin toplamına eşittir. Bu özellik, SHAP tekniğinin güçlü yönlerinden bir tanesidir. Bunun sebebi ilgili modelin tahminini basit bir biçimde yorumlanabilir parçalara bölmektedir.

3. Global ve yerel yorumlama: SHAP tekniği hem modelin genel davranışı (global) hem de bireysel tahminler için özellik katkılarının (yerel) açıklanmasını sağlamaktadır. Global yorumlar, ilgili modelin genel davranışlarının anlaşılmasına katkı sağlarken yerel yorumlar ise modeldeki her bir veri noktasının neden belirli tahmin yaptığını açıklamaktadır.
4. Model agnostik: SHAP tekniği modelden bağımsız bir yöntem olarak verilebilmektedir. Doğrusal modellerden karmaşık derin öğrenme ağlarına kadar çeşitli model türlerinde kullanılabilmesini sağlamaktadır [152].

3.10.3. SHAP Tekniğinin Çalışma Prensipleri

SHAP tekniğinde, özelliklerin model tahminine katkısının hesaplanabilmesi için belirli adımların izlenmesi gerekmektedir. Bunlar sırasıyla şu şekildedir;

1. Modelin ve özelliklerin seçilmesi: SHAP tekniği, herhangi bir modelin tahminini açıklamak amacıyla bir örnek ve bu örneğin özelliklerini seçmektedir. Eğer model sınıflandırıcı ise ilgili modelin her bir özellik için katkıları hesaplanmaktadır.
2. Shapley değerlerinin hesaplanması: SHAP tekniğinde, modelin tahmininin oluşturulabilmesi amacıyla her özelliğin farklı kombinasyonları üzerindeki etkileri hesaplanmalıdır. Bu durum ilgili modelin her özellik için Shapley değerinin hesaplanmasıyla sağlanabilmektedir.
3. Açıklamaların oluşturulması: SHAP tekniği, hesaplanan Shapley değerlerini esas alarak her bir özellik için ilgili modelin tahminine yaptığı katkıları sunmaktadır. Bu değerler genel olarak görselleştirilebilir biçimlerde sunulabilmekte ve kullanıcılara açıklamalar sağlayabilmektedir. Bu aşamada hem global hem de yerel açıklamalar yapılmaktadır. Global açıklamalarda; tüm modelin öğrenme süreci ile genel karar sistemleri hakkında bilgi elde edilebilmekte ve özelliklerin genel etki düzeyleri ile birbirleriyle olan ilişkileri elde edilebilmektedir. Yerel açıklamalarda ise modeldeki her bir örnek için özelliklerin model tahminine olan katkıları görselleştirilmektedir. Bu durum sonucunda her bir tahminin arkasındaki mantık anlaşılabilir. Bu durum sonucunda her bir tahminin arkasındaki mantık anlaşılabilir.
4. Yorumlama: SHAP tekniği, kullanıcıların ilgili modelin nasıl çalıştığını ve hangi özelliklerin hangi tahminlere sağladığı katkıların anlaşılmasını sağlamaktadır [152].

3.10.4. SHAP Tekniğinin Avantaj ve Sınırlılıkları

SHAP tekniği kullanıcılarına çeşitli avantajlar sunmaktadır. Bunlardan bazıları şu şekilde verilebilmektedir;

- Adil ve tutarlı açıklamalar: SHAP tekniği, her özelliğin ilgili modelin tahminine olan katkılarını adil bir biçimde sunmaktadır. Bu durum sonucunda hangi özelliğin modelin kararları üzerinde daha fazla etkili olduğu net biçimde anlaşılabilmektedir.
- Model agnostik: SHAP tekniği herhangi bir makine öğrenimi modeline (doğrusal, doğrusal olmayan, derin öğrenme gibi) uygulanabilmektedir.
- Global ve yerel açıklamalar: SHAP tekniği hem ilgili modelin genel davranışı (global açıklama) hem de bireysel tahminler (yerel açıklama) hakkında bilgi verebilmektedir. Bu durum hem kullanıcılar hem de araştırmalar için esnek bir ortamın oluşturulmasına katkı sağlamaktadır.
- Yüksek düzeyde anlaşılabilirlik: SHAP tekniğinde sunulan görselleştirme yöntemleri, ilgili modelin tahminlerine nasıl ulaşıldığının kolay bir şekilde anlaşılmasını sağlamaktadır.
- Model performansını etkilememe: SHAP tekniği, ilgili modelin doğruluğu ile performansını etkilemeden açıklamalar sunmaktadır. Bunun sebebi SHAP tekniğinin yalnızca tahminlerin açıklanmasına yönelik bir süreçten oluşturulmasıdır [153].

SHAP tekniğinin çeşitli sınırlılıkları da bulunmaktadır. Bunlar şu şekilde sıralanabilmektedir;

- Maliyet: Shapley değerlerinin hesaplanabilmesi karmaşık ve hesaplama açısından maliyetli olabilmektedir. Özellikle büyük veri setleri ile karmaşık modeller için Shapley değerlerinin hesaplanması zaman alabilmektedir.
- Yaklaşık değer hesaplama: SHAP tekniğinin hesaplama süresinin kısaltılabilmesi için yaklaşık hesaplama teknikleri kullanılabilmektedir. Bu durum ilgili modelin doğruluğunun belirli düzeylerde kaybedilmesine sebep olabilmektedir.
- Büyük modellerde karşılaşılan zorluklar: Çok sayıda özellik ve büyük veri setleriyle çalışan modellerde (derin öğrenme, büyük ağaç tabanlı gibi) SHAP tekniğinin hesaplanması oldukça zordur. Ayrıca bazı durumlarda sınırlı kaynaklarla yapılması gerektiği de söylenebilmektedir [153].

3.11. LIME (Local Interpretable Model-Agnostic Explanations) Tekniği

LIME tekniği; yerel yorumlanabilir model-agnostik açıklamalar anlamına gelmektedir. LIME tekniği, karmaşık ve opak makine öğrenimi modellerinin kararlarını açıklamak amacıyla kullanılan popüler açıklanabilir tekniklerden bir tanesidir. LIME tekniği, ilgili modelin karmaşıklığından bağımsız olarak çalışmaktadır. Özetle bu teknikte yalnızca karar süreçlerinin açıklanması değil aynı zamanda herhangi bir makine öğrenimi modeline uygulanması da yapılabilmektedir [154]. LIME,

özellikle sınıflandırıcılar gibi karmaşık modellerin yerel açıklamalarını sağlamada etkili bir tekniktir. LIME, bir modelin genel yapısının anlaşılması yerine belirli bir veri noktasındaki tahminlerin nasıl yapıldığının anlaşılmasına odaklanmaktadır. Modeldeki açıklamalar yereldir. Modelin belirli bir örneğe özgü olması ve ilgili modelin kararının anlaşılabilmesi amacıyla mevcut örneği kullanması ile süreç yürütülmektedir [155].

3.11.1. LIME Tekniğinin Çalışma Prensibi

LIME tekniğinde herhangi bir modelin kararlarını açıklamak amacıyla çeşitli adımları izlenmektedir. Bunlar sırasıyla şu şekilde verilebilmektedir;

1. Veri noktalarının seçimi: LIME tekniğinde, model için açıklama yapılacak veri noktası seçilmelidir. Bu durum modelin tahmin edeceği bir test örneği olarak verilebilmektedir.
2. Yeni veri noktalarının oluşturulması: LIME tekniğinde mevcut veri noktasına benzeyen ancak çeşitli rastgele değişiklikler yapılmış yeni veri örnekleri oluşturulmalıdır. Oluşturulan yeni örnekler, ilgili modelin nasıl bir tahmin yaptığına göre varyasyonlar içermektedir.
3. Modelin tahminlerinin toplanması: Model içerisinde oluşturulan yeni veri noktaları, orijinal model üzerinde test edilmelidir ve her biri için tahminler alınmalıdır.
4. Yerel yorumlanabilir modelin eğitilmesi: LIME tekniğinde, elde edilen yeni veriler ile tahminlerin alt kümeleri üzerinde açıklamalara odaklanan basit bir model eğitilmektedir. Bu model, orijinal modelin davranışını yerel olarak taklit etmektedir.
5. Özelliklerin ağırlıklarının hesaplanması: Yerel modellerdeki özelliklerin her birinin orijinal modelin tahminlerine nasıl katkı sağladığını göstermektedir. Bu durum, orijinal modelin kararlarının daha anlaşılır hale getirilmesini sağlamaktadır.
6. Açıklamaların sunulması: LIME tekniğinde belirli bir örnek için oluşturulan tahminin hangi özelliklerin referans alınarak yapıldığı ve hangi özelliklerin en etkili olduğunun görselleştirilmesine yönelik açıklamalar sunulmaktadır [152].

3.11.2. LIME Tekniğinin Avantajları ve Sınırlılıkları

LIME tekniği kullanıcılarına çeşitli avantajlar sunmaktadır. Bunlar başlıca şu şekilde verilebilmektedir;

- Model agnostik: Herhangi bir makine öğrenimi modeline (Karar ağaçları, sinir ağları, destek vektör makineleri gibi) uygulanabilmekte ve çalışabilmektedir.
- Yerel yorumlama: Her bir örnekten yerel açıklama elde edilebildiği için kullanıcıların modelin karar süreçlerini daha spesifik bir biçimde anlaması sağlanabilmektedir.

- Basit ve yorumlanabilir modeller: Karmaşık modelleri basitleştirmekte ve yorumlanabilir bir forma dönüştürerek açıklamaya çalışmaktadır.
- Esneklik: Modelin karmaşıklığına ya da yapısına bağlı bir şekilde esnek biçimlerde çeşitli türlerde açıklamalar elde edilebilmektedir [156].

LIME tekniğinin çeşitli sınırlılıkları da bulunmaktadır. Bunlar başlıca şu şekilde verilebilmektedir;

- Yerel yorumlamaların sınırlı olması: LIME tekniği ile yerel açıklamalar elde edilebilmekte ve bu açıklamalar yalnızca ilgili örnek üzerinde yapılabilmektedir. Bu sebeple ilgili modelin genel yapısının anlaşılabilmesi amacıyla birden fazla örnek üzerinden açıklamaların yapılması gerekmektedir.
- Veri noktalarının etkisi: LIME tekniğinde açıklamalar sadece belirli örnekler üzerinde oluşturulmaktadır. Bu durum ilgili modelin genel davranışına yönelik yanıltıcı sonuçlar verebilmektedir. Modelin çeşitli veri noktalarındaki tutarlılığının anlaşılması da zorlaşabilmektedir.
- Hesaplama maliyeti: LIME tekniğinde her bir açıklama için ilgili modelin çeşitli tahminleri yapılmaktadır. Bu durum özellikle büyük veri kümeleri ya da karmaşık modeller için yüksek hesaplama maliyetlerine yol açabilmektedir.
- Basitleştirilmiş modellerin yetersiz kalması: LIME tekniğinde karmaşık bir modelin yerel açıklamalarının yapılması için daha basit bir model kullanılmaktadır. Ancak bu basit modeller bazı durumlarda orijinal modelin davranışını tam olarak yansıtmayabilmektedir. Bu durum sonucunda modelin yapmış olduğu açıklamaların doğrulukları da azalabilmektedir [156].

Makine öğrenmesinin kullanılmasının günümüzde birçok alanda avantajlarının olduğu görülebilmektedir. Bu kapsamda konunun daha iyi anlaşılabilmesi amacıyla literatürde yapılan makine öğrenmesinin kullanıldığı tıbbi alandaki çalışmalar incelenmiştir.

3.12. Literatürde Yapılan Çalışmalar

Bu bölümde makine öğrenmesi yöntemlerinin kullanılmasıyla hastalık teşhisi yapan çalışmalar ve sonuçları verilmiştir.

3.12.1. Beyin Tümörüne Yönelik Yapılan Çalışmalar

Ramteke ve Monali [157] çalışmasında normal ve malign beyin tümörlerinin MR görüntüleri ile doku özelliklerinin K-En Yakın Komşu sınıflandırma algoritmasının kullanımıyla doğruluğunun incelenmesi amaçlanmıştır. Çalışma sonucunda en yakın komşu sınıflandırma algoritmasının MR görüntülerinden tümörlerin tespit doğruluğunun %80 olduğu ortaya konulmuştur.

Gadpayleand ve Mahajani [158] çalışmasında normal huylu ve kötü huylu beyin tümörlerinin MR görüntüleriyle doku özelliklerinin sinir ağı sınıflandırıcısıyla doğruluklarının incelenmesi amaçlanmıştır. Çalışma sonucunda sinir ağı sınıflandırıcısının tespit doğruluğunun %72,5 olduğu ortaya konulmuştur.

Ghosh ve Bandyopadhyay [159] çalışmasında hastaların MR görüntülerinden beyindeki tümör tiplerinin sınıflandırılmasının bulanık K-Means Kümeleme algoritması kullanımıyla doğruluğunun incelenmesi amaçlanmıştır. Çalışma sonucunda beyindeki tümörlerin sınıflandırılmasında bulanık K-Means Kümeleme algoritmasının %89,2 doğruluğunun olduğu ortaya konulmuştur.

Abidin vd. [23] çalışmasında metastaz ve glioblastoma tümörlerinin tespit edilebilmesi için AdaBoost sınıflandırma algoritmasının doğruluğunun incelenmesi amaçlanmıştır. Çalışma sonucunda tümörlerin tespit edilmesindeki sınıflandırma doğruluğunun %71 olduğu ortaya konulmuştur.

Anaraki vd. [160] çalışmasında beyin tümörü görüntülerinin genetik algoritma ve CNN'e göre sınıflandırma doğruluğunun incelenmesi amaçlanmıştır. Çalışma sonucunda geliştirilen modelin gliomun üç derecesinin sınıflandırılmasında %90,9 doğruluğunun olduğu ortaya konulmuştur.

Sajjad vd. [24] çalışmasında beyin tümörlerinin sınıflandırılması için CNN mimarisinin VGG-19 algoritması kullanılmasıyla doğruluğunun incelenmesi amaçlanmıştır. Çalışma sonucunda CNN modelinden önce %87,38 doğruluğu varken CNN modelinde veri sayısının artırılmasıyla %90,67 doğruluğa yükseldiği ortaya konulmuştur.

Mohsen [47] çalışmasında ayırık dalgacık dönüşümü özellikleri ile derin öğrenme yöntemlerini birleştiren sistem önerisinin yapılması amaçlanmıştır. Çalışma da temel bileşen analizleriyle özellik boyutları azaltılmış ve seçilen özellikler derin sinir ağlarıyla sınıflandırılmıştır. Çalışma sonucunda modelin %96,97 doğruluğunun, %97 hassasiyetinin ve %98,4 eğri altında kalan alan değerinin olduğu ortaya konulmuştur.

Zhou vd. [161] çalışmasında kontrastlı T1W sekansı ile T2W-Flair sekansının düşük/yüksek dereceli gliomaların 1p/19q birlikte silme durumlarının sınıflandırılmasının yapılması amaçlanmıştır. Çalışma kapsamında Rastgele Orman sınıflandırıcı kullanılmıştır. Çalışmanın test sonucunda 0,92'lik AUC değeri elde edilmiş ve IDH mutant gliomaları bulunan hasta grup için 1p/19q birlikte silme durumunun tahmin edilebilmesi için farklı model eğitilmiştir. Çalışma sonucunda 15 radyomik özellik ile 0,69 AUC değeri ortaya konulmuştur.

Park vd. [25] çalışmasında Rembrandt veri seti kullanılarak 175 LGG'nin MR görüntülerinin test ve doğrulama değerlerinin incelenerek mutasyonları öngören modelin geliştirilmesi amaçlanmıştır. Çalışma sonucunda geliştirilen modelin test setlerinde 0,859 AUC değerine ve 0,788 AUC değerine sahip IDH1 mutasyonlarını öngören bir model olduğu ortaya konulmuştur.

Bisdas vd. [162] çalışmasında Destek Vektör Makinesini kullanarak IDH-mutant tümörlerinin sınıflandırılması amaçlanmıştır. Çalışma da birinci dereceli istatistikler ile doku özelliği

ekstraksiyonuna sahip olan Grade 2 ile Grade 3 tümörü olan 37 hasta verisi hem Flair hem de ortalama difüzyonel basıklık görüntüleri kullanılmıştır. Bu görüntüler Destek Vektör Makinesi aracılığıyla IDH-mutant tümörleri sınıflandırmış ve mutasyon tespitinde %81,1'lik doğruluğunun ve %59 AUC değerinin olduğu ortaya konulmuştur.

Yu vd. [163] çalışmasında Grade 2 tanısı alan hastaların IDH durumlarının tahmin edilmesi amaçlanmıştır. Çalışma kapsamında geliştirilen radyomik teknik ile görüntü segmentasyonu, özellik çıkarma, radyomik sıralama, özellik seçimi ile sınıflandırma işlemleri sırasıyla mevcut veri setine uygulanmıştır. Çalışma da 671 özellik elde edilmiş ve bu özellikler arasından 110 tanesi seçilmiştir. Çalışma sonucunda geliştirilen modele dayalı noninvazif IDH1 durum tahmininin %80 doğrulukta, %83 duyarlılıkta ve %74 özgüllükte olduğu ortaya konulmuştur.

Shofty vd. [164] çalışmasında IDH1 mutasyonlu tümörlerle LGG tanısı alan 47 hastanın ameliyat öncesi MR görüntüleri ve 1p/19q durumlarının genetik analizleri yapılmıştır. Veriler beş katlı çapraz doğrulama ile incelenmiştir. Çalışma sonucunda radyomik analizler ile 1p/19q bozulmamış tümürlü astrositomlar, 1p/19q kodlu oligodendrogliomlardan ayırt edilebilmiştir. Çalışma sonucunda modelde en iyi sınıflandırmayı Ensemble Torbalı Ağaçlar sınıflandırıcısının (%87) yaptığı ortaya konulmuştur.

Ramon vd. [165] çalışmasında MR görüntülerinden elde edilen 2D doku özelliklerinin potansiyellerinin değerlendirilmesi amaçlanmıştır. Çalışmada toplam 100 hasta verisi kullanılmış ve 88 radyomik özellikten 32 özellik seçilmiştir. Ayrıca bu özellikler, tümörlerin metastas ve glioblastoma sınıflandırılması için kullanılmıştır. Sınıflandırma sonucunda Vektör Makine algoritmasından %89 AUC değeri elde edilirken, Naive Bayes algoritmasından ve K-En Yakın Komşu algoritmasından %80 AUC değeri elde edilmiştir. Ayrıca çalışma sonucunda vektör makine algoritmasının en iyi performans gösterdiği bildirilmiştir.

Han vd. [166] çalışmasında histopatolojik düşük dereceli glioma kategorisindeki Grade 2 ile Grade 3 tanısı alan 277 hastanın 647 MR tabanlı özellikleri çıkarılmıştır. Çalışmada radyonik analiz işlemi kullanılmış ve eğitim kohortunda 1p/19q birlikte silinmesini tahmin etmek amacıyla Rastgele orman algoritması kullanılmıştır. Çalışma sonucunda Rastgele Orman algoritmasının eğitimde %88,7 doğruluğunun, tahmin etmede ise %76 doğruluğunun olduğu ortaya konulmuştur. Ayrıca algoritmanın kohortlarında 1p/19q birlikte silme genotiplerini ayırt etmek amacıyla kullanılabileceği bildirilmiştir.

Chang vd. [167] çalışmasında MR görüntülerinden elde edilen veriler ile IDH1 mutasyon ve 1p/19q kod çözme durumunun sınıflandırılması amaçlanmıştır. Çalışmada düşük/yüksek dereceli gliomali 259 hasta verisi TCIA'dan geçmişe dönük alınmıştır. Ardından çalışmada IDH1 mutasyonu ile 1p/19q kod çözme durumlarının sınıflandırılması için kıvrımlı sinir ağı eğitilmiş ve bu veriler temel bileşen analizlerinin sınıflandırılması amacıyla özelliklerin çıkarılmasında kullanılmıştır. Çalışma

sonucunda IDH1 mutasyon durumunun %94 doğruluğunun olduğu ve 1p/19q kod çözme durumunun ise %92 doğruluğunun olduğu ortaya konulmuştur.

Lu vd. [168] çalışmasında TCIA'dan malign gliomalı hastaların MR görüntüleri ile Destek Vektör Makinesi sınıflandırıcısının kullanılmasıyla tahmin edilmesi amaçlanmıştır. Çalışmada 214 hasta verisi kullanılmış ve test veri setleri çeşitli kurumlardan elde edilen 70 hastanın MR verileriyle eğitilmiştir. Çalışma sonucunda IDH genotipinin %90 doğruluğunun olduğu ve 1p/9q durumunun %80 doğruluğunun olduğu ortaya konulmuştur. Ayrıca çalışma sonucunda Destek Vektör Makinesinin hastalık sınıflandırmasında kullanılabilir olduğu vurgulanmıştır.

3.12.2. Diğer Çeşitli Hastalıklara Yönelik Yapılan Çalışmalar

Akkus vd. [169] çalışmasında LGG 1p/19q veri setiyle CNN kontrast sonrası T1 ve T2 ağırlıklı MR görüntülerinden 159 LGG'nin 1p/19q durumunun tahmin edilmesi amaçlanmıştır. Çalışma sonucunda modelin %93,3 hassaslığının, %82,2 özgüllüğünün ve %87,7 doğruluğunun olduğu ortaya konulmuştur.

Koçak vd. [170] çalışmasında LGG 107 hastanın farklı makine öğrenimi algoritmalarıyla 1p/19q kod çözme durumlarının incelenmesi amaçlanmıştır. Çalışmada Yapay Sinir Ağı, Destek Vektör Makinesi, Stokastik Gradyan, Naive Bayes ve Rastgele Orman Algoritmaları kullanılmıştır. Algoritmaların AUC değerlerinin %76,9-86,9 arasında olduğu, doğruluklarının %80,1-84 arasında olduğu ortaya konulmuştur. Ayrıca çalışmada Yapay Sinir Ağının %86,9 AUC ile %83,8 doğruluğunun olduğu ve en yüksek başarıyı elde eden algoritma olduğu vurgulanmıştır.

Voort vd. [171] çalışmasında tümörlerin 1p/19q durumlarının Destek Vektör Makinesi ile incelenmesi amaçlanmıştır. Çalışmada 26 aastroitom, 26 oligodendroglioma ve 11 karışık tip beyin tümörlü hasta verisi kullanılmıştır. Çalışma kullanılan veriler, 35 hasta birlikte silinmemiş ve 28 hasta birlikte silinmiş Grade 2 ya da Grade 3 tümöre sahiptir. Çalışma sonucunda toplam yüz çapraz doğrulama ardından Destek Vektör Makinesi algoritmasının T2 ağırlıklı görüntülerde %72 doğruluğunun olduğu ortaya konulmuştur.

Kohli ve Arora [172] çalışmasında meme kanseri veri setiyle farklı makine öğrenmesi yöntemlerinin incelenmesi amaçlanmıştır. Çalışma da 699 hasta verisi ile 9 öznitelik kullanılmıştır. Çalışma sonucunda Lojistik Regresyonun %95,71 doğruluğunun, Karar Ağacının %94,29 doğruluğunun, Rassal Orman Algoritmasının %97,14 doğruluğunun, Destek Vektör Makinesinin %97,14 doğruluğunun, AdaBoost'un %98,57 doğruluğunun olduğu ortaya konulmuştur. Ayrıca AdaBoost'un hastalık tespitlerinde en yüksek performansı gösterdiği vurgulanmıştır.

Tyagi vd. [173] çalışmasında tiroit hastalığının tahmin edilmesinde makine öğrenmesi yöntemlerinin performanslarının incelenmesi amaçlanmıştır. Çalışmada Karar Ağacı, Destek Vektör Makinesi, Yapay Sinir Ağları ve K-En Yakın Komşu gibi çeşitli teknikler kullanılmıştır. Çalışma sonucunda Destek Vektör Makinesinin %99,63 doğruluk oranında, K-En Yakın Komşu

algoritmasının %98,62 doğruluk oranında, Yapay Sinir Ağlarının %97,50 doğruluk oranında ve Karar Ağacının %75,76 doğruluk oranında performans gösterdiği ortaya konulmuştur. Ayrıca çalışmada tiroit hastalığının tahmin edilmesinde en iyi performans gösteren algoritmanın Destek Vektör Makinesi olduğu vurgulanmıştır.

Almansour vd. [174] çalışmasında kronik böbrek hastalığının tahmin edilmesinde makine öğrenmesi yöntemlerinin performanslarının incelenmesi amaçlanmıştır. Çalışma kapsamında 400 hasta verisi ve 24 öznitelik kullanılmıştır. Çalışma sonucunda Destek Vektör Makinesi algoritmasının %97,75 doğruluk oranının olduğu ve Yapay Sinir Ağları algoritmasının %99,75 doğruluk oranının olduğu ortaya konulmuştur. Ayrıca çalışma da en yüksek performansı yapay Sinir Ağları algoritmasının verdiği vurgulanmıştır.

Xiao vd. [175] çalışmasında makine öğrenmesi yöntemlerinin kullanılmasıyla kronik böbrek hastalığının tahmin edilmesi amaçlanmıştır. Çalışma kapsamında 551 hasta verisi ve 18 öznitelik kullanılmıştır. Çalışma sonucunda Lojistik Regresyon modelinin %82 doğruluk performansının olduğu ve %87 AUC değeriyle en iyi performansı gösterdiği ortaya konulmuştur.

Singh vd. [176] çalışmasında karaciğer hastalığının farklı makine öğrenmesi teknikleriyle tahmin edilmesi amaçlanmıştır. Çalışmanın ilk aşamasında Rassal Orman Algoritmasının %72,53 doğruluğunun, Lojistik Regresyonun %72,50 doğruluğunun, Sıralı Minimal Optimizasyonun kullanılmasıyla %71,35, J48'in kullanılmasıyla %68,78, K-En yakın komşu algoritmasıyla %64,15 ve Naive Bayes'in %55,74 performans gösterdiği ortaya konulmuştur. Çalışmanın ikinci aşamasında ise Lojistik Regresyonun %73,36, Rassal Orman Algoritmasının %71,88, Sıralı Minimal Optimizasyonun %71,36, J48'in %70,67, K-En Yakın Komşu'nun %67,41 ve Naive Bayes'in %55,90 doğruluk performansı gösterdiği ortaya konulmuştur. Ayrıca çalışma da Lojistik Regresyonun en iyi performansı gösterdiği de vurgulanmıştır.

Kukar vd. [177] çalışmasında kan testlerinin kullanılmasıyla Covid-19 hastalığının teşhis edilmesinin makine öğrenmesi yöntemleriyle gerçekleştirilmesi amaçlanmıştır. Çalışmada 5493 veri ve 35 öznitelik kullanılmıştır. Çalışmada model XGBoost tekniği ile çapraz doğrulama biçiminde oluşturulmuştur. Çalışma sonucunda modelin %81,90 duyarlılığının ve %97,90 özgüllüğünün olduğu ve çapraz doğrulama sonucunda ise AUC değerinin %97 olduğu ortaya konulmuştur. Ayrıca modelin kullanılabilir olduğu vurgulanmıştır.

Saha vd. [178] çalışmasında göğüs röntgen görüntülerinin kullanılmasıyla Covid-19 hastalığının teşhis edilmesinin CNN ve makine öğrenmesi yöntemleriyle yapılması amaçlanmıştır. Çalışma da Destek Vektör Makinesi, Karar Ağacı, Rassal Orman ve AdaBoost gibi farklı teknikler kullanılmıştır. Çalışma sonucunda CNN'in %96,52 doğruluğunun ve Destek Vektör Makinesi algoritmasının ise %96,96 doğruluğunun olduğu ortaya konulmuştur. Ayrıca çalışmada Covid-19 teşhisinde Destek Vektör Makinesi algoritmasının en yüksek performansı gösterdiği vurgulanmıştır.

Olatunji vd. [179] çalışmasında Tiroid kanserinin makine öğrenmesi yöntemleriyle erken teşhisinin yapılabilmesi amaçlanmıştır. Çalışmada Destek Vektör Makinesi, Rassal Orman, Yapay Sinir Ağları ve Naive Bayes algoritmaları kullanılmıştır. Çalışma sonucunda Rassal Orman algoritmasının %90,91 doğruluğunun olduğu, Destek Vektör Makinesinin %84,09 doğruluğunun olduğu, Naive Bayes'in %81,82 doğruluğunun olduğu ve Yapay Sinir Ağlarının %88,64 doğruluğunun olduğu ortaya konulmuştur.

Ryzhikova vd. [180] çalışmasında Alzheimer hastalığının tahmin edilmesinde makine öğrenmesi yöntemlerinin kullanılmasıyla incelenmesi amaçlanmıştır. Çalışmada beyin omurilik sıvısının yakın kızılötesi Raman spektroskopisinden elde edilen veriler kullanılmıştır. Ayrıca çalışmada 21 hasta ve 16 sağlıklı bireyin verisi gruplandırılmıştır ve yeni bir yöntem geliştirilmiştir. Çalışma sonucunda geliştirilen yöntemin %84 doğrulukla iyi performans gösterdiği ortaya konulmuştur. Buna ek olarak çalışmada geliştirilen modelin Alzheimer hastalığının teşhisinde kullanılabilir nitelikte olduğu da bildirilmiştir.

Hassan vd. [181] çalışmasında prostat kanseri tespitinde yapay zeka yöntemlerinin kullanılmasının incelenmesi amaçlanmıştır. Çalışmada ultrason ve MR görüntülerinden oluşan veriler kullanılmıştır. Çalışma sonucunda ultrason görüntülerinde %97 doğruluğun, MR görüntülerinde ise %80 doğruluğun olduğu ortaya konulmuştur. Ayrıca geliştirilen modelin prostat kanseri tespitinde kullanılabilir olduğu, modelin performansının artırılabilmesi için öznitelik çıkarımının yapılması gerektiği bildirilmiştir.

Palaniappan ve Awang [182] çalışmasında Akıllı Kalp Hastalığı tahmin sisteminin geliştirilmesi amaçlanmıştır. Çalışmada 909 hasta verisi ile 13 öznitelik kullanılmıştır. Çalışma sonucunda Yapay Sinir Ağları algoritmasının %85,68 doğruluk, Naive Bayes algoritmasının %88,12 doğruluk ve Karar Ağacı algoritmasının %80,40 doğruluk performansının olduğu ortaya konulmuştur. Ayrıca çalışma da Akıllı Kalp Hastalığının tahmin edilmesinde en yüksek performansı gösteren algoritmanın Naive Bayes algoritması olduğu ve hastalık tahmininde kullanılabilir olduğu vurgulanmıştır.

Ani vd. [183] çalışmasında Koroner Kalp hastalığının tahmin edilmesinde makine öğrenme tekniklerinin kullanılmasının incelenmesi amaçlanmıştır. Çalışmada K-En Yakın Komşu, Karar Ağacı, Naive Bayes ve Rassal Orman algoritmaları kullanılmıştır. Çalışma sonucunda K-En Yakın Komşu algoritmasının %77 doğruluğunun, Karar Ağacı algoritmasının %81 doğruluğunun, Naive Bayes algoritmasının %84 doğruluğunun ve Rassal Orman algoritmasının %89 doğruluğunun olduğu ortaya konulmuştur. Ayrıca çalışma da Koroner Kalp hastalığının tahmininde en yüksek performansı gösteren algoritmanın Rassal Orman algoritması olduğu bildirilmiştir.

Dwivedi [20] çalışmasında kalp hastalıklarının tahmin edilmesinde farklı makine öğrenimi algoritmalarının kullanılmasının incelenmesi amaçlanmıştır. Çalışmada 270 hasta verisi ile 13 öznitelik kullanılmıştır. Çalışma sonucunda K-En Yakın Komşu algoritmasının %80

doğruluğunun, Naive Bayes algoritmasının %83 doğruluğunun, Lojistik Regresyon algoritmasının %85 doğruluğunun, Yapay Sinir Ağları algoritmasının %84 doğruluğunun ve Destek Vektör Makinesinin %82 doğruluğunun olduğu ortaya konulmuştur. Ayrıca çalışma sonucunda kalp hastalıklarının tahmin edilmesinde en yüksek performans gösteren algoritmanın Lojistik Regresyon olduğu bildirilmiştir.

Özmen vd. [19] çalışmasında kalp hastalıklarının makine öğrenmesi yöntemleriyle tahmin edilmesi amaçlanmıştır. Çalışmada 303 hasta verisi ile 13 öznitelik kullanılmıştır. Çalışma sonucunda Rassal Orman Algoritmasının %82,50 duyarlılığının ve %84,21 doğruluğunun olduğu, Lojistik Regresyonun %87,50 duyarlılığının ve %85,53 doğruluğunun olduğu ortaya konulmuştur. Ayrıca çalışmada kalp hastalıklarının tahmin edilmesinde en yüksek performans gösteren algoritmanın Lojistik Regresyon olduğu da vurgulanmıştır.

Sonuç olarak makine öğrenmesi algoritmalarının kullanılarak hastalıkların tanılarının konulması, tespit edilmesi ve teşhis edilmesi açısından önemli bir fayda sağladığı söylenebilmektedir. Bir sonraki bölümde araştırmanın materyal ve yöntemlerinin tanıtılmasının ardından esas önemli olan bulguların sunumu yapılmıştır.

4. MATERYAL VE METOT

Evrişimli sinir ağları (Convolutional Neural Networks, CNNs), derin öğrenme alanında özellikle görüntü işleme ve sınıflandırma görevlerinde yaygın olarak kullanılan bir yapay sinir ağı türüdür. CNNs, görüntülerden otomatik olarak özellik çıkarma yeteneğine sahiptir ve bu özellikleri kullanarak sınıflandırma yapmaktadır [184].

Bu çalışmada evrişimli sinir ağları (Convolutional Neural Networks, CNNs) kullanılarak beyin tümörü tespiti bağlamında bir model eğitilmiş ve bu model açıklanabilir yapay zeka metotları olan GradCAM, Lime ve Shapley ile görselleştirilmiştir. Çalışmada kullanılan veri setindeki dört sınıftan (Glioma, Meningioma, Notumor ve Pituitary) üçer adet ve toplamda 12 adet imge seçilerek elde edilen sonuçların karşılaştırılabilmesi için görselleştirilmiştir. Modellemede kullanılan imgeler giriş boyutunda 224x224x3 olarak modelde kullanılmıştır. Modelde sırasıyla Input Layer'ı takip eden birden fazla Convolution Layer, Batch Normalization, Max Pooling, Average Pooling ve Dense layerlardan oluşan katmanlarla model mimarisi kurulmuştur. Modelde aktivasyon fonksiyonu olarak “ReLU”, Dense Layer için “Softmax” seçilmiş, Optimizer parametresi olarak “Adam” kullanılmış ve learning rate 0.0005 olarak belirlenmiştir. Loss function olarak “Categorical Cross Entropy”, metrikler ise “Categorical Accuracy” olarak atanmıştır. Model eğitiminde 15 epoch ile eğitim gerçekleştirilmiştir.

4.1. GradCAM

Görselleştirme için son Convolution katmanı kullanılmıştır. GradCAM görselleri için ısı haritaları elde edilmiş ve bu ısı haritaları orijinal imge üzerine bindirilerek süper piksel görseller oluşturulmuştur. Böylelikle doğrudan orijinal imge üzerindeki sonuçlar görülebilmektedir. Sonuçlarda her imge için sırasıyla orijinal imge, temel ısı haritası ve GradCAM süper piksel ısı haritası bir arada bulunmaktadır. Isı haritasındaki mavi renkli alanlar az öneme sahip, kırmızı renkli alanlar ise modelin karar verme süreci için daha çok öneme sahip alanları ifade etmektedir. Bununla birlikte GradCAM çalışma yapısı nedeniyle, sonuçların son convolution katmanı için elde edilmiş olması modelin her adımındaki karar verme sürecini temsil etmemektedir. Bulgularda verilen sonuçlarda görüleceği üzere bazı imgeler her yerde önemli ve önemsiz bölge ısı haritası değerlerine sahipken bazı imgelerde ise bu resmin bir kısmında geçerli olmuştur. Bu durum modelin sınıflandırma sürecinde resme göre değişiklik gösterdiğini ifade etmektedir. Farklı sınıftan imgelerde farklı bölgelere odaklanarak değerlendirme yapılmaktadır.

4.2. Lime

LIME görselleri için önce orijinal imge üzerinde sonuç alınmış daha sonra ısı haritaları elde edilmiş ve bu ısı haritaları orijinal imge üzerine bindirilerek süper piksel görseller oluşturulmuştur. Böylelikle doğrudan orijinal imge üzerindeki sonuçlar ısı haritası değerlerine göre görülebilmektedir. Sonuçlarda her imge için sırasıyla orijinal imge, LIME sonucu, temel ısı haritası ve LIME süper piksel ısı haritası bir arada bulunmaktadır. LIME sonucunu içeren ikinci sıradaki imgelerde (LIME Explanation) sarı kenar çizgileri içinde yapılan segmentasyon modelin karar verme sürecini en çok etkileyen üç alanı ifade etmektedir. Segmentasyon için quickshift algoritması kernel_size=9 parametresiyle kullanılmıştır. Bu üç alan yeşil veya kırmızı renkle ifade edilebilmektedir. Bu üç alandan birbirine bitişik olan aynı renkteki bölgeler birleştirilmiş şekildedir ve sonuçta bu sebeple üçten daha az alan görülebilmektedir. Bu bazı imgelerde tamamen yeşil yani olumlu etkileyen iki alanı birleşmiş şekilde, bazı imgelerde ise yeşil ve kırmızı olarak olumlu ve olumsuz etkileyen alanları ifade etmektedir. Bunların yanındaki LIME Isı Haritası (Heatmap) farklı renklerden oluştuğu için bu üç alan renk aralığı birbirine yakın dahi olsa seçilebilmektedir.

4.3. Shapley

Shapley metodu uygulanırken veri setinde sahip olduğumuz dört sınıfın tamamı için sonuçlar elde edilmiştir. En başta orijinal imge yanında ise dört sınıf için Shapley sonuçlarını içeren imgeler bulunmaktadır. Isı haritasındaki mavi renkli alanlar az öneme sahip, kırmızı renkli alanlar ise modelin karar verme süreci için daha çok öneme sahip alanları ifade etmektedir. Bazı imgelerde sınıflar için Shapley sonuçları bu şekilde ısı haritaları olarak ifade edilebilmişken, bazı imgelerde ise herhangi bir Shapley sonucu alınamadığından ısı haritası oluşmamıştır. Bu durum Shapley metodunun elimizdeki veri seti için yeterince uyumlu olmadığını veya Shapley sonuçlarının çok küçük olduğunu göstermektedir. Yani Shapley metodu modeli iyi bir şekilde açıklayamamıştır.

4.4. Veri Seti ve Eğitim Süreci

Çalışmada kullanılan veri seti açık kaynak olarak tutulan Kaggle platformundan alınmıştır. Glioma (Eğitim Seti:1321 Test Seti:300), Meningioma (Eğitim Seti:1339 Test Seti:306), Notumor (Eğitim Seti:1594 Test Seti:405) ve Pituitary (Eğitim Seti:1457 Test Seti:300) sınıflarına görseller bulunan veri seti çalışma kapsamında eğitim ve test olmak üzere iki parçaya ayrılmıştır. Eğitim setinde toplam 5712, Test setinde 1311 imge bulunmaktadır. Eğitim setinin %10'u (571 imge) model eğitiminde kullanılmak üzere doğrulama seti olarak ayrılmış ve kalan 5141 adet imge eğitim setinde kullanılmıştır. İmgelere modele girmeden önce ön işlem uygulanmıştır. Görselleştirmelerde tutarlılık sağlanması göz önünde bulundurularak her sınıftan (NoTumor, Glioma, Meningioma,

Pituitary) üçer tane olacak şekilde test setinden imgeler seçilmiştir. Bu imgeler her görselleştirme modelinde karşılaştırılabilmesi için sabit olarak tutulmuştur.




5. BULGULAR VE TARTIŞMA

Çalışmanın bu bölümünde araştırma tasarımına uygun olarak derin öğrenme modellerinden Evrişimli sinir ağıları (Convolutional Neural Networks, CNN) kullanılarak eğitimi yapılan beyin tümörü tespiti ve üç farklı (GradCAM, LIME ve Shapley) yöntem ile görselleştirilmesine ait bulgular yer almaktadır.


5.1. CNN Modeli Eğitim Bulguları

Şekil 5.1’de eğitimi yapılan CNN modelinin blok diyagramı görülebilmektedir.




Şekil 5. 1. Eğitimi yapılan CNN modelinin blok diyagramı

Şekil 5.1’den de görüldüğü gibi diyagramda veri seti CNN modeline girer ve modelin her katmanından sıra ile geçer. Katmanlarda işlem uygulanan imgeler dört sınıftan ağırlığı en fazla sınıf olarak tahmin çıktısı alınır. Ayrıca modellemeden sonra açıklanabilir yapay zeka tekniklerinden olan GradCAM, Lime ve Shapley ile görselleştirmeler modellenmiştir. Bu tekniklerden GradCAM doğrudan “Son Convolution Katmanı”ndaki ağırlıklara göre görselleştirmeler sağlarken, Lime ve Shapley tekniklerinde modelin tamamından yararlanılarak görselleştirmeler ortaya konulmuştur. Eğitim 15 epoch ile gerçekleşmiştir. Yani tüm eğitim seti 15 kez model eğitimine katkı sağlamıştır. Şekil 5.2’de eğitimi gerçekleştirilen CNN modeline ait Epoch-Doğruluk grafiği görülebilmektedir. Şekil 5.2’deki yatay eksen epoch sayısını, dikey eksen ise doğruluk (accuracy) değerlerini göstermektedir.




Şekil 5. 2. Epoch doğruluk grafiği

Şekil 5.2'den de görüldüğü gibi epoch ilerledikçe genel olarak modelin doğruluk eğrilerinin de artış gösterdiği tespit edilmiştir. İlk epoch Eğitim seti doğruluğu %75,00 ile başlamış ve on dördüncü epochta %99,09'a ulaşmıştır. Doğrulama setinde ise ilk epoch doğruluğu %38,00 ile başlamış ve on dördüncü epochta %96,85'e ulaşmıştır. Şekil 5.3'de modelin final metrikleri verilmiştir. Bu metrikler alınırken eğitimde kullanılmayıp ayrı tutulan Test setindeki imgeler kullanılmış ve modelden tahminler alınarak gerçek değerlerle karşılaştırılmıştır.



Şekil 5. 3. Model metrikleri

Şekil 5.3'den de görüldüğü gibi modelin doğruluğunun %94,43 olduğu, kesinliğinin %94,30 olduğu, duyarlılığının %94,0 olduğu ve F1 skorunun %94,13 olduğu tespit edilmiştir. Şekil 5.4'de CNN modelinin eğitimi sonucunda elde edilen karmaşıklık matrisi verilmiştir. Bu sonuçlar test seti kullanılarak elde edilmiştir. İmgelere ait gerçek sınıfları sol dikey eksen, modelin tahmin ettiği sınıfları ise alt yatay eksen temsil etmektedir.




Şekil 5. 4. Karmaşıklık matrisi

Şekil 5.4'den de görüldüğü gibi Glioma sınıfına ait imgelerden 271 adet doğru şekilde tespit edilirken, bu sınıftan 27 adet görsel “Meningioma”, 2 adet görsel ise “No tumor” sınıfı olarak,

Meningioma sınıfına ait imgelerden 274 adet doğru şekilde tespit ederken, bu sınıftan 14 adet görsel “Glioma”, 11 adet görsel “No tumor”, 7 adet görsel ise “Pituitary” sınıfı olarak, No Tumor sınıfına ait imgelerden 403 adet doğru şekilde tespit edilirken, bu sınıftan 2 görsel “Meningioma” sınıfı olarak, Pituitary sınıfına ait imgelerden 290 adet doğru şekilde tespit edilirken, bu sınıftan 1 görsel “Glioma”, 7 görsel “Meningioma”, 2 görsel “No tumor” sınıfı olarak tahmin edildiği tespit edilmiştir.

5.2. GradCAM Yöntemi ile Görselleştirme


Çalışmada CNN eğitiminden sonra elde edilen sonuçlar bağlamında, modelden elde edilen tahminler öncelikle GradCAM yöntemi kullanılarak görselleştirilmiştir. GradCAM sonuçları Şekil 5.5’te gösterilmiştir.



Şekil 5. 5. GradCAM yöntemi görselleştirmesi (No Tumor)


Şekil 5.5’ten de görüldüğü gibi İlk görselde No Tumor sınıfına ait bulgular verilmiştir. Bu modelin geniş bir alanında mavi renkte aktivasyon gösterdiği ve daha kısa fakat yoğun kırmızılı bir alanda

yoğun aktivasyon gösterdiği görülmektedir. Geniş mavi alanlar modelin tümör bulunmayan beyin dokusunu geniş bir alanda değerlendirdiğini, dar kırmızı alanlar ise bu bölgede tümör olasılığı ile ilgili yüksek önem taşıyan aktivasyonları ifade etmektedir. Bununla birlikte bu sonuç modelin No Tumor sınıfı için büyük oranda doğru değerlendirme yaptığını göstermektedir. İkinci No Tumor sınıfına ait görselde, yine mavi rengin geniş bir alanda etkin olduğu ve daha küçük bir beyin bölgesinde ise kırmızı rengin ağırlıkta olduğu görülmektedir. Kırmızı aktivasyonun dar bir bölgede yoğunlaşması, modelin potansiyel anormal bölgeleri doğru bir şekilde tespit etme çabasında olduğunu ancak bu bölgenin küçüklüğü göz önüne alındığında, yanlış pozitif tespitlere de yol açabileceğini düşündürmektedir. Üçüncü No Tumor sınıfına ait görselde geniş bir alana yayılmış birkaç mavi aktivasyon bölgesi ve daha küçük birkaç alanda kırmızı aktivasyon bölgesi gözlemlenmektedir. Bu, modelde aktivasyon sırasında farklı tümör tipleri için görselin farklı alanlarının değişken aktivasyonlar ürettiğini göstermektedir. Bu durum, modelin beyin boyunca geniş bir alanı taradığını, No Tumor sınıfını ayırt ettiğini ve potansiyel anomalilerin farkında olduğunu göstermektedir. Şekil 5.6'da Glioma tümör sınıfından 3 görsel görülebilmektedir.




Şekil 5. 6. GradCAM yöntemi görselleştirmesi (Glioma tümör)

Şekil 5.6'dan da görüldüğü gibi ilk Glioma sınıfına ait görselde, modelin aktivasyonları beynin alt ve orta kısımlarında mavi renkte yoğunlaşırken, beynin dışında daha yüksek bir kırmızı aktivasyon gözlemlenmiştir. Bu, modelin beynin dışında tümör olması muhtemel olmayan bir alana odaklanmakta ve dolayısıyla yanlış çalıştığını gösteren yanlış pozitif bir aktivasyon vermektedir. Hatalı aktivasyon, modelin bu imgede yanlış tahminde bulunabileceğini göstermektedir. İkinci Glioma sınıfına ait görselde, modelin beynin üst kısımlarında mavi ve kırmızı renklerde aktive olduğu, ancak beynin dışında bir bölgede de kırmızı aktivasyonun yoğun olduğu bir alan bulunduğu görülmektedir. Bu modelin tümörün olmaması gereken alanlara odaklandığını gösteriyor ve bu görüntü için yanlış sınıflandırmaya olan eğilimini açıklıyor. Hatalı aktivasyon, modelin bu imgede yanlış tahminde bulunabileceğini göstermektedir. Üçüncü Glioma sınıfına ait görselde, modelin beynin sol kısmında ve bunun dışındaki bazı alanlarda büyük miktarlarda kırmızı renkte aktivasyon gösterdiği görülmektedir. Modelin tümörün de bulunabileceği geniş bir beyin alanını yeterince değerlendirdiği gözlemlenebilir; ancak çevredeki alanlara doğru düşük seviyeli aktivasyonlar olduğu dikkat çekmektedir. Bu, modelin geniş alanları glioma sınıfı için değerlendirirken bazı dış bölgelerde gereksiz aktivasyonlar gösterdiğini ifade eder. Şekil 5.7'de 3 farklı Meningioma sınıfına ait sonuç çıktısı görülebilmektedir.



Şekil 5. 7. GradCAM yöntemi görselleştirmesi (Meningioma tümör)

Şekil 5.7’den de görüldüğü gibi ilk Meningioma sınıfına ait görselde, beyin zar bölgesine yakın bir alanda modelin aktivasyonlarının yoğunlaştığı görülmektedir. Modelin tümör tespiti için doğru bir alan belirleyebildiğine dair bu kırmızı aktivasyonlar, söz konusu görselde etkili bir sınıflandırma tahmini yapabileceğini göstermektedir. İkinci Meningioma sınıfına ait görselde, model beyinin çevresinde, zar bölgesinde kırmızı renkte yoğun aktivasyon göstermiştir. Bu durum modelin tümör tespitinde doğru alanları değerlendirdiğini göstermektedir. Üçüncü Meningioma sınıfına ait görselde, modelin beyin etrafında ve hatta dışında aktive olduğu bazı alanları kırmızı renkte göstermektedir. Burada modelin tümörün bulunabileceği ve tümör olmaması gereken dış alanlara da odaklandığını görülmektedir. Bu hatalı aktivasyonların bulunması, modelin bu imgede yanlış tahminde bulunabileceğini göstermektedir. Şekil 5.8’de 3 farklı Pituitary tümör sınıfına ait sonuç çıktısı görülebilmektedir.




Şekil 5. 8. GradCAM yöntemi görselleştirmesi (Pituitary tümör)

Şekil 5.8’den de görüldüğü gibi ilk Pituitary sınıfına ait görselde, modelin beynin orta ve alt bölümlerinde kırmızı, ayrıca burun bölgesinde mavi renkte aktivasyon gösterdiği gözlemlenmiştir. Modelin beynin iç bölgesinde doğru aktivasyonlar göstermesi, tümör tespiti için uygun alanlara odaklandığını ortaya koymaktadır. Ayrıca, burun bölgesinde mavi aktivasyon göstermesi, modelin bu görselde gereksiz bölgelere önem vermediğini göstermektedir. İkinci Pituitary sınıfına ait görselde, modelin sol ve sağ beyin bölgelerinde kırmızı, göz çevresinde ise mavi renkte aktivasyonlar gözlemlenmiştir. Modelin beynin iç bölgelerinde doğru aktivasyonlar göstermesi, tümör tespiti için uygun alanları değerlendirdiğini gösterirken, göz çevresinde düşük öneme sahip mavi aktivasyonların olması, modelin tümör bulunmaması gereken bölgelerde daha az odaklandığını, yani dikkatli bir sınıflandırma yapabileceğine işaret etmektedir. Üçüncü Pituitary sınıfına görselde, modelin beynin orta ve sol bölümlerinde kırmızı, sağ tarafında ise mavi renkte aktivasyon gösterdiği tespit edilmiştir. Bu aktivasyonlar, modelin tümör bulunabilecek beyin bölgelerinde doğru alanlara odaklandığını ve bu görselde tutarlı bir sınıflandırma gerçekleştirebileceğini ortaya koymaktadır.


5.3. LIME Yöntemi ile Görselleştirme

Şekil 5.9’de Lime yöntemi No Tumor sınıfına ait 3 farklı bulgu görülebilmektedir.



Şekil 5. 9. LIME yöntemi görselleştirmesi (No Tumor)


Şekil 5.9’den da görüldüğü gibi ilk No Tumor sınıfına ait görselde, modelin aktivasyonlarının beyinin sağ bölümünde, sol alt kenarda ve beyin dışında sol bölümde yeşil renkte yoğunlaştığı gözlemlenmiştir. Modelin geniş bir alanda aktivasyon göstermesi, tümör bulunmayan bölgelerde de değerlendirme yaptığını ortaya koymaktadır. Bu durum, modelin gereksiz bölgelere odaklanarak yanlış pozitif tahmin yapabileceğini göstermektedir. İkinci No Tumor sınıfına ait görselde, modelin beyinin orta bölümünde ve sağ kenarda yeşil, beyin üst bölümünde ise kırmızı renkte aktivasyon gösterdiği tespit edilmiştir. Bu aktivasyonların, modelin tümör bulunabilecek alanlarda odaklandığını göstermesi, sınıflandırmanın doğru tahmin edilebileceğini göstermektedir. Üçüncü No Tumor sınıfına ait görselde, modelin beyinin sağ bölümünde, sağ ve sol kenarlarda yeşil renkte aktivasyonlar gösterdiği görülmüştür. Bu aktivasyonların, modelin potansiyel tümör alanlarına odaklandığını göstermektedir. Bu durum farklı tümör tipleri için modelin görselde farklı alanları değerlendirdiğini göstermektedir. Şekil 5.10’da Glioma sınıfa ait LIME görselleştirmeleri görülebilmektedir.



Şekil 5. 10. LIME yöntemi görselleştirmesi (Glioma Tümör)


Şekil 5.10'dan da görüldüğü gibi ilk Glioma sınıfına ait bir görselde, modelin beyin sol kenar bölümünde yeşil, beyin büyük bölümünde ise kırmızı renkte aktivasyonlar gösterdiği tespit edilmiştir. Bu durum, modelin tümör bulunabilecek alanlarda düşük öncelikli aktivasyonlar oluşturduğunu ve bu görselde hatalı bir şekilde odaklandığını göstermektedir. Kırmızı aktivasyonun geniş bir alana yayılması, modelin bazı bölgelerde gereksiz yüksek önem verdiğini ve bu nedenle doğruluk oranının olumsuz etkilenebileceğini ortaya koymaktadır. İkinci Glioma sınıfına ait görselde, modelin beyin sağ bölümünde ve sağ alt kısmında yeşil, ayrıca sağ alt bölümde kırmızı renkte aktivasyon gösterdiği gözlemlenmiştir. Model, tümör bulunabilecek alanlara odaklanırken, alt bölgedeki düşük önem seviyesine sahip aktivasyonlar ile tümör bulunma ihtimali az olan bölgelerde de odaklanma göstermektedir. Bu durum, modelin genel olarak doğru bir sınıflandırma yapabileceğini göstermektedir. Üçüncü Glioma sınıfına ait görselde, modelin beyin sağ bölümünde ve sağ kenarda yeşil, sol alt bölümünde ise kırmızı renkte aktivasyonlar gösterdiği gözlemlenmiştir. Modelin, tümör bulunabilecek alanlara odaklanma eğiliminde olduğu anlaşılmaktadır. Bu durum modelin bu görselde tümör tespiti için belli bir alana odaklandığını

göstermektedir. Şekil 5.11’de Meningioma sınıfına yönelik yapılan LIME görselleştirme sonuçları verilmiştir.



Şekil 5. 11. LIME yöntemi görselleştirmesi (Meningioma Tümör)

Şekil 5.11’den de görüldüğü gibi ilk Meningioma sınıfına ait görselde, modelin beyinin sol alt ve sol üst bölümlerinde yeşil, sağ üst bölümünde ise kırmızı renkte aktivasyon gösterdiği tespit edilmiştir. Modelin, tümör bulunabilecek sol bölgelere yoğunlaşması doğru bir odaklanmayı gösterirken, sağ üst bölümdeki düşük öncelikli kırmızı aktivasyonlar, modelin bu bölgede de dikkat verdiğini ancak daha az öneme sahip olduğunu ortaya koymaktadır. Bu durum modelin bu görselde tümör tespiti için doğru alana odaklandığını göstermektedir. İkinci Meningioma sınıfına ait görselde, modelin beyinin üst sağ ve orta alt bölümlerinde yeşil renkte aktivasyonlar gösterdiği gözlemlenmiştir. Bu durum, modelin tümör bulunabilecek doğru alanlara odaklandığını ve bu görselde tutarlı bir sınıflandırma gerçekleştirdiğini göstermektedir. Üçüncü Meningioma sınıfına ait görselde, modelin beyinin sağ orta ve sağ alt bölümlerinde yeşil, sağ bölümünde ise kırmızı renkte aktivasyon gösterdiği tespit edilmiştir. Modelin sağ bölgedeki düşük öncelikli kırmızı aktivasyonlara rağmen, tümör bulunma olasılığı yüksek alanlara odaklanmış olması, sınıflandırma tahmininin doğru olabileceğini göstermektedir. Şekil 5.12’de Pituitary sınıfına yönelik yapılan LIME görselleştirme sonuçları verilmiştir.




Şekil 5. 12. LIME yöntemi görselleştirmesi (Pituitary Tümör)

Şekil 5.12’den de görüldüğü gibi ilk Pituitary sınıfına ait görselde, modelin beyin üst, orta ve sol alt bölümlerinde yeşil renkte aktivasyon gösterdiği tespit edilmiştir. Modelin, tümör bulunma olasılığı yüksek geniş alanlarda aktivasyonlar göstermesi, bu görselde doğru alanları değerlendirdiğini ortaya koymaktadır. İkinci Pituitary sınıfına ait görselde, modelin beyin sol ve sağ kenar bölümlerinde yeşil, sağ alt bölümünde ise kırmızı renkte aktivasyonlar gözlemlenmiştir. Bu aktivasyonların dağılımı, modelin tümör bulunabilecek alanlara odaklandığını ve sağ alt bölgedeki düşük öncelikli aktivasyonların, bu alanlarda daha az önem verildiğini göstermektedir. Bu, modelin doğru bir sınıflandırma için belirli alanlara odaklandığına işaret eder. Üçüncü Pituitary sınıfına ait görselde, modelin beyin sol ve sağ kenarları ile beyin dışındaki sol alt bölgede yeşil renkte aktivasyon gösterdiği tespit edilmiştir. Bu durumda, modelin hem beyin içindeki doğru bölgelerde hem de tümör bulunmaması gereken dış alanlarda aktivasyon göstermiştir. Bu durum %100 doğruluk elde edilmeyen modelin bu görsel için hatalı aktivasyona sahip olabileceğini göstermektedir.

5.4. SHAPLEY Yöntemi ile Görselleştirme

Şekil 5.13’de SHAPLEY yöntemine ait her bir imge için orijinal ve her dört sınıf tahmininde aktivasyon görülen sonuçlar görülebilmektedir.



Şekil 5. 13. SHAPLEY yöntemine ait bulgular

Şekil 5.13'den de görüldüğü gibi No Tumor Sınıfına ait görselde modelin beyin genelinde geniş bir aktivasyon alanı oluşturduğu gözlemlenmiştir. Beynin farklı bölgelerinde görülen bu aktivasyonlar, modelin tümör tespiti için beyin geniş alanlarını değerlendirdiğini ve çoğunlukla doğru alanlara odaklandığını göstermektedir. Ancak, bazı durumlarda aktivasyonların beyin dışına kayması, modelin sınıflandırma kararlarını etkileyebilecek potansiyel hatalara yol açabileceğini göstermektedir. Bu durum, modelin No Tumor sınıfı için genellikle güvenilir bir sınıflandırma yaparken, nadiren de olsa yanlış pozitiflere yol açabileceğini göstermektedir. Glioma Sınıfına ait görsellerde yalnızca bir görselde belirgin bir aktivasyon gözlemlenmiştir. Bu görselde model, tümör bulunabilecek bir bölgeye odaklanarak doğru bir alanda değerlendirme yapmıştır. Ancak, diğer iki görselde herhangi bir aktivasyonun bulunmaması, modelin bu sınıf için her zaman tutarlı bir performans sergileyemediğini göstermektedir. Meningioma Sınıfına ait görsellerin bazılarında, modelin beyin kenar kısımlarında ve genelinde aktivasyonlar gösterdiğini ortaya koymuştur. Modelin doğru alanlara odaklanarak etkili bir sınıflandırma yaptığı anlaşılmakla birlikte, bazen beyin dışına da kayması, yanlış pozitif sonuçlara neden olabilmektedir. Pituitary Sınıfına ait görsellerin bazılarında ise herhangi bir belirgin aktivasyon gözlemlenmemiştir. Bu durum bu sınıftaki imgeleri Shapley tekniğiyle açıklayamadığını göstermektedir.

Hussain ve Shouno [185] çalışmasında çoklu sınıflar için açıklanabilir derin öğrenme yaklaşımıyla beyin MR görüntüleme tümör sınıflandırması ve Gradyan Ağırlıklı sınıfın kullanılmasıyla yerleştirilme etkinleştirme eşlemesinin yapılması amaçlanmıştır. Çalışma da CAM, GradCAM ve GradCAM++ kullanılmıştır. Çalışma sonucunda GradCAM yönteminin pre-trained VGG-19 modelinin scratch-VGG-19 ile EfficientNet modelleriyle diğer tekniklere kıyasla daha yüksek performans gösterdiği ortaya konulmuştur. Nancy ve Sathyarajasekaran [186] çalışmasında beyin tümörü segmentasyonu gibi karmaşık görevlerin açıklanabilir yapay zeka modellerinin yorumlanabilirliğinin ve etkinliğinin incelenmesi amaçlanmıştır. Çalışmada MACE, Gradient Shap, LIME, GradCAM ve Guided GradCAM yöntemleri kullanılmıştır. Çalışma sonucunda beyin tümörü görüntülerinin etkili ve yorumlanabilirlik açısından en iyi performans gösteren modelin GradCAM olduğu ortaya konulmuştur. Öztürk ve Katar [187] çalışmasında GradCAM yöntemiyle MR görüntülerinden beyin tümörlerinin sınıflandırılması amaçlanmıştır. Çalışmada 3.000 beyin MR görüntüsü kullanılmıştır. Çalışma sonucunda %99,33 doğruluk ile GradCAM yönteminin yüksek performans gösterdiği ortaya konulmuştur. Amin vd. [188] çalışmasında beyin tümörü teşhisinde GradCAM, LIME ve Shapley yöntemlerinin kullanılabilirlik performanslarının incelenmesini amaçlamıştır. Çalışma sonucunda her üç yönteminde doğrulama doğruluğunun %98 olduğu ve beyin tümörlerinde kullanılabilir olduğu ortaya konulmuştur. Gaur vd. [189] çalışmasında MR görüntü veri setlerinin kullanılarak Menenjiyom, Gliom ve Hipofiz tümörleri gibi beyin tümörlerinin ayrık alt türlerinin tahmin edilmesinin derin öğrenme modelleriyle uygulanabilirliğinin incelenmesi amaçlanmıştır. Çalışma da Shapley, LIME ve GradCAM

yöntemleri kullanılmıştır. Çalışma sonucunda CNN modelinin %94,64 doğruluğunun olduğu ve yöntemlerin kullanılabilir olduğu ortaya konulmuştur. Bu kapsamda literatürdeki çalışmalarla yapılan çalışmanın doğruluklarının paralel sonuçlar verdiği ancak kullanılacak model önerilerinin farklılık gösterdiği bildirilebilmektedir. Bu farklılığın literatürdeki çalışmalardan farklı bir sonuç vermesinin en temel sebepleri; yapılan çalışmada karmaşık modelin kullanılmasından ve model mimarisinin özellik haritasının anlamlandırılmasının zor olmasından kaynaklı olabileceği düşünülmektedir.



6. SONUÇLAR

Yapılan çalışma, beyin tümörlerinin tespitinde kullanılan CNN modellerinin performansını üç farklı açıklanabilir yapay zeka tekniği olan GradCAM, LIME ve Shapley yöntemleri ile analiz etmeyi hedeflemiştir. Her bir teknik, modelin hangi alanlara odaklandığını ve sınıflandırma kararlarını nasıl verdiğini açıklamak için kullanılmıştır. Bu tekniklerin her biri, modelin karar mekanizmalarının daha iyi anlaşılmasına yardımcı olmakta ve modelin güvenilirliğini artırmak için önemli bilgiler sağlamaktadır. Bu çalışmada evrimsel sinir ağları (Convolutional Neural Networks, CNNs) kullanılarak beyin tümörü tespiti bağlamında bir model eğitilmiş ve bu model açıklanabilir yapay zeka metotları olan GradCAM, Lime ve Shapley ile görselleştirilmiştir. Çalışmada kullanılan veri setindeki dört sınıftan (Glioma, Meningioma, Notumor ve Pituitary) üçer adet ve toplamda 12 adet imge seçilerek elde edilen sonuçların karşılaştırılabilmesi için görselleştirilmiştir. Model eğitiminde 15 epoch ile eğitim gerçekleştirilmiştir. Modelin doğruluğunun %94,43 olduğu, kesinliğinin %94,30 olduğu, duyarlılığının %94,0 olduğu ve F1 skorunun %94,13 olduğu tespit edilmiştir. Karmaşıklık matrisinde; Glioma sınıfına ait imgelerden 271 adet doğru şekilde tespit edilirken, bu sınıftan 27 adet görsel “Meningioma”, 2 adet görsel ise “No tumor” sınıfı olarak, Meningioma sınıfına ait imgelerden 274 adet doğru şekilde tespit ederken, bu sınıftan 14 adet görsel “Glioma”, 11 adet görsel “No tumor”, 7 adet görsel ise “Pituitary” sınıfı olarak, No Tumor sınıfına ait imgelerden 403 adet doğru şekilde tespit edilirken, bu sınıftan 2 görsel “Meningioma” sınıfı olarak, Pituitary sınıfına ait imgelerden 290 adet doğru şekilde tespit edilirken, bu sınıftan 1 görsel “Glioma”, 7 görsel “Meningioma”, 2 görsel “No tumor” sınıfı olarak tahmin edildiği tespit edilmiştir.

Çalışma sonucunda her üç teknik de modeli açıklamaya çalışırken model metrikleri ve sınıflandırma tahminleri ne olursa olsun, seçilen imgeler üzerinde tam performans gösteremediği tespit edilmiştir. GradCAM yöntemi, modelin son katmanlarındaki aktivasyonları görselleştirerek, tümör bulunma olasılığı yüksek alanların belirlenmesinde önemli bir araç olarak öne çıkmıştır. Bu teknik, modelin doğru alanlara odaklandığını açık bir şekilde göstermiş ancak zaman zaman modelin tümör bulunmayan bölgelere de odaklanabildiğini ortaya koymuştur. LIME yöntemi ise, modelin her bir sınıflandırma kararını daha detaylı bir şekilde açıklayarak, modelin hangi alanlara daha fazla önem verdiğinin anlaşılmasına olanak tanımıştır. LIME analizleri, modelin genellikle doğru alanlara odaklandığını ancak bazı durumlarda yine gereksiz aktivasyonlar üretebildiğini göstermiştir. Shapley yöntemi, her bir sınıf tahmini için modelin aktivasyon dağılımını inceleyerek, modelin genel performansının değerlendirilmesine yardımcı olmuştur. Shapley analizi, modelin bazı sınıflarda (No Tumor ve Meningioma) genellikle doğru alanlara odaklandığını ancak Glioma ve Pituitary sınıflarında performansın tutarlı olmadığını göstermiştir. Sonuç olarak, her üç teknik de modelin karar mekanizmalarını farklı açılardan inceleyerek, modelin güçlü ve zayıf yönlerini

belirlemede önemli bir rol oynamıştır. GradCAM, modelin genel odaklanma alanlarını belirlemede etkili olmuş; LIME, modelin kararlarının detaylı bir açıklamasını sunmuş; Shapley ise modelin genel performansını ve eksikliklerini ortaya koymuştur. Bu tekniklerin birlikte kullanılması, modelin daha güvenilir ve etkili bir şekilde çalışmasını sağlamak için daha fazla veri sağlanmasına veya gerekli iyileştirmelerin yapılmasına olanak tanımaktadır.



ÖNERİLER

Gelecekte yapılacak çalışmalara;

1. Daha geniş ve dengeli veri setlerini kullanarak modellerin genelleştirilebilirliğini artırmaları,
2. Çeşitli tümör türleri ile alt türlerinin tespitine yönelik özelleştirilmiş modeller geliştirmeleri,
3. Transfer öğrenme ya da pre-trained modellerinin farklı MR modalitelerine adaptasyonlarını incelemeleri,
4. MR görüntülerinin yanı sıra diğer tıbbi görüntüleme yöntemleri (PET, CT gibi) ve klinik verileri kullanarak çok modaliteli modeller geliştirmeleri,
5. Yöntemlerin spesifik tümör türleri için hangi durumlarda daha etkili olduğunun incelenmesi önerilmektedir.

KAYNAKLAR

- [1] R. Ullah, S. Khan, I. Ishtiaq, S. Shahzad, H. Ali, M. Bilal, Cost effective and efficient screening of alzheimer disease with raman spectroscopy and machine learning algorithms, *Photodiagn Photodyn Ther.* 32 (2020) 1-6. doi:10.1016/j.pdpdt.2020.101963.
- [2] A. Zebene, E. Arsand, S. Walderhaug, D. Albers, L. Mamykina, T. Botsis, G. Hartvigsen, Data-driven modeling and prediction of blood glucose dynamics: Machine learning applications in type 1 diabetes, *Artif Intell Med.* 98 (2019) 109-134. doi:10.1016/j.artmed.2019.07.007.
- [3] M. Musleh, E. Alajrami, A. Khalil, B. Nasser, A. Barhoom, S. Naser, Predicting liver patients using artificial neural network, *J Acad Inf Syst Res.* 3 (2019) 1–11.
- [4] N. Dabowsa, N. Amaitik, A. Maatuk, A. Shadi, A hybrid intelligent system for skin disease diagnosis, *Engineering and Technology* (2017) 1–6. doi:10.1109/ICEngTechnol.2017.8308157.
- [5] C. Tian, M. Yu, L. Shan, Y. Wu, T. Zhang, B. Bi, B. Zhang, Radiography of direct drive double shell targets with hard x-rays generated by a short pulse laser, *Nuclear Fusion* 59 (2019) 1-23. doi:10.1088/1741-4326/aafe30.
- [6] A. Hosny, C. Parmar, J. Quackenbush, L.H. Schwartz, H.J. Aerts, artificial intelligence in radiology, *Nature Reviews Cancer* 18 (2018) 500-510. doi:10.1038/s41568-018-0016-5.
- [7] R. Fitzgerald, Error in radiology, *Clinical Radiology* 56 (2001) 938-946. doi:10.1053/crad.2001.0858.
- [8] E.P. Ambinder, A history of the shift toward full computerization of medicine, *Journal of Oncology Practice* 1 (2005) 50-54. doi:10.1200/jop.2005.1.2.54.
- [9] S. Wang, Y. Zhang, T. Zhan, P. Phillips, Y.D. Zhang, G. Liu, X. Wu, Pathological brain detection by artificial intelligence in magnetic resonance imaging scanning, *Progress in Electromagnetics Research* 156 (2016) 105-133. doi:10.2528/PIER16070801.
- [10] R.J. Gillies, P.E. Kinahan, H. Hricak, Radiomics: Images are more than pictures, they are data, *Radiology* 278 (2016) 563–577. doi:10.1148/radiol.2015151169.
- [11] F. Pacchiano, M. Tortora, C. Doneda, G. Izzo, F. Arrigoni, L. Ugga, A. Brunetti, Radiomics and artificial intelligence applications in pediatric brain tumors, *World Journal of Pediatrics* (2024) 1-17.
- [12] Q. Tian, L.F. Yan, X. Zhang, Y.C. Hu, Y. Han, G.B. Cui, Radiomics strategy for glioma grading using texture features from multiparametric MRI, *Journal of Magnetic Resonance Imaging* 48 (2018) 1518-1528. doi:10.1002/jmri.26010.
- [13] A. Chaddad, M.J. Kucharczyk, P. Daniel, S. Sabri, B.J. Jean-Claude, T. Niazi, B. Abdulkarim, Radiomics in glioblastoma: Current status and challenges facing clinical implementation, *Frontiers In Oncology* 9 (2019) 280-374. doi:10.3389/fonc.2019.00374.
- [14] R.M. Pulgam, Digital image processing techniques–A survey, *SCRIBD* 5 (2022) 78-84.
- [15] D. Ravi, C. Wong, F. Deligianni, M. Berthelot, J. Andreu-Perez, B. Lo, G.Z. Yang, Deep learning for health informatics, *J. Biomed. Heal. Informatics* 21 (2017) 4-21.
- [16] M. Bhandari, P. Yogarajah, M.S. Kavitha, J. Condell, Exploring the capabilities of a lightweight cnn model in accurately identifying renal abnormalities: cysts, stones, and tumors, using lime and shap, *Applied Sciences* 13 (2023) 1-17. doi:10.3390/app13053125.

- [17] J. Narkhede, Comparative evaluation of post-hoc explainability methods in AI: LIME, SHAP, and Grad-CAM, 2024. <https://ieeexplore.ieee.org/abstract/document/10762963>, (05 Şubat 2025’de erişildi).
- [18] Y. Chen, Q. Ren, J. Yan, Rethinking and improving robustness of convolutional neural networks: A shapley value-based approach in frequency domain, *Advances In Neural Information Processing Systems* 35 (2022) 324-337.
- [19] Ö. Özmen, A. Khdr, E. Avcı, Sınıflandırıcıların kalp hastalığı verileri üzerine performans karşılaştırması, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 30 (2018) 153-159.
- [20] A.K. Dwivedi, Performance evaluation of different machine learning techniques for prediction of heart disease, *Neural Computing and Applications* 39 (2018) 685-693.
- [21] M.R. Hassan, M.F. Islam, M.Z. Uddin, G. Ghoshal, M.M. Hassan, Prostate cancer classification from ultrasound and mri images using deep learning based explainable artificial intelligence, *Future Generation Computer Systems* 127 (2022) 462-472. doi:10.1016/j.future.2021.09.030.
- [22] P. Gadpayleand, P. Mahajani, Detection and classification of brain tumor in mri images, *Int. J. Electr. Comput. Eng.* 5 (2013) 45–49.
- [23] A.Z. Abidin, I. Dar, A.M. D'Souza, E.P. Lin, A. Wismüller, Investigating a quantitative radiomics approach for brain tumor classification, *Medical Imaging* 10 (2019) 36-45. doi:10.1117/12.2512995.
- [24] M. Sajjad, S. Khan, K. Muhammad, W. Wu, A. Ullah, S.W. Baik, Multigrade brain tumor classification using deep CNN with extensive data augmentation, *Journal of Computational Science* 30 (2019) 74-82. doi:10.1016/j.jocs.2018.12.003.
- [25] Y.W. Park, K. Han, S.S. Ahn, S. Bae, Y.S. Choi, J.H. Chang, S.K. Lee, Prediction of IDH1-mutation and 1p/19q-codeletion status using preoperative mr imaging phenotypes in lower grade gliomas, *American Journal of Neuroradiology* 39 (2018) 37-42. doi:10.3174/ajnr.A5421.
- [26] A. Orman, Brain tumor detection via explainable convolutional neural networks, *El-Cezeri Journal of Science and Engineering* 8 (2021) 1323-1337. doi:10.31202/ecjse.924446.
- [27] H.A. Khan, W. Jue, M. Mushtaq, M.U. Mushtaq, Brain tumor classification in mri image using convolutional neural network, *Math. Biosci. Eng.* 17 (2020) 6203-6216.
- [28] J.A. Marmolejo, U. Kose, Numerical Grad-Cam based explainable convolutional neural network for brain tumor diagnosis, *Mobile Networks and Applications* 29 (2024) 109-118.
- [29] C.J. Honey, J.P. Thivierge, O. Sporns, Can structure predict function in the human brain?, *Neuroimage* 52 (2010) 766-776. doi:10.1016/j.neuroimage.2010.01.071.
- [30] C.E. Coffey, W.E. Wilkinson, L.A. Parashos, S.R. Soady, R.J. Sullivan, L.J. Patterson, W.T. Djang Quantitative cerebral anatomy of the aging human brain: A cross-sectional study using magnetic resonance imaging, *Neurology* 42 (1992) 527-527. doi:10.1212/WNL.42.3.527.
- [31] D. Wahdan, Anatomy of medulla, 2024. <https://www.docdroid.net/8pInJNk/anatomy-of-medulla-2024-docx#page=3>, (10 Aralık 2024’de erişildi).
- [32] A. Leblanc, Anatomy and imaging of the cranial nerves: A neuroanatomic method of investigation using magnetic resonance imaging and computed tomography, Springer Science & Business Media, Berlin, 2012.
- [33] E. Gordon, Brain imaging technologies: How, what, when and why?, *Australian & New Zealand Journal of Psychiatry* 33 (1999) 187-196. doi:10.1046/j.1440-1614.1999.00557.x.
- [34] T. Katsuda, H. Isshiki, Contribution of medical big data analysis technology to medical innovations, *Fujitsu Scientific & Technical Journal* 54 (2018) 59-65.

- [35] N.A. Charles, E.C. Holland, R. Gilbertson, R. Glass, H. Kettenmann, The brain tumor microenvironment, *Glia* 59 (2011) 1169-1180. doi:10.1002/glia.21264.
- [36] R.R. Agravat, M.S. Raval, A survey and analysis on automated glioma brain tumor segmentation and overall patient survival prediction, *Archives of Computational Methods in Engineering* 28 (2021) 4117-4152.
- [37] A. İlçe, B. Totur, T. Özbayır, Evaluation of patients with brain tumors according to international nanda nursing diagnoses: Care suggestions, *Journal of Neurological Sciences* 27 (2010) 178-184.
- [38] J. Boutry, S. Tissot, B. Ujvari, J.P. Capp, M. Giraudeau, A.M. Nedelcu, F. Thomas, The evolution and ecology of benign tumors, *Biochimica et Biophysica Acta-Reviews on Cancer* 1 (2022) 18-32.
- [39] S.R. Gesaka, P.M. Okemwa, P.M. Mwachaka, Histological types of brain tumors diagnosed at the kenyatta national hospital between 2016 and 2019: A retrospective study, *Discover Oncology* 15 (2024) 1-11.
- [40] M.J. Bent, M. Geurts, P.J. French, M. Smits, D. Capper, J.E. Bromberg, S.M. Chang, Primary brain tumours in adults, *The Lancet* 402 (2023) 1564-1579.
- [41] K.D. Miller, Q.T. Ostrom, C. Kruchko, N. Patil, T. Tihan, G. Cioffi, H.E. Fuchs, K.A. Waite, A. Jemal, R.L. Siegel, Brain and other central nervous system tumor statistics, *A Cancer Journal for Clinicians* 71 (2021) 381-406. doi:10.3322/caac.21693.
- [42] C.E. Badr, D.J. Silver, F.A. Siebzehnubel, L.P. Deleyrolle, Metabolic heterogeneity and adaptability in brain tumors, *Cellular and Molecular Life Sciences* 77 (2020) 5101-5119.
- [43] M.L. Bondy, M.E. Scheurer, B. Malmer, J.S. Barnholtz-Sloan, F.G. Davis, Brain tumor epidemiology: Consensus from the brain tumor epidemiology consortium, *Cancer* 113 (2008) 1953-1968. doi:10.1002/cncr.23741.
- [44] Ç. Erçelik, K. Hanbay, Beyin tümörü sınıflandırmada histogram eşitleme yönteminin bazı derin öğrenme modellerine etkileri, *Computer Science* 8 (2023) 83-92. doi:10.53070/bbd.1373990.
- [45] A.B. Şimşek, A. Dicle, Primer beyin tümörü: Klinik özellikler, tedavi ve bakım, *Dokuz Eylül Üniversitesi Hemşirelik Fakültesi Elektronik Dergisi* 6 (2013) 102-113.
- [46] G. Sünter, A.G. Güngördü, İ. Midi, K. Ağan, C. Aykut, Beyin tümörü olan hastalarda status epileptikus, *Journal of the Turkish Epilepsi Society* 25 (2019) 155-159. doi: 10.14744/epilepsi.2018.04834.
- [47] H. Mohsen, Classification using deep learning neural networks for brain tumors, *Future Computing and Informatics Journal* 3 (2018) 68-71. doi:10.1016/j.fcij.2017.12.001.
- [48] Sağlık Bakanlığı, Türkiye kanser istatistikleri, 2018. https://hsgm.saglik.gov.tr/depo/birimler/kanser-db/Dokumanlar/Istatistikler/Kanser_Rapor_2018.pdf, (12 Aralık 2024'de erişildi).
- [49] D.N. Louis, A. Perry, G. Reifenberger, A. Deimling, D. Figarella-Branger, W.K. Cavenee, D.W. Ellison, The 2016 World Health Organization classification of tumors of the central nervous system: A summary, *Acta Neuropathologica* 131 (2016) 803-820.
- [50] P. Wesseling, D. Capper, WHO 2016 classification of gliomas, *Neuropathology and Applied Neurobiology* 44 (2018) 139-150. doi:10.1111/nan.12432.
- [51] D.N. Louis, A. Perry, P. Wesseling, D.J. Brat, I.A. Cree, D. Figarella-Branger, D.W. Ellison, The 2021 WHO classification of tumors of the central nervous system: A summary, *Neuro-Oncology* 23 (2021) 1231-1251. doi:10.1093/neuonc/noab106.

- [52] A.G. Osborn, M.T. Preece, Intracranial cysts: Radiologic-pathologic correlation and imaging approach, *Radiology* 239 (2006) 650-664. doi:10.1148/radiol.2393050823.
- [53] S. Cha, Neuroimaging in neuro-oncology, *Neurotherapeutics* 3 (2006) 539-550.
- [54] K.W. Muir, A. Buchan, R. Kummer, J. Rother, J.C. Baron, Imaging of acute stroke, *The Lancet Neurology* 5 (2006) 755-768.
- [55] S.A. Kahraman, Bilgisayarlı tomografi prensipleri ve uygulamadaki yenilikler, *ADO Klinik Bilimler Dergisi* 3 (2010) 481-489.
- [55] R.K. Kumrular, A. Polat, Klinik uygulamalarda ileri biyomedikal görüntüleme teknolojileri, *Avrupa Bilim ve Teknoloji Dergisi* (2021) 207-221. doi:10.31590/ejosat.840321.
- [57] F. Koçyiğit, 2008. Düşük Frekanslı Transkutanöz Elektriksel Sinir Stimülasyonu Uygulamasının Santral Ağrı Modülasyonuna Etkisinin Fonksiyonel Manyetik Rezonans Görüntüleme İle Araştırılması, Doktora Tezi, Dokuz Eylül Üniversitesi, Tıp Fakültesi.
- [58] B. Işık, Manyetik rezonans görüntüleme ve anestezi, *Marmara Medical Journal* 19 (2006) 98-103.
- [59] Z.U. Rahman, P. Sethi, G. Murtaza, H.U. Virk, A. Rai, M. Mahmood, K. Albalbissi, Feature tracking cardiac magnetic resonance imaging: A review of a novel non-invasive cardiac imaging technique, *World Journal of Cardiology* 9 (2017) 276-312. doi:10.4330/wjc.v9.i4.312.
- [60] T.G. Turkington, Introduction to PET instrumentation, *Journal of Nuclear Medicine Technology* 29 (2001) 4-11.
- [61] S.R. Cherry, M. Dahlbom, PET: Physics, instrumentation, and scanners, Springer, New York, 2006.
- [62] K. Herholz, S.F. Carter, M. Jones, T.H. Bak, Positron emission tomography in dementia, *Seminars in Nuclear Medicine* 37 (2007) 373-386.
- [63] L. Kostakoglu, S.J. Goldsmith, 18F-FDG PET evaluation of the response to therapy for lymphoma and for breast, lung, and colorectal carcinoma, *Journal of Nuclear Medicine* 44 (2003) 224-239.
- [64] Z.H. Zhou, Machine learning, Springer Nature, New York, 2021.
- [65] E. Alpaydin, Machine learning, MIT Press, Cambridge, 2021.
- [66] I.H. Sarker, Machine learning: Algorithms, real-world applications and research directions, *SN Computer Science* 2 (2021) 1-21.
- [67] R. Jhaveri, R. Kadiyala, R. Roshani, K.D. Rajesh, Mobile information system 2022. <https://onlinelibrary.wiley.com/doi/toc/10.1155/9071.si.943756?page=3>, (18 Kasım 2024'de erişildi).
- [68] I. Naqa, M.J. Murphy, What is machine learning?, Springer International Publishing, New York, 2015.
- [69] B. Mahesh, Machine learning algorithms-A review, *International Journal of Science and Research* 9 (2020) 381-386. doi: 10.21275/ART20203995.
- [70] K. Alkhatib, H. Najadat, I. Hmeidi, M.K.A. Shatnawi, Stock price prediction using K-Nearest Neighbor (kNN) algorithm, *International Journal of Business, Humanities and Technology* 3 (2013) 32-44.
- [71] S.B. Imandoust, M. Bolandraftar, Application of K-Nearest Neighbor (Knn) approach for predicting economic events: Theoretical background, *International Journal Of Engineering Research And Applications* 3 (2013) 605-610.

- [72] Ü. Çavuşoğlu, S. Kaçar, Anormal trafik tespiti için veri madenciliği algoritmalarının performans analizi, Academic Platform Journal of Engineering and Science (2019) 205-216. doi:10.21541/apjes.418519.
- [73] S. Huang, N. Cai, P.P. Pacheco, S. Narrandes, Y. Wang, W. Xu, Applications of support vector machine (SVM) learning in cancer genomics, Cancer Genomics & Proteomics 15 (2018) 41-51.
- [74] A. Mammone, M. Turchi, N. Cristianini, Support vector machines, Wiley Interdisciplinary Reviews: Computational Statistics 1 (2009) 283-289. doi:10.1002/wics.49.
- [75] G. Chitralkha, R. Jyoti, A quick review of ML algorithms, 2021. https://www.researchgate.net/publication/355666048_A_Quick_Review_of_ML_Algorithms, (19 Kasım 2024'de erişildi).
- [76] O. Kaynar, H. Arslan, Y. Görmez, Y.E. Işık, Makine öğrenmesi ve öznetelik seçim yöntemleriyle, Bilişim Teknolojileri Dergisi (2018) 175-185. doi:10.17671/gazibtd.368583.
- [77] M.P. LaValley, Logistic regression, Circulation 117 (2008) 2395-2399. doi:10.1161/CIRCULATIONAHA.106.682658.
- [78] T.G. Nick, K.M. Campbell, Logistic regression, Topics In Biostatistics (2007) 273-301.
- [79] W. Mc Culloch, W. Pitts, A logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical Biophysics (1943) 115-133.
- [80] E. Çiftçi, Sinir sistemi: Nöronlar, 2024. <https://bilscience.com/sinir-sistemi-noronlar/>, (08 Aralık 2024'de erişildi).
- [81] Philosophy of AI, Structure of artificial nerve cells, 2024. https://www.youtube.com/supported_browsers?next_url=https%3A%2F%2Fwww.youtube.com%2Fwatch%3Fv%3D3gTYC6MVKUQ, (10 Aralık 2024'de erişildi).
- [82] M.G. Abdolrasol, S.S. Hussain, T.S. Ustun, M.R. Sarker, M. Hannan, R. Mohamed, A. Milad, Artificial neural networks based optimization techniques: A review, Electronics 10 (2021) 26-89. doi:10.3390/electronics10212689.
- [83] J.D. Kelleher, A brief history of deep learning, Deep Learning 11 (2020) 25-32.
- [84] P. Saikia, R.D. Baruah, S.K. Singh, P.K. Chaudhuri, Artificial neural networks in the domain of reservoir characterization: A review from shallow to deep models, Computers & Geosciences 135 (2020) 104-357. doi:10.1016/j.cageo.2019.104357.
- [85] L. Deng, D. Yu, Deep learning: Methods and applications, Trends 7 (2014) 197-387. doi:10.1561/20000000039.
- [86] H.A. Song, S.Y. Lee, Hierarchical representation using NMF, 2013. https://www.cs.cmu.edu/~hyunahs/papers/ICONIP2013_1.pdf, (31 Aralık 2024'de erişildi).
- [87] G.E. Hinton, S. Osindero, Y.W. Teh, A fast learning algorithm for deep belief nets, Neural Computation 18 (2006) 1527-1554. doi:10.1162/neco.2006.18.7.1527.
- [88] T. Wataya, Introduction to deep learning: Minimum essence required to launch a research, Japanese Journal Radiology 38 (2020) 907-921.
- [89] M.M. Taye, Theoretical understanding of convolutional neural network: concepts, architectures, applications, future directions, Computation 11 (2023) 45-52. doi:10.3390/computation11030052.
- [90] T. Kattenborn, L. Jens, S. Felix, H. Stefan, Review on Convolutional Neural Networks (CNN) in vegetation remote sensing, Journal of Photogrammetry and Remote Sensing (2021) 24-49. doi:10.1016/j.isprsjprs.2020.12.010.

- [91] L. Alzubaidi, J. Zhang, A.J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaría, M.A. Fadhel, M. Al-Amidie, L. Farhan, Review of deep learning: concepts, CNN architectures, challenges, applications, future directions, *Journal of Big Data* 8 (2021) 1-74.
- [92] A. Mohamed, T. Gaber, O. Karam, E.A. Rashed, A novel CNN pooling layer for breast cancer segmentation and classification from thermograms, *Plosone* 17 (2022) 1-18. doi:10.1371/journal.pone.0276523.
- [93] S. Albawi, A.M. Tareq, A. Saad, Understanding of a convolutional neural network, 2018. file:///C:/Users/admin/Downloads/10.1109/ICEngTechnol.2017.83081861.pdf, (20 Aralık 2024'de erişildi).
- [94] M. Zoric, M. Stula, I. Markic, M. Braovic, Transfer learning in building neural network model case study, 2024. https://www.researchgate.net/profile/Ivan-Markic-2/publication/385420935_Transfer_Learning_in_Building_Neural_Network_Model_Case_Study/links/67248e3577b63d1220d21e09/Transfer-Learning-in-Building-Neural-Network-Model-Case-Study.pdf, (10 Aralık 2024'de erişildi).
- [95] K. Filus, J. Domanska, Recycling of generic imagenet-trained models for smart-city applications, 2023. <https://ieeexplore.ieee.org/abstract/document/10302563>, (08 Aralık 2024'de erişildi).
- [96] Y. Le Cun, Y. Bengio, G. Hinton, Deep learning, *Nature* 521 (2015) 421-436.
- [97] Y. Tiraki, H. Temurtaş, S. Serttaş, Ç. Bakır, Çeşitli görüntülerin sınıflandırılması için yeni bir evrimsel sinir ağı önerisi, *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi* 13 (2024) 262-278. doi:10.28948/ngumuh.1355726.
- [98] N. Veni, J. Manjula, High-performance visual geometric group deep learning architectures for mri brain tumor classification, *The Journal of Supercomputing* 78 (2022) 12753-12764.
- [99] Ö. Savaş, Derin öğrenme hakkında neredeyse herşey, 2022. <https://medium.com/software-development-turkey/derin-%C3%B6%C4%9Frenme-hakk%C4%B1nda-neredeyse-her-%C5%9Fey-4-8addddc428ee>, (12 Aralık 2024'de erişildi).
- [100] I. Kandel, M. Castelli, Transfer learning with convolutional neural networks for diabetic retinopathy image classification: A review, *Applied Sciences* 10 (2021) 2-24. doi:10.3390/app10062021.
- [101] D. Sarwinda, R.H. Paradisa, A. Bustamam, P. Anggia, Deep learning in image classification using residual network (resnet) variants for detection of colorectal cancer, *Procedia Computer Science* 179 (2021) 423-431. doi:10.1016/j.procs.2021.01.025.
- [102] Coding Nomads, What is Resnet, 2024. <https://codingnomads.com/what-is-resnet>, (13 Aralık 2024'de erişildi).
- [103] M. Sandler, MobileNetV2: Inverted residuals and linear bottlenecks, 2018. https://openaccess.thecvf.com/content_cvpr_2018/papers/Sandler_MobileNetV2_Inverted_Residuals_CVPR_2018_paper.pdf, (13 Aralık 2024'de erişildi).
- [104] H. Wang, Score-CAM: Score-weighted visual explanations for convolutional neural networks, 2020. https://openaccess.thecvf.com/content_CVPRW_2020/papers/w1/Wang_Score-CAM_Score-Weighted_Visual_Explanations_for_Convolutional_Neural_Networks_CVPRW_2020_paper.pdf, (03 Ekim 2024'de erişildi).
- [105] C. Szegedy, Rethinking the inception architecture for computer vision, 2016. https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Szegedy_Rethinking_the_Inception_CVPR_2016_paper.pdf, (15 Aralık 2024'de erişildi).
- [106] S. Zorgui, A convolutional neural network for lentigo diagnosis, 2020. https://link.springer.com/content/pdf/10.1007/978-3-030-51517-1_8.pdf, (14 Aralık 2024'de erişildi).

- [107] M. Mahdianpari, B. Salehi, F. Mohammadimanesh, Deep convolutional neural networks for complex land cover classification of remote sensing imagery, AGU Fall Meeting Abstracts 3 (2018) 31-38.
- [108] G. Huang, Densely connected convolutional networks 2017. https://openaccess.thecvf.com/content_cvpr_2017/papers/Huang_Densely_Connected_Convolutional_CVPR_2017_paper.pdf, (14 Aralık 2024'de erişildi).
- [109] D. Arora, M. Garg, M. Gupta, Diving deep in deep convolutional neural network, 2020. <https://ieeexplore.ieee.org/abstract/document/9362907>, (15 Aralık 2024'de erişildi).
- [110] H. Kibriya, M. Masood, M. Nawaz, R. Rafique, S. Rehman, Multiclass brain tumor classification using convolutional neural network and support vector machine, 2021. file:///C:/Users/admin/Downloads/Multiclass_Brain_Tumor_Classification_Using_Convolutional_Neural_Network_and_Support_Vector_Machine.pdf, (16 Kasım 2024'de erişildi).
- [111] S.Inthiyaz, S.H. Ahammad, A. Krishna, V. Bhargavi, D. Govardhan, V. Rajesh, YOLO (You Only Look Once) making object detection work in medical imaging on convolution detection system, International Journal of Pharmaceutical Research 12 (2020) 300-312. doi: 10.31838/ijpr/2020.12.02.0003.
- [112] K. Antun, Razvoj rješenja za prepoznavanje svjetlosne prometne signalizacije i implementacija razvijenog rješenja na realnu ADAS platformu, 2024. <https://repozitorij.etfos.hr/islandora/object/etfos:2908/datastream/PDF/view>, (12 Aralık 2024'de erişildi).
- [113] Ö. Polat, Detection of covid-19 from chest ct images using xception architecture: A deep transfer learning based approach, Sakarya University Journal of Science 25 (2021) 800-810. doi:10.16984/saufenbilder.903886.
- [114] F. Chollet, Xception: Deep learning with depthwise separable convolutions, 2017. https://openaccess.thecvf.com/content_cvpr_2017/papers/Chollet_Xception_Deep_Learning_CVPR_2017_paper.pdf, (11 Aralık 2024'de erişildi).
- [115] T.Mingxing, EfficientNet,2019. <https://blog.research.google/2019/05/efficientnetimproving-accuracy-and.html?m=1>, (10 Aralık 2024'de erişildi).
- [116] M.M. Islam, M.A. Talukder, M.A. Uddin, A. Akhter, M. Khalid, Brainnet: precision brain tumor classification with optimized efficientnet architecture, International Journal of Intelligent Systems (2024) 1-24. doi:10.1155/2024/3583612.
- [117] S. Tripathy, R. Singh, M. Ray, Automation of brain tumor identification using efficientnet on magnetic resonance images, Procedia Computer Science 218 (2023) 1551-1560. doi:10.1016/j.procs.2023.01.133.
- [118] T. Padma, C.U. Kumari, D. Yamini, Image segmentation using mask R-CNN for tumor detection from medical images, 2022. <https://ieeexplore.ieee.org/abstract/document/9751891>, (18 Aralık 2024'de erişildi).
- [119] R. Girshick, J. Donahue, M. Darrell, T.J., Berkeley, Rich feature hierarchies for accurate object detection and semantic segmentation, 2014. https://openaccess.thecvf.com/content_cvpr_2014/papers/Girshick_Rich_Feature_Hierarchies_2014_CVPR_paper.pdf, (16 Kasım 2024'de erişildi).
- [120] C. Pomahobhy, Application of convolutionary neural networks object recognition security in video streams, 2020. <file:///C:/Users/admin/Downloads/Admin,+008.pdf>, (11 Kasım 2024'de erişildi).
- [121] Y. Chen, S. Liu, X. Shen, J. Jia, Fast point R-CNN, 2019. https://openaccess.thecvf.com/content_ICCV_2019/papers/Chen_Fast_Point_R-CNN_ICCV_2019_paper.pdf, (08 Kasım 2024'de erişildi).

- [122] R. Girshick, Fast R-CNN, IEEE, New York, 2015.
- [123] M.M. Mijwil, K. Aggarwal, R. Doshi, K.K. Hiran, M. Gök, The distinction between R-CNN and fast RCNN in image analysis: A performance comparison, *Asian Journal of Applied Sciences* 10 (2022) 429-437.
- [124] O. Ronneberger, P. Fischer, T. Brox, U-net: Convolutional networks for biomedical image segmentation, Springer International Publishing, New York, 2015.
- [125] E. Zahra, B. Ali, W. Siddique, Medical image segmentation using a U-Net type of architecture, 2020. <https://arxiv.org/pdf/2005.05218>, (11 Kasım 2024'de erişildi).
- [126] X. Zhang, Y. Li, Y. Liu, S.X. Tang, X. Liu, K. Punithakumar, D. Shi, Automatic spinal cord segmentation from axial-view MRI slices using CNN with grayscale regularized active contour propagation, 2021. <https://www.sciencedirect.com/science/article/abs/pii/S0010482521001396>, (11 Ekim 2024'de erişildi).
- [127] N. Bjorck, C.P. Gomes, B. Selman, K. Weinberger, Understanding batch normalization, 2018. <https://proceedings.neurips.cc/paper/2018/file/36072923bfc3cf47745d704feb489480-Paper.pdf>, (12 Ekim 2024'de erişildi).
- [128] F. Milletari, N. Navab, S.A. Ahmadi, V-Net: Fully convolutional neural networks for volumetric medical image segmentation, 2016. <https://arxiv.org/pdf/1606.04797>, (14 Eylül 2024'de erişildi).
- [129] Ö. Çiçek, A. Abdulkadir, S.S. Lienkamp, T. Brox, O. Ronneberger, 3D U-Net: Learning dense volumetric segmentation from sparse annotation, 2016. https://www.researchgate.net/profile/Olaf-Ronneberger/publication/304226155_3D_U-Net_Learning_Dense_Volumetric_Segmentation_from_Sparse_Annotation/links/5b2a4c990f7e9b1d009c9b60/3D-U-Net-Learning-Dense-Volumetric-Segmentation-from-Sparse-Annotation.pdf, (08 Eylül 2024'de erişildi).
- [130] M.Z. Alom, C. Yakopcic, T.M. Taha, V.K. Asari, Nuclei segmentation with recurrent residual convolutional neural networks based U-Net, 2018. <https://ieeexplore.ieee.org/abstract/document/8556686>, (16 Eylül 2024'de erişildi).
- [131] S. Pattanayak, Pro deep learning with tensorflow 2.0: A mathematical approach to advanced artificial intelligence in python, Springer, New York, 2023.
- [132] C. Srinivas, M. Zakariah, Y.A. Alothaibi, K. Shaukat, B. Partibane, H. Awal, Deep transfer learning approaches in performance analysis of brain tumor classification using MRI images, *Journal of Healthcare Engineering* (2022) 1-17. doi:10.1155/2022/3264367.
- [133] Medium, Karışıklık matrisi, 2021. <https://burhanbilen.medium.com/kar%C4%B1%C5%9F%C4%B1kl%C4%B1k-matrisi-confusion-matrix-990dfc718653>, (10 Ekim 2024'de erişildi).
- [134] P.P. Angelov, E.A. Soares, R. Jiang, N.I. Arnold, P.M. Atkinson, Explainable artificial intelligence: An analytical review, *Wiley* 11 (2021) 1-13. doi:10.1002/widm.1424.
- [135] A. Englebert, O. Cornu, C.D. Vleeschouwer, Poly-Cam: High resolution class activation map for convolutional neural networks, *Machine Vision and Applications* 35 (2024) 70-89.
- [136] K. Vinogradova, A. Dibrov, G. Myers, Towards interpretable semantic segmentation via gradient-weighted class activation mapping, *Artificial Intelligence* 34 (2020) 13943-13944. doi:10.1609/aaai.v34i10.7244.
- [137] S. Riyadi, E.N. Pramudya, C. Damarjati, J.M. Lopez, J.G. Herrero, Explainable optimization of deep learning model for Covid-19 detection using chest images, *Informatics in Medicine Unlocked* 49 (2024) 1-15. doi:10.1016/j.imu.2024.101559.

- [138] D.E. Turan, 2023. Beyond 2D And More: Binterpreting Remote Sensing Image Classification Methods Via Explainable Artificial Intelligence, Doktora Tezi, Sabancı Üniversitesi, Fen Bilimleri Enstitüsü.
- [139] S. Yin, L. Wang, M. Shafiq, L. Teng, A.A. Laghari, M.F. Khan, G2Grad-CAMRL: An object detection and interpretation model based on gradient-weighted class activation mapping and reinforcement learning in remote sensing images, *Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 16 (2023) 3583-3598. doi:10.1109/JSTARS.2023.3241405.
- [140] M.S. Jamil, S.P. Banik, G.A. Rahaman, S. Saha, *Computer vision and image analysis for industry 4.0*, Chapman and Hall, London, 2023.
- [141] M.B. Muhammad, M. Yeasin, Eigen-CAM: Class activation map using principal components, 2020. <https://arxiv.org/pdf/2008.00299>, (01 Ekim 2024'de erişildi).
- [142] M. Muhammad, M. Yeasin, Eigen-CAM: Visual explanations for deep convolutional neural networks, *SN Computer Science* 2 (2021) 36-47.
- [143] M. Erturk, M.Ü. Öziç, M. Tassoker, Deep convolutional neural network for automated staging of periodontal bone loss severity on bite-wing radiographs: an eigen-cam explainability mapping approach, *Journal of Imaging Informatics in Medicine* (2024) 1-20.
- [144] R. Ibrahim, M.O. Shafiq, Augmented Score-CAM: High resolution visual interpretations for deep neural networks, *Knowledge-Based Systems* 252 (2022) 109-287. doi:10.1016/j.knosys.2022.109287.
- [145] R. Fu, Q. Hu, X. Dong, Y. Guo, B. Li, Axiom-based Grad-CAM: Towards accurate visualization and explanation of CNNs, 2020. <https://arxiv.org/pdf/2008.02312>, (06 Eylül 2024'de erişildi).
- [146] P.T. Jiang, C.B. Zhang, Q. Hou, M.M. Cheng, Y. Wei, LayerCAM: Exploring hierarchical class activation maps for localization, *Transactions on Image Processing* 30 (2021) 875–888. doi:10.1109/TIP.2021.3089943.
- [147] C. Liang, B. Xiao, B. Cheng, Y. Dong, XANet: An efficient remote sensing image segmentation model using element-wise attention enhancement and multi-scale attention fusion, *Remote Sensing* 15 (2022) 186-236. doi:10.3390/rs15010236.
- [148] A.K. Gizzini, M. Shukor, A.J. Ghandour, Extending CAM-based XAI methods for remote sensing imagery segmentation, 2023. <https://arxiv.org/pdf/2310.01837>, (07 Kasım 2024'de erişildi).
- [149] S.S. Fatima, M. Wooldridge, N.R. Jennings, A linear approximation method for the shapley value, *Artificial Intelligence* 172 (2008) 1673-1699. doi:10.1016/j.artint.2008.05.003.
- [150] H. Chen, I.C. Covert, S.M. Lundberg, S.I. Lee, Algorithms to estimate shapley value feature attributions, *Nature Machine Intelligence* 5 (2023) 590-601.
- [151] E. Winter, The Shapley value, 2002. <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=90811fdcd3f3243fa57c0e2d14926a70e5858b1>, (16 Ekim 2024'de erişildi).
- [152] A. Bhattacharya, *Applied machine learning explainability techniques: Make ml models explainable and trustworthy for practical applications using LIME, SHAP, and more*, Packt Publishing, Birmingham, 2022.
- [153] R.I. Hamilton, P.N. Papadopoulos, Using SHAP values and machine learning to understand trends in the transient stability limit, *Transactions on Power Systems* 39 (2023) 1384-1397. doi:10.1109/TPWRS.2023.3248941.

- [154] B. Aldughayfiq, F. Ashfaq, N.Z. Jhanjhi, M. Humayun, Explainable AI for retinoblastoma diagnosis: Interpreting deep learning models with Lime and Shap, *Diagnostics* 13 (2023) 1869-1932. doi:10.3390/diagnostics13111932.
- [155] M.E. Günay, N.A. Tapan, Analysis of PEM and AEM electrolysis by neural network pattern recognition, association rule mining and Lime, *Energy and AI* 13 (2023) 100-254. doi:10.1016/j.egyai.2023.100254.
- [156] V.K. Pandey, S. Dhiman, K. Bharti, A review on the use of lime in soil stabilization, *Latest Trends in Engineering and Technology* (2024) 414-421.
- [157] R. Ramteke, K.Y. Monali, Automatic medical image classification and abnormality detection using K-Nearest Neighbour, *Int. J. Adv. Comput. Res.* 2 (2012) 168-190.
- [158] P. Gadpayleand, P. Mahajani, Detection and classification of brain tumor in MRI images, *Int. J. Electr. Comput. Eng.* 5 (2013) 45-49.
- [159] D. Ghosh, S.K. Bandyopadhyay, Brain tumor detection from MRI image: An approach, *IJAR* 3 (2017) 1152-1159.
- [160] A.K. Anaraki, M. Ayati, F. Kazemi, Magnetic resonance imagingbased brain tumor grades classification and grading via convolutional neural networks and genetic algorithms, *Biocybernetics Biomed. Eng.* 39 (2019) 63-74. doi:10.1016/j.bbe.2018.10.004.
- [161] H. Zhou, K. Chang, H.X. Bai, B. Xiao, C. Su, W.L. Bi, R.Y. Huang, Machine learning reveals multimodal mri patterns predictive of isocitrate dehydrogenase and 1p/19q status in diffuse low-and high-grade gliomas, *Journal of Neuro-Oncology* 142 (2019) 299-307.
- [162] S. Bisdas, H. Shen, S. Thust, V. Katsaros, G. Stranjalis, C. Boskos, J. Zhang, Texture analysis-and support vector machine-assisted diffusional kurtosis imaging may allow in vivo gliomas grading and idh-mutation status prediction: a preliminary study, *Scientific Reports* 8 (2018) 1-9.
- [163] J. Yu, Z. Shi, Y. Lian, Z. Li, T. Liu, Y. Gao, Y. Mao, Noninvasive IDH1 mutation estimation based on a quantitative radiomics approach for grade II glioma, *European Radiology* 27 (2017) 3509-3522.
- [164] B. Shofty, M. Artzi, D. Ben Bashat, G. Liberman, O. Haim, A. Kashanian, F. Bokstein, D.T. Blumenthal, Z. Ram, T. Shahar, MRI radiomics analysis of molecular alterations in low-grade gliomas, *International Journal of Computer Assisted Radiology And Surgery* 13 (2018) 563-571.
- [165] R. Ramon, S. Ruiz-Espana, E. Molla-Olmos, D. Moratal, Glioblastomas and brain metastases differentiation following an MRI texture analysis-based radiomics approach, *Physica Medica* 76 (2020) 44-54. doi:10.1016/j.ejmp.2020.06.016.
- [166] Y. Han, Z. Xie, Y. Zang, S. Zhang, D. Gu, M. Zhou, D. Zhou, Noninvasive genotype prediction of chromosome 1p/19q co-deletion by development and validation of an mri-based radiomics signature in lowergrade gliomas, *Journal Of Neuro-Oncology* 140 (2018) 297-306.
- [167] P. Chang, J. Grinband, B.D. Weinberg, M. Bardis, M. Khy, G. Cadena, D. Chow, Deep-learning convolutional neural networks accurately classify genetic mutations in gliomas, *American Journal of Neuroradiology* 39 (2018) 1201-1207.
- [168] C.F. Lu, F.T. Hsu, K.L. Hsieh, Y.J. Kao, S.J. Cheng, J.B. Hsu, P.H. Tsai, Machine learning-based radiomics for molecular subtyping of gliomas, *Clin. Cancer Res.* 24 (2018) 4429-4436. doi:10.1158/1078-0432.CCR-17-3445.
- [169] Z. Akkus, I. Ali, J. Sedlar, T.L. Kline, J.P. Agrawal, I.F. Parney, B.J. Erickson, Predicting 1p19q chromosomal deletion of low-grade gliomas from mr images using deep learning, 2016. <https://arxiv.org/pdf/1611.06939>, (14 Eylül 2024'de erişildi).

- [170] B. Koçak, E.S. Durmaz, E. Ates, I. Sel, S.T. Gunes, O.K. Kaya, O. Kilickesmez, Radiogenomics of lower-grade gliomas: machine learning– based mri texture analysis for predicting 1p/19q codeletion status, *European Radiology* 30 (2020) 877-886.
- [171] S.R. Voort, R. Gahrman, W.J. Niessen, Radiogenomic classification of 1p/19q status in presumed low grade gliomas, 2017. <https://nvphbv.nl/site/wp-content/uploads/2016/09/Presentation-Sebastiaan.pdf>, (09 Ekim 2024’de erişildi).
- [172] P.S. Kohli, S. Arora, Application of machine learning in disease prediction, 2018. <https://ieeexplore.ieee.org/abstract/document/8777449>, (07 Ekim 2024’de erişildi).
- [173] A. Tyagi, R. Mehra, A. Saxena, Interactive Thyroid disease prediction system using machine learning technique, 2018. https://www.researchgate.net/profile/Ankita-Tyagi/publication/331533687_Interactive_Thyroid_Disease_Prediction_System_Using_Machine_Learning_Technique/links/5d3be73b4585153e592534ce/Interactive-Thyroid-Disease-Prediction-System-Using-Machine-Learning-Technique.pdf, (02 Ekim 2024’de erişildi).
- [174] N.A. Almansour, H.F. Syed, N.R. Khayat, R.K. Altheeb, R.E. Juri, J. Alhiyafi, S. Alrashed, S.O. Olatunji, Neural network and support vector machine for the prediction of chronic kidney disease: a comparative study, *Computers In Biology And Medicine* 109 (2019) 101-111. doi:10.1016/j.combiomed.2019.04.017.
- [175] J. Xiao, R. Ding, X. Xu, H. Guan, X. Feng, T. Sun, S. Zhu, Z. Ye, Comparison and development of machine learning tools in the prediction of chronic kidney disease progression, *Journal of Translational Medicine* 17 (2019) 1-13.
- [176] J. Singh, S. Bagga, R. Kaur, Software-based prediction of liver disease with feature selection and classification techniques, *Procedia Computer Science* 167 (2020) 1970-1980. doi:10.1016/j.procs.2020.03.226.
- [177] M. Kukar, G. Guncar, T. Vovko, S. Podnar, P. Cernelc, M. Brvar, M. Zalaznik, Covid-19 diagnosis by routine blood tests using machine learning, *Scientific Reports* 11 (2021) 107-138.
- [178] P. Saha, M.S. Sadi, M.M. Islam, EMCNet: Automated Covid-19 diagnosis from x-ray images using convolutional neural network and ensemble of machine learning classifiers, *Informatics In Medicine Unlocked* 22 (2021) 100-155. doi:10.1016/j.imu.2020.100505.
- [179] S.O. Olatunji, S. Alotaibi, E. Almutairi, Z. Alrabae, Y. Almajid, R. Altabee, Early diagnosis of thyroid cancer diseases using computational intelligence techniques: a case study of a Saudi Arabian dataset, *Computers in Biology and Medicine* 131 (2021) 104-267. doi:10.1016/j.combiomed.2021.104267.
- [180] E. Ryzhikova, N.M. Ralbovsky, V. Sikirzhytski, O. Kazakov, L. Halamkova, J. Quinn, E.A. Zimmerman, I.K. Lednev, Raman spectroscopy and machine learning for biomedical applications: alzheimer’s disease diagnosis based on the analysis of cerebrospinal fluid, *Spectrochimica Acta - Part A: Molecular and Biomolecular Spectroscopy* 248 (2021) 119-188. doi:10.1016/j.saa.2020.119188.
- [181] M.R. Hassan, M.F. Islam, M.Z. Uddin, G. Ghoshal, M.M. Hassan, Prostate cancer classification from ultrasound and MRI images using deep learning based explainable artificial intelligence, *Future Generation Computer Systems* 127 (2022) 462-472. doi:10.1016/j.future.2021.09.030.
- [182] S. Palaniappan, R. Awang, Intelligent heart disease prediction system using data mining techniques, *IJCSNS* 8 (2008) 108-115. doi:10.1109/AICCSA.2008.4493524.
- [183] R. Ani, A. Augustine, N.C. Akhil, O.S. Deepa, Random forest ensemble classifier to predict the coronary heart disease using risk factors, *Soft Computing Systems* 1 (2016) 701-710.
- [184] Ö.Ü. Yılmaz, Derin öğrenme, *Kodlab*, İstanbul, 2021.

- [185] T. Hussain, H. Shouno, Explainable deep learning approach for multi-class brain magnetic resonance imaging tumor classification and localization using gradient-weighted class activation mapping, *Information* 14 (2023) 578-642. doi:10.3390/info14120642.
- [186] A.M. Nancy, K. Sathyarajasekaran, Multi-modal explainability evaluation for brain tumor segmentation: Metrics MSFI, *International Journal of Intelligent Systems and Applications in Engineering* 12 (2024) 341–347.
- [187] T. Öztürk, O. Katar, A deep learning model collaborates with an expert radiologist to classify brain tumors from MR images, *Turkish Journal of Science and Technology* 17 (2022) 203-210. doi:10.55525/tjst.1143392.
- [188] K.H. Amin, Z.S. Saleh, C. Deo, An explainable ai framework for artificial intelligence of medical things, 2024. <https://arxiv.org/pdf/2403.04130>, (12 Ağustos 2024’de erişildi).
- [189] L. Gaur, M. Bhandari, T. Razdan, S. Mallik, Z. Zhao, Examining the prediction of discrete subtypes of brain tumors with deep learning models, 2022.
file:///C:/Users/admin/AppData/Local/Microsoft/Windows/INetCache/IE/3DRHLJ80/fgene-13-822666[1].pdf, (20 Aralık 2024’de erişildi).

ÖZGEÇMİŞ

Muhammet Doğukan İLİ

[illegible]

- _____
- _____

AKADEMİK FAALİYETLER

Bildiriler:

1. Muhammet Doğukan İLİ, Fatih ÖZYURT, Canan KOÇ (2023-07-10) Evrimsel Sinirsel Ağları Kullanarak Eurosat Verisetini Sınıflandırma XIII International Scientific Research Congress, 170 – 176.