



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**BEYİN TÜMÖRÜNÜN DERİN ÖĞRENME YAKLAŞIMLARI
KULLANILARAK TESPİT EDİLMESİ**

Cafer ASLIM

**Ağustos-2024
BATMAN**

T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

YÜKSEK LİSANS TEZİ

BEYİN TÜMÖRÜNÜN DERİN ÖĞRENME YAKLAŞIMLARI
KULLANILARAK TESPİT EDİLMESİ

Cafer ASLİM

Danışman
Doç. Dr. Abidin ÇALIŞKAN

Ağustos-2024
BATMAN

TEZ KABUL VE ONAYI

Cafer ASLIM tarafından hazırlanan ‘‘Beyin Tumorünün Derin Öğrenme Yaklaşımları Kullanılarak Tespit Edilmesi’’ adlı tez çalışması 27/08/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Erdal BAŞARAN

.....

Danışman

Doç. Dr. Abidin ÇALIŞKAN

.....

Üye

Doç. Dr. Ömer Ali KARAMAN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdür V.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Cafer ASLIM

27/08/2024

ÖZET

YÜKSEK LİSANS TEZİ

BEYİN TÜMÖRÜNÜN DERİN ÖĞRENME YAKLAŞIMLARI KULLANILARAK TESPİT EDİLMESİ

Cafer ASLİM

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Abidin ÇALIŞKAN

2024, 71 Sayfa

Jüri

Doç. Dr. Abidin ÇALIŞKAN

Doç. Dr. Erdal BAŞARAN

Doç. Dr. Ömer Ali KARAMAN

Bu yüksek lisans tezi, beyin tümörlerinin tespiti için derin öğrenme yöntemlerinin kullanımını incelemektedir. Beyin tümörleri, dünya genelinde nadir görülmelerine rağmen yüksek ölüm oranlarına sahip ciddi malignitelerdir. Erken teşhis ve doğru sınıflandırma, tedavi sürecinde hayati öneme sahiptir. Bu çalışmada, derin öğrenme yöntemlerinin, özellikle evrimsel sinir ağlarının (ESA), beyin tümörlerinin tespiti ve sınıflandırılması üzerindeki performansı değerlendirilmektedir. Çeşitli derin öğrenme modelleri ve makine öğrenmesi algoritmaları kullanılarak, beyin tümörlerinin MRI ve BT görüntülerinden tespit edilmesi amaçlanmıştır. Çalışmada VGG19, Inception V3 ve MobileNet gibi derin öğrenme modelleri ile K-En Yakın Komşu (k-NN) ve Destek Vektör Makineleri (DVM) gibi makine öğrenme algoritmaları kullanılmıştır. Model performansları doğruluk, hassasiyet, duyarlılık, F1 skoru ve ROC-AUC gibi metriklerle değerlendirilmiştir. Elde edilen sonuçlar, derin öğrenme modellerinin beyin tümörlerinin tespitinde yüksek doğruluk ve güvenilirlik sunduğunu göstermektedir. Özellikle VGG19 modelinin diğer modellere kıyasla daha yüksek performans sergilediği tespit edilmiştir.

Bu bulgular, derin öğrenme yöntemlerinin tıbbi görüntü analizi alanında etkili bir araç olabileceğini ve klinik uygulamalarda kullanılabilirliğini göstermektedir. Gelecekteki çalışmalarda, daha büyük veri setleri ve farklı derin öğrenme modelleri kullanılarak performansın daha da artırılması hedeflenebilir.

Anahtar Kelimeler: Beyin tümörü, bilgisayarlı tomografi, derin öğrenme, evrimsel sinir ağları, makine öğrenmesi

ABSTRACT

MS THESIS

DETECTING BRAIN TUMOR USING DEEP LEARNING APPROACHES

Cafer ASLIM

Batman University Graduate Education Institute

Electrical Electronics Engineering Department

Advisor: Assoc. Prof. Dr. Abidin ÇALIŞKAN

2024, 71 Pages

Jury

Assoc. Prof. Dr. Abidin ÇALIŞKAN

Assoc. Prof. Dr. Erdal BAŞARAN

Assoc. Prof. Dr. Ömer Ali KARAMAN

This master's thesis examines the use of deep learning methods for the detection of brain tumors. Brain tumors, though relatively rare worldwide, are serious malignancies with high mortality rates. Early diagnosis and accurate classification are crucial in the treatment process. This study evaluates the performance of deep learning methods, particularly convolutional neural networks (CNNs), in detecting and classifying brain tumors. The aim is to detect brain tumors from MRI and CT images using various deep learning models and machine learning algorithms. In this study, deep learning models such as VGG19, Inception V3, and MobileNet, along with machine learning algorithms like K-Nearest Neighbors (K-NN) and Support Vector Machines (SVM), were utilized. Model performances were evaluated using metrics such as accuracy, precision, recall, F1 score, and ROC-AUC. The results indicate that deep learning models offer high accuracy and reliability in detecting brain tumors. Notably, the VGG19 model demonstrated superior performance compared to other models.

These findings suggest that deep learning methods can be an effective tool in medical image analysis and have potential applicability in clinical practice. Future studies may focus on improving performance by using larger datasets and different deep learning models.

Keywords: computed tomography, convolutional neural networks, deep learning, Lung cancer, transfer learning

ÖNSÖZ

Yüksek lisans eğitimim boyunca ve çalışmalarımda beni destekleyen, yönlendiren, fikirleri ile sürekli gelişimimi sağlayan danışmanım Sayın Doç. Dr. Abidin ÇALIŞKAN'a ve çalışmam boyunca beni sürekli destekleyen, maddi ve manevi her türlü konularda bana yardımcı olan eşime ve aileme sonsuz teşekkürler.

Cafer ASLIM
BATMAN- 2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
ŞEKİLLER.....	x
TABLolar.....	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
1.1. Tümör Nedir.....	2
1.2. Tümör Çeşitleri	3
1.2.1 İyi huylu beyin tümörü	4
1.2.2 Kötü huylu beyin tümörü.....	4
1.2.3 Türkiye’de beyin tümörü	5
1.2.4 Beyin tümörünün sınıflandırılması	5
1.2.4.1. Dünya sağlık örgütü (DSÖ) sınıflandırması.....	5
1.2.4.2. Moleküler ve genetik sınıflandırma.....	6
1.2.4.3. Klinik ve radyolojik sınıflandırma	6
1.2.5 Beyin görüntüleme teknikleri	7
1.2.5.1. Bilgisayarlı tomografi.....	7
1.2.5.2. Manyetik rezonans görüntüleme	8
1.2.5.3. Pozitron emisyon tomografi	9
1.2.6 Literatürde yapılan çalışmalar	9
2. MATERYAL VE YÖNTEM.....	16
2.1. Yapay Zekâ	16
2.2. Makine Öğrenmesi	17
2.3. Derin Öğrenme.....	18
2.3.1. Kullanım alanları ve önemi.....	18
2.4. Yapay Sinir Ağları.....	19
2.4.1. Yapay sinir ağı katmanları.....	19
2.4.1.1. Giriş katmanı	19
2.4.1.2. Gizli katmanlar	20
2.4.1.3. Çıkış katmanı.....	20
2.4.2. Kullanım alanları ve önemi.....	21
2.5. Evrimsel Sinir Ağları.....	21
2.5.1. Evrimsel sinir ağları katmanları	22
2.5.2. Evrimsel katmanı.....	22
2.5.3. Havuzlama katmanı	23
2.5.4. Tam bağlantılı katman	23
2.5.5. Seyreltme katmanı	24
2.6. ESA’da eğitiminde kullanılan hiper parametreler.....	24

2.6.1.	Öğrenme oranı	24
2.6.2.	Epoch sayısı	25
2.6.3.	Batch boyutu	26
2.7.	Görüntü Segmantasyonu	26
3.	METODOLOJİ.....	28
3.1.	Veri Seti	28
3.2.	Veri Ön İşleme	28
3.2.1.	Veri temizleme.....	29
3.2.2.	Veri entegrasyonu	30
3.2.3.	Veri dönüşümü.....	30
3.2.4.	Veri azaltma	30
3.2.5.	Veri ayrıştırma	30
3.2.6.	Verilerden öznitelik çıkarma	31
3.2.7.	Ham veri toplama ve inceleme	31
3.2.8.	Özelliklerin seçimi	31
3.2.9.	Özellik dönüşümü	32
3.2.10.	Özellik inşası.....	32
3.2.11.	Özellik seçimi ve doğrulama.....	32
3.3.	Geliştirilen Derin Öğrenme Modelleri	32
3.3.1.	Kullanılan makine öğrenme sınıflandırıcıları	32
3.3.1.1.	k-En yakın komşu.....	32
3.3.1.2.	Destek vektör makineleri (DVM).....	33
3.3.2.	Kullanılan derin öğrenme modelleri	34
3.3.2.1.	VGG19	34
3.3.2.2.	Inception V3	35
3.3.2.3.	MobileNet.....	36
4.	UYGULAMA VE DEĞERLENDİRME.....	38
4.1.	Çalışmada Kullanılan Programlama Dili	38
4.2.	Bu Çalışmada Kullanılan Kütüphaneler.....	38
4.1.1.	NumPy	38
4.1.2.	Pandas	38
4.1.3.	Matplotlib ve seaborn	39
4.1.4.	Scikit-learn.....	39
4.1.5.	TensorFlow ve keras	39
4.3.	Model Performans Metrikleri.....	39
4.3.1.	Doğruluk	40
4.3.2.	Hassasiyet	40
4.3.3.	Duyarlılık	41
4.3.4.	F1 Skoru.....	41
4.3.5.	ROC-AUC	42
5.	BULGULAR VE TARTIŞMA.....	43
5.1.	VGG19	43
5.1.1.	k En yakın komşu sınıflandırma	43
5.1.2.	Destek vektör makineleri	45
5.2.	Inception V3.....	47

5.2.1.	k En yakın komşu sınıflandırma	47
5.2.2.	Destek vektör makineleri	49
5.3.	MobileNet	51
5.3.1.	k En yakın komşu sınıflandırma	52
5.3.2.	Destek vektör makineleri	54
6.	SONUÇ VE ÖNERİLER.....	57
6.1.	Sonuçlar.....	57
6.2.	Öneriler	58
	KAYNAKLAR	59
	ÖZGEÇMİŞ	71

ŞEKİLLER

Şekil 1.1. Beyin tümör tipleri.....	4
Şekil 1.2. BT çalışma mantığı.....	8
Şekil 2.1. Yapay Zekânın kapsamı.....	16
Şekil 2.2. Yapay sinir ağının genel yapısı.....	20
Şekil 2.3. Evrimsel sinir ağlarının yapısı.....	22
Şekil 3.1. veri setinin test, eğitim, doğrulama klasörleri.....	28
Şekil 3.2. Verinin ön işleme aşamaları.....	29
Şekil 3.3. Görüntülerdeki fazlalıkların temizlenmesi.....	29
Şekil 3.4. Verilerdeki orantısızlığın giderilmesi.....	30
Şekil 3.5. Tek görüntüden çeşitli teknikler ile veri artırma.....	31
Şekil 3.6. VGG19 yapısı.....	35
Şekil 3.7. Inception V3'ün yapısı.....	36
Şekil 3.8. Mobilenet Yapısı.....	37
Şekil 5.1. VGG19/K-NN eğitim verisi karmaşıklık tablosu.....	43
Şekil 5.2. VGG19/K-NN doğrulama verisi karmaşıklık tablosu.....	45
Şekil 5.3. VGG19/K-NN verisi verisi karmaşıklık tablosu.....	45
Şekil 5.4. VGG19/DVM eğitim verisi karmaşıklık tablosu.....	46
Şekil 5.5. VGG19/DVM doğrulama verisi karmaşıklık tablosu.....	47
Şekil 5.6. VGG19/DVM test verisi karmaşıklık tablosu.....	47
Şekil 5.7. InceptionV3/K-NN eğitim verisi karmaşıklık tablosu.....	49
Şekil 5.8. InceptionV3/K-NN doğrulama verisi karmaşıklık tablosu.....	49
Şekil 5.9. InceptionV3/K-NN test verisi karmaşıklık tablosu.....	50
Şekil 5.10. InceptionV3/DVM eğitim verisi karmaşıklık tablosu.....	51
Şekil 5.11. InceptionV3/DVM doğrulama verisi karmaşıklık tablosu.....	51
Şekil 5.12. InceptionV3/DVM test verisi karmaşıklık tablosu.....	52
Şekil 5.13. MobileNet/K-NN eğitim verisi karmaşıklık tablosu.....	53
Şekil 5.14. MobileNet/K-NN doğrulama verisi karmaşıklık tablosu.....	54
Şekil 5.15. MobileNet/K-NN test verisi karmaşıklık tablosu.....	54
Şekil 5.16. MobileNet/DVM eğitim verisi karmaşıklık tablosu.....	55
Şekil 5.17. MobileNet/DVM doğrulama verisi karmaşıklık tablosu.....	56
Şekil 5.18. MobileNet/DVM test verisi karmaşıklık tablosu.....	55

TABLolar

Tablo 1.1. Beyin tümörü veri setleri ile yapılan çalışmalar.....	14
Tablo 3.1. Veri Setinin eğitim, doğrulama ve test olarak bölünmesi.....	28
Tablo 5.1. K-NN ile test verisi üzerinde sınıflandırma sonuçları.....	45
Tablo 5.2. DVM ile test verisi üzerinde sınıflandırma sonuçları.....	48
Tablo 5.3. VGG19 ile K-NN /DVM ile sınıflandırma test verisi üzerinde performans sonuçları.....	48
Tablo 5.4. K-NN ile test verisi üzerinde sınıflandırma sonuçları.....	50
Tablo 5.5. DVM ile test verisi üzerinde sınıflandırma sonuçları.....	52
Tablo 5.6. InceptionV3 K-NN /DVM ile sınıflandırma test verisi üzerinde performans sonuçları.....	52
Tablo 5.7. K-NN ile test verisi üzerinde sınıflandırma sonuçları.....	55
Tablo 5.8. DVM ile test verisi üzerinde sınıflandırma sonuçları.....	55
Tablo 5.9. MobileNet ile K-NN /DVM ile sınıflandırma test verisi üzerinde performans sonuçları.	56
Tablo 5.10. Tüm modellerin test verisi üzerinde sınıflandırma sonuçları.....	56

SİMGELER VE KISALTMALAR

- BDT** : Bilgisayar Destekli Tespit
BT : Bilgisayarlı Tomografi
BG : Bilgisayarlı Görü
DDİ : Doğal Dil İşleme
DVM : Destek Vektör Makineleri
DÖ : Derin Öğrenme
ESA : Evrişimsel Sinir Ağı
k-NN : k-En Yakın Komşu
MR : Manyetik Rezonans
MÖ : Makine Öğrenmesi
PET : Pozitron Emisyon Tomografi
RD : Radyo Dalgaları
US : Ultrason
YSA : Yapay Sinir Ağları
YZ : Yapay Zekâ

1. GİRİŞ

Beyin tümörü sınıflandırmasına ilişkin ilk çalışma, 1863 yılında patolog Rudolf Virchow tarafından gerçekleştirilmiştir (Banan ve Hartmann, 2017). Ancak, bu alandaki çalışmalar, başlangıçta sınırlı kalmış veya sonuçsuz kalmıştır. 1952 yılında Dünya Sağlık Örgütü (WHO), Sağlık İstatistikleri Uzmanlar Komitesi bünyesinde bir alt komisyon oluşturarak, tümör sınıflamaları konusunda prensipleri içeren bir yayın yayımlamıştır (Danyeli, 2019).

Beyin tümörleri, maligniteler geliştiğinde ciddi sağlık sorunlarına yol açabilirler. Beyin kanserinin neyin sebep olduğuna dair henüz kesin olarak bilinmemekle beraber, maalesef bu tümörler beyin gibi hayati bir organın içinde konumlandıkları için genellikle yüksek ölüm oranlarına sahiptirler. Dünya genelinde belgelenen tüm malignitelerin sadece %2'sini oluşturan kötü huylu beyin tümörleri, nadir görülmelerine rağmen ciddi tehlike arz ederler (Luo ve ark., 2020).

Beyin Tümörlerinin tanı ve tedavisi son yıllarda, beyin tümörlerinin teşhis ve tedavisinde önemli ilerlemeler kaydedilmiştir. Gelişmiş görüntüleme teknikleri, tümörlerin daha erken ve hassas bir şekilde tespit edilmesine olanak tanımaktadır. Özellikle manyetik rezonans görüntüleme (MRI) ve pozitron emisyon tomografisi (PET) gibi ileri düzey görüntüleme yöntemleri, tümörlerin konumunu ve büyüklüğünü yüksek doğrulukla belirlemektedir (Johnson ve ark., 2021).

Moleküler biyoloji ve genetik alanlarındaki ilerlemeler, tümörlerin biyolojik özelliklerinin daha iyi anlaşılmasını sağlamaktadır. Bu sayede, tümörlerin genetik profilleri çıkarılarak, kişiselleştirilmiş tedavi yaklaşımları geliştirilmektedir. Örneğin, bazı gen mutasyonları belirli beyin tümörü tiplerinde sıkça görülmekte ve bu mutasyonlara yönelik hedefe yönelik tedaviler, hastaların tedaviye yanıtını artırmaktadır (Smith, 2020).

Beyin tümörlerinin tedavisinde cerrahi müdahale, radyoterapi ve kemoterapi gibi yöntemler kullanılmaktadır. Cerrahi müdahale, tümörün mümkün olduğunca çıkarılmasını amaçlarken, radyoterapi ve kemoterapi kalan tümör hücrelerinin yok edilmesine yönelik tedavilerdir. Bunun yanı sıra, immünoterapi ve gen terapisi gibi yeni tedavi yöntemleri de araştırılmakta ve klinik denemelerde uygulanmaktadır (Brown, 2019).

Beyin tümörlerinin tedavisinde multidisipliner bir yaklaşım benimsenmekte, nörologlar, onkologlar, radyologlar ve cerrahlar arasında iş birliği sağlanarak en iyi hasta

sonuçlarına ulaşılmaktadır. Bu iş birliği, her bir uzmanlık alanının bilgi ve deneyiminin bir araya getirilmesiyle, hastaların tedavi süreçlerinin daha etkin ve başarılı bir şekilde yönetilmesini sağlamaktadır (Smith, 2020).

Sağlıktaki tüm bu gelişmelere rağmen, beyin tümörlerinin tamamen tedavi edilmesi hala çok büyük zorluklar içermektedir. Beyin tümörlerinin heterojen yapısı, tedaviye yanıtın öngörülmesini zorlaştırmakta ve nüks olasılığını artırmaktadır. Bu nedenle, beyin tümörlerinin tedavisi ve yönetimi konusunda sürekli araştırma ve yeniliklerin takip edilmesi büyük önem taşımaktadır (Williams, 2018).

Gelecekteki araştırmalar ve yenilikler beyin tümörleri alanında özellikle tümör biyolojisinin daha iyi anlaşılması ve yeni tedavi hedeflerinin belirlenmesi üzerine odaklanacaktır. YZ ve MÖ gibi teknolojiler, büyük veri setleri üzerinden analizler yaparak, tümörlerin tanı ve tedavisinde daha hassas ve etkili yöntemlerin geliştirilmesine katkı sağlayacaktır. Ayrıca, hasta kaynaklı kök hücre modelleri ve organoid teknolojileri, beyin tümörlerinin laboratuvar ortamında incelenmesini ve yeni tedavi yaklaşımlarının test edilmesini mümkün kılacaktır (Kumar, 2021).

Beyin tümörleri, nadir görülmelerine rağmen ciddi sağlık sorunlarına yol açan malignitelerdir. Tarihsel süreçte bu alanda önemli ilerlemeler kaydedilmiş olup, günümüzde gelişmiş tanı ve tedavi yöntemleri sayesinde hastaların yaşam süreleri ve yaşam kaliteleri artırılması amaçlanmaktadır. Ancak, hala çözülemeyen pek çok sorun ve karşılanmamış ihtiyaç bulunmaktadır. Bu nedenle, beyin tümörlerinin tedavisi ve yönetimi konusunda sürekli araştırma ve yeniliklerin takip edilmesi büyük önem taşımaktadır.

1.1. Tümör Nedir

Beyin tümörü, hastanın beyinde veya çevresindeki hücrelerde meydana gelen anormal büyümeler sonucu oluşur ve bu durum nörolojik sistemde aksamalara yol açarak hayatı tehdit edebilir. Uluslararası Kanser Araştırma Ajansı (IARC), beyin tümörlerini tüm kanser ölümleri arasında %2,52 oranıyla 12. sırada değerlendirmektedir. ABD'de kayıt altına alınan beyin tümörü vakası sayısı 700.000'i aşmakta olup, bu vakaların %42'sini erkekler, %58'ini ise kadınlar oluşturmaktadır. Kanada Beyin Tümörü Vakfı'na göre, Kanada'da her gün 27 yeni beyin tümörü vakası teşhis edilmektedir. Bu hastalık; tekrarlayan baş ağrıları, denge ve konuşma bozuklukları, işitme problemleri, kişilik

değişiklikleri, sürekli yorgunluk ve sebepsiz bulantı gibi belirtilerle kendini gösterebilir(Agravad ve ark., 2021).

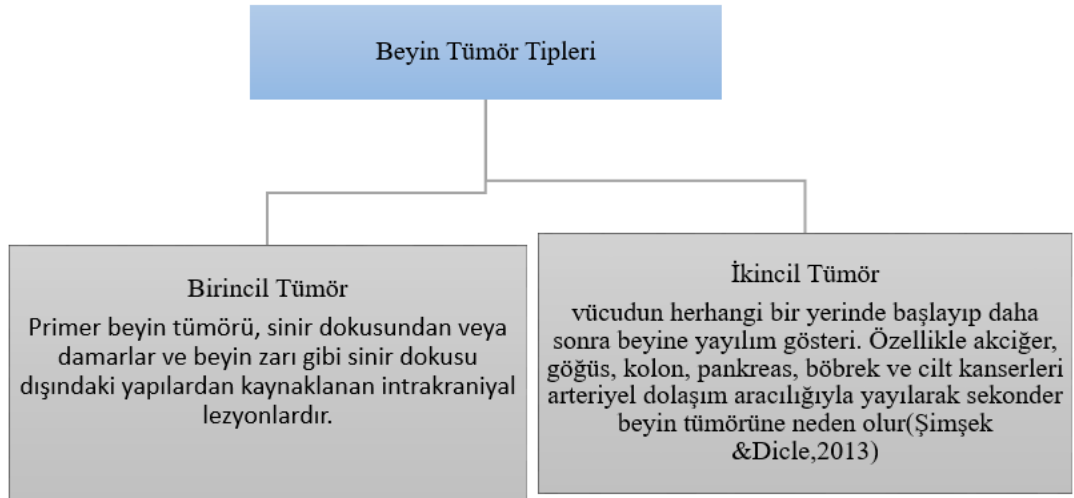
Beyin tümörü teşhis ve tedavisi güç olan bir hastalıktır. Beyin tümörleri çocukluk dönemleri hastalıkları arasında ikinci, 50 yaş sonrası özellikle başka organ kanserlerinin beyine olan yayılımı da göz önüne alındığında üçüncü en çok rastlanılan tümör grubunu oluşturur. Beyin tümürlü hastalarının hayatta kalma süreci ve yaşadıkları rahatsızlığın; etkisi yaşa, performans durumuna, bilişsel duruma; tümör büyüklüğüne ve tipine bağlı olarak değişkenlik göstermektedir(Arzu ve ark., 2010).

1.2. Tümör Çeşitleri

Beyin tümörleri, oluşum yerlerine göre birincil veya ikincil olarak sınıflandırılabilir. Birincil beyin tümörleri doğrudan beyinde başlarken, ikincil beyin tümörleri başka bir vücut bölgesindeki kanserin beyine sıçrama yapması sonucu ortaya çıkar. DNA'da meydana gelen mutasyonlar nedeniyle gelişen beyin tümörleri, kontrolsüz bir şekilde bölünerek anormal hücrelerin sayısının artmasına yol açar. Bu süreç, nörolojik fonksiyonlarda kalıcı hasarlara ve sonunda kişinin yaşamını yitirmesine neden olabilir.

Birincil ve ikincil olarak ayrılan beyin tümörleri hücrelerin yüksek derecede anormal olarak büyümesi ve bölünmesiyle merkezi sinir sistemine hasar verebilir veya işleyişini⁸⁴ bozabilir. Birincil beyin tümörü beyin dokularında yayılma göstermeyip iyi huylu olarak adlandırılırken ikincil beyin tümörü ise meme, akciğer veya vücudun diğer kısımlarındaki kanser hücrelerinin beyine yayılmasıyla oluşur ve kötü huyludur(Erçelik ve Hanbay, 2023)

Beyin tümörleri, hem doğrudan beyin dokusundan kaynaklanan primer tümörler hem de başka bir bölgeden beyne sıçrayan metastatik tümörler, sıkça nöbetlere neden olabilir. Nöbetlerin türü, tümörün bulunduğu yere ve türüne göre değişir. Epilepsi hastalarında beyin tümörlerine rastlanma oranı %4'tür. Beyin tümörü olan hastaların%30–70'i, hastalığın bir döneminde nöbetler yaşar.



Şekil 1.1. Beyin tümör tipleri

Metastatik beyin tümörü olan hastaların yaklaşık %40'ı ise hastalıkları süresince nöbet geçirir. Bu nöbetlerin yarısı basit veya karmaşık parsiyel nöbetlerdir. Basit parsiyel nöbetler, belirli bir beyin bölgesinde başlar ve bilinç kaybına neden olmazken, karmaşık parsiyel nöbetler de belirli bir bölgede başlar ama bilinç kaybına yol açar. Diğer yarısı ise sekonder jeneralize nöbetlerdir, yani beyinde belirli bir noktada başlayıp daha sonra tüm beyne yayılan nöbetlerdir. Status epileptikus (SE), uzun süren veya tekrarlayan nöbetler olarak tanımlanır ve beyin tümörü olan hastalarda da görülebilir(Sünter ve ark., 2019). Beyin tümörleri, iyi huylu veya düşük dereceli (derece I ve II) ve kötü huylu veya yüksek dereceli (derece III ve IV) olarak sınıflandırılır.

1.2.1 İyi huylu beyin tümörü

İyi huylu (benign) beyin tümörlerinde kanserli hücre yoktur: Çoğu ameliyat gibi cerrahi müdahale ile hastadan alınır ve çok nadiren tekrarlarlar. Çok müstesna durumlarda iyi huylu beyin tümörleri, zamanla kötü huylu tümöre dönüşebilir.

İyi huylu tümörler kanserli değildir ve genellikle daha az saldırgan olarak kabul edilirler. Bu tür tümörler beyinden kaynaklanır, yavaş büyürler ve vücudun başka bir bölgesine yayılmazlar(Mohsen ve ark., 2018)

1.2.2 Kötü huylu beyin tümörü

Kötü huylu beyin tümörleri genellikle daha tehlikeli olup, çoğunlukla ciddi hayati tehlike oluşturlar. Kötü huylu tümörler hızla büyüyerek, çevrelerindeki sağlıklı dokulara yayılma eğilimindedirler. Kötü huylu tümörler kanserlidir ve hızla büyüyerek sınırları belirsiz hale gelirler. Kötü huylu tümörler, primer malign tümör olarak beyin kendisinden kaynaklanabilir veya sekonder malign tümör olarak başka bir vücut bölgesinde başlayıp beyne yayılabilirler(Mohsen ve ark., 2018).

1.2.3 Türkiye’de beyin tümörü

Türkiye’de beyin tümörlerinin insidansı hakkında belirli sayısal verilere ulaşmak zor olsa da, Sağlık Bakanlığı'nın 2018 yılında yayınladığı, kanser istatistik raporunda beyin ve sinir sistemi tümörlerinin çeşitli yaş gruplarında görüldüğü belirtilmiştir. Bu raporda, beyin tümörlerinin çocukluk çağında daha sık görüldüğü ve erkeklerde kadınlara oranla biraz daha fazla rastlandığı belirtilmiştir(Sağlık bakanlığı, 2018)

1.2.4 Beyin tümörünün sınıflandırılması

1.2.4.1. Dünya sağlık örgütü (DSÖ) sınıflandırması

Dünya Sağlık Örgütü (WHO), beyin tümörlerini histolojik özelliklerine ve malignite derecelerine göre sınıflandırır. DSÖ'nün 2016 ve 2021 yıllarında güncellediği sınıflandırma sistemi, tümörlerin genetik ve moleküler özelliklerini de dikkate alır.

Histolojik Sınıflandırma: Gliomalar: Astrocytoma, oligodendroglioma ve ependymoma gibi tümörleri içerir. "Gliomalar, beyin tümörlerinin en yaygın türüdür ve merkezi sinir sistemi tümörlerinin yaklaşık %30'unu oluşturur" (Louis ve ark., 2016).

Meningiomalar: Beyin zarlarından (meninks) kaynaklanır. "Meningiomalar genellikle benign tümörler olup, genellikle yavaş büyürler ve cerrahi ile çıkarılabilirler" (Louis ve ark., 2016).

Sinir Kılıfı Tümörleri: Schwannoma ve neurofibroma gibi. "Schwannomalar, genellikle işitme sinirini etkileyen ve işitme kaybına neden olabilen benign tümörlerdir" (Wesseling ve Capper, 2018).

Embriyonel Tümörler: Medulloblastoma gibi çocuklarda sık görülen tümörler. "Medulloblastomalar, çocuklarda görülen en yaygın malign beyin tümörleridir ve genellikle beyincikte yer alırlar" (Louis ve ark., 2016).

Malignite Derecesi:

- Grade I: Benign (iyi huylu) tümörler. "Grade I tümörler, genellikle yavaş büyür ve cerrahi ile tamamen çıkarılabilir" (Louis ve ark., 2016).
- Grade II: Düşük dereceli malign tümörler. "Grade II gliomalar, nispeten yavaş büyüyen ancak zamanla daha malign hale gelebilen tümörlerdir" (Louis ve ark., 2021).
- Grade III: Orta derecede malign tümörler. "Anaplastik gliomalar olarak da bilinen Grade III tümörler, daha hızlı büyüyen ve daha agresif olan tümörlerdir" (Louis ve ark., 2016).
- Grade IV: Yüksek derecede malign ve agresif tümörler (örneğin glioblastoma). "Glioblastomalar, en agresif beyin tümörlerindedir ve genellikle tanı konulduktan sonra hızlı bir şekilde ilerler" (Louis ve ark., 2021).

1.2.4.2. Moleküler ve genetik sınıflandırma

Günümüzde moleküler ve genetik özellikler de beyin tümörlerinin sınıflandırılmasında önemli bir rol oynamaktadır. Bu sınıflandırma, tümörlerin genetik mutasyonları, moleküler belirteçleri ve epigenetik değişikliklerini dikkate alır.

- IDH Mutasyonu: İzositrat dehidrojenaz (IDH) mutasyonu, gliomaların sınıflandırılmasında önemli bir belirleyicidir. "IDH-mutant gliomalar, IDH-wildtype gliomalara göre genellikle daha iyi prognoza sahiptir" (Wesseling ve Capper, 2018).
- 1p/19q Kodeksiyon: Oligodendrogliomaların tanısında kullanılır ve genellikle daha iyi tedavi yanıtı ve prognoz ile ilişkilidir. "1p/19q kodeksiyon varlığı, oligodendrogliomaların kemoterapiye daha iyi yanıt verdiğini göstermektedir" (Louis ve ark., 2021).
- MGMT Metilasyonu: Glioblastomaların tedavi yanıtını ve prognozunu etkileyen bir diğer genetik belirteçtir. "MGMT promotör metilasyonu, temozolomid tedavisine daha iyi yanıt veren glioblastoma hastalarını belirlemede kullanılır" (Wesseling ve Capper, 2018).

1.2.4.3. Klinik ve radyolojik sınıflandırma

Klinik belirtiler ve radyolojik bulgular da beyin tümörlerinin sınıflandırılmasında kullanılır. Görüntüleme teknikleri, tümörün konumunu, boyutunu ve çevre dokularla ilişkisini değerlendirmede yardımcı olur.

Konum: Supratentorial (beynin üst kısmında) ve infratentorial (beynin alt kısmında) olarak sınıflandırılabilir. "Supratentorial tümörler, serebral hemisferlerde yer alırken, infratentorial tümörler beyincik ve beyin sapında bulunur" (Osborn ve Preece, 2006).

Radyolojik Görünüm: MR ve BT görüntülemeleri, tümörlerin heterojen yapısını, kist oluşumunu, nekroz alanlarını ve kontrast tutulumu gibi özellikleri değerlendirmek için kullanılır. "Radyolojik görüntüleme, tümörlerin malignite derecesini ve cerrahi rezeke edilebilirliğini değerlendirmek için kritik öneme sahiptir" (Cha, 2006).

1.2.5 Beyin görüntüleme teknikleri

Beyinde oluşabilecek herhangi bir hasar durumunda o hasarın durumuna göre beyin görüntüleme tekniği kullanılır. Beyin çeperinin zayıflaması, genişlemesi, baloncuk oluşturması ve bu nedenle meydana gelen kanamaların teşhisinde başlıca kullanılan görüntüleme yöntemleri şunlardır: $H^{215}O$ PET beyin anjiyografisi, bilgisayarlı tomografi anjiyografisi (BTA), manyetik rezonans görüntüleme (MRG) ve manyetik rezonans anjiyografi (MRA)(Muir ve ark., 2006).

1.2.5.1. Bilgisayarlı tomografi


Bilgisayarlı tomografinin (BT) geliştirilmesi, radyolojinin evriminde kritik bir dönüm noktasıdır. BT, vücudun içyapılarının detaylı kesit görüntülerini üretmek için bilgisayar teknolojisini kullanır. Bu süreç, radyolojik görüntülemede önemli bir ilerleme sağlamıştır. BT'nin getirdiği yenilik, doktorların hastalıkları daha doğru bir şekilde teşhis etmelerine ve tedavi planlarını daha etkili bir şekilde belirlemelerine olanak tanımıştır. Bu teknoloji, hastaların vücutlarının iç kısımlarını katman katman inceleyerek, daha önce mümkün olmayan detayları görmeyi mümkün kılmıştır. Radyolojinin bu şekilde gelişmesi, modern tıbbın birçok alanında büyük faydalar sağlamıştır.

Bu alanda ilk çalışmaları olan matematikçi J. Radon 1917 yılında objelerin projeksiyonlarının birden çok boyutlu oluşturulabileceğini teorik olarak mümkün olabileceğinin öne sürmüştür. Klinik ortamında ilk BT X-ışını ünitesi 1972 yılında

İngiltere’de G.N. Hounsfield tarafından geliştirilmiştir. Bu dönemlerde BT yardımıyla beynin farklı bölümlerinden çeşitli kesitler alınmış ve anatomik oluşumları görüntüleme teknikleri izlenmiştir(Kahraman, 2010).

BT görüntülemenin arkasındaki temel ilke, hastanın çevresinde tam bir tur dairesel taramayla farklı açılardan alınan iki boyutlu X-ışını projeksiyonlarını kullanılarak görüntü geri çatma algoritmalarıyla kesitsel görüntüleme yapabilmesine dayanmaktadır. Bir BT’nin temel üç bileşeni, düzlemsel röntgen görüntülemeye olduğu gibi X-ışını tüpü, hasta ve bir dedektör sistemidir (Smith ve Webb, 2010).

BT’nin fiziksel yapısının ve çalışma prensibinin farklı perspektiflerden sunulan görselleri şekil 2’te verilmiştir.



Şekil 1.2. BT çalışma mantığı. (a) Görüntüleme tekniği bir dizi tek boyutlu projeksiyonu kaydetmek için X-ışını tüpünün ve çoklu dedektörlerin eşzamanlı ve eşeksenli rotasyonuna dayanmaktadır. (b) Baş/ayak eksenini boyunca masa hareketi nedeniyle, X-ışını demeti hasta etrafında sarmal bir yol izlemektedir((Smith ve Webb, 2010).)

1.2.5.2. Manyetik rezonans görüntüleme

MRG yöntemi çoklu düzlemde görüntüleme kapasitesine sahip, iyonlaştırıcı radyasyon içermeyen, farklı diziler kullanarak lezyonları tespit edip ve tanımlayan bir görüntüleme yöntemidir. Doğru tanı için şüphe edilen hastalığa yönelik uygun protokoller hazırlanması ve lezyonların değişik dizi görünümünün iyi bilinmesi gerekir(Duygu ve Karabulut, 2010).

MRG işlemi sırasında alınan sinyallerin yoğunluğunun doku tipine göre değişmesi ise görüntülemenin temel mantığını oluşturmaktadır. MRG sırasında sürekli hidrojen kullanılmasının sebebi ise, tek proton içermesi ve insan dokularında yoğun olarak

bulunan elementlerdir. Radyo dalgaları (RD) kullanıldığında, hidrojen atomları manyetik alanın etkisiyle düzenli bir şekilde hizalanır. Bu dizilim sırasında elde edilen yoğunluğa göre bilgisayar ortamında görüntü oluşturur(Işık, 2006).

MRG'nin avantajlarından biri, yumuşak doku kontrastını yüksek çözünürlükte sunabilmesidir. Bu, özellikle beyin, kas-iskelet sistemi ve yumuşak dokuların değerlendirilmesinde önemli bir avantaj sağlar. Ayrıca, MRG'nin non-invaziv bir yöntem olması ve tekrarlanabilirliği, hastalıkların takibinde ve tedaviye yanıtın değerlendirilmesinde önemli bir rol oynar (Smith ve ark., 2015).

1.2.5.3. Pozitron emisyon tomografi

Pozitron Emisyon Tomografisi (PET), tıbbi görüntüleme için kullanılan bir nükleer tıp yöntemidir. PET, radyoaktif maddelerin yaydığı pozitronları tespit ederek, vücudun içindeki biyokimyasal ve fizyolojik süreçleri görselleştirir(Turkington, 2001). Bu teknoloji, kanser, kalp hastalıkları ve nörolojik bozuklukların tanı ve tedavisinde yaygın olarak kullanılır (Gambhir, 2002; Bengel, 2011).

PET taramalarında, radyoaktif izotoplar vücuda enjekte edilir ve bu izotoplar pozitron yayar. Pozitronlar, elektronlarla etkileşime girerek gama ışınları oluşturur ve bu ışınlar PET tarayıcısı tarafından tespit edilir (Bailey ve ark., 2005). Bu sayede, hücresel düzeyde metabolik aktiviteler yüksek çözünürlükte görüntülenir (Cherry ve Dahlbom, 2006).

PET'in en büyük avantajlarından biri, kanser hücreleri gibi yüksek metabolik aktiviteye sahip dokuları erken evrede tespit edebilmesidir (Gambhir, 2002). Aynı zamanda, kalp ve beyin hastalıklarının tanı ve takibinde de önemli bir rol oynar (Bengel, 2011; Herholz ve ark., 2007). Ancak, radyoaktif izotopların kullanımı ve yüksek maliyet gibi dezavantajları da bulunmaktadır (Kostakoglu ve Goldsmith, 2003).

Bu üç yöntemin yanında beynin yapısına bağlı yaygın olarak kullanılan başka bilgisayarlı tıbbi teknikler de mevcuttur. Bunlar Difüzyon Manyetik Rezonans Görüntüleme (Difüzyon MRG), Manyetik Rezonans Spektroskopi (MRS), Difüzyon Tensor Görüntüleme (DTI), Magnetoensefalografi (MEG) Single Photon Emission Computed Tomography (SPECT)'dir.

1.2.6 Literatürde yapılan çalışmalar

Vaishnavee ve Amshakala (2015), Çalışmalarında, beyin MRI görüntülerindeki bölgeleri belirlemek için SOM kümeleme yöntemini önerdiler. Segmentasyon aşamasında doğruluğu artırmak için Histogram Eşitleme tekniğini kullandılar. Ardından, Gri Düzey Oluşum Matrisi, segmentasyon sonrasında orta kümelenmiş bölgelerin oluşumunu engellemek için özellik çıkarma işleminde kullanıldı. Öznitelik seçiminde, sınıflandırma doğruluğunu artırmak için PCA yöntemine başvuruldu. Otomatik tümör tespiti için MRI görüntülerinden Proksimal Destek Vektör Makineleri (PDVM) kullanıldı. PDVM, hesaplama açısından daha verimli ve hızlı olduğu için, SOM ile Histogram Eşitleme tarafından modellenen doku sınıflarını tespit etmek için kullanıldı.

Deepak ve Ameer (2015), Çalışmalarında 3 farklı beyin tümörünü DL mimarisi ile sınıflandırmıştır. Çalışmada öncelikle transfer öğrenme yöntemi kullanılmış öznitelikler çıkarılmış, DVM ve k-NN yöntemleri ile sınıflandırılmıştır. ESA, DVM ve k-NN mimarileri ile yüksek doğruluk değerleri %92,3, %97,8 ve %98,0 olarak bulunmuştur.

Cheng ve arkadaşları (2015) beyin tümörünü sınıflandırma amacıyla verileri çoğaltmışlar ve ardından çoğaltılan verileri belli bölgelere ayırmışlardır. Öznitelik çıkarıma sonucu DVM sınıflandırıcısı ile elde edilen doğruluk değerleri %83,54'den %88,19'a yükseltmişlerdir. Veriyi halka-formu ile ayırtırmak ise çalışmanın doğruluğunu %91,28'e yükseltmiştir.

Aslan (2024) Yaptığı çalışmada, manyetik rezonans görüntülerinde beyin tümörlerini otomatik olarak tespit etmek ve sınıflandırmak amacıyla bir ESA-LSTM modeli geliştirilmiştir. Modelin etkinliğini doğrulamak için açık erişimli beyin tümörü MRG veri setleriyle karşılaştırmalar yapılmıştır. Elde edilen doğruluk değeri %98,1 olmuştur.

Abbood ve arkadaşları (2021) Çalışmalarında kullandıkları veri setinin %80 ini eğitim, %10 unu doğrulama ve % 10 unu test için ayırmışlar. Çalışmalarında dört ESA modelini karşılaştırmışlar. VGG16 için %86,4, AlexNet için %82,7, GoogleNet için %91 ve ResNet50 için %95.8 doğruluk değerlerini elde etmişler ve buradan hareketle yüksek doğruluk değerine sahip modelin ResNet50, en hızlı modelin ise AlexNet olduğu sonucunu elde etmişler.

Alnemer ve Rasheed, (2021) beyin tümörü MR görüntüleri üzerinde ESA modellerinden ResNet152V2 i kullanarak iki çalışma gerçekleştirmişlerdir. İlk çalışmada veri seti üzerinde veri artımı yapılmadan %96.47'lik başarı elde edilmiştir. İkinci deneme de ise; veri seti üzerinde veri arttırma yapılmış elde edilen başarı yüzdesi %98,9 olmuştur.

Halimeh ve Teshnehab (2019), beyin tümörleri ve diğer hastalıkları için tespit etmek için MRG kullanımını önermiştir. Beyin tümörü hastalığı, anormal beyin hücrelerinin büyümesi sonucu ortaya çıkar. Multipl skleroz (MS), kronik bir durum olup beyin ve nörolojik sisteme zarar verir. Bu iki durumun MRG kullanılarak tespit ve teşhis edilmesi benzerlikleri nedeniyle, yanlış teşhisler olabilir. Yapılan çalışmada beyin tümörü ve MS aynı anda teşhis etmek için bir ESA kullanmışlardır. Sonuç olarak, bu yöntemle tümör ve MS teşhisinde %96'lık yüksek bir doğruluk elde edilmiştir.

Srinivas ve arkadaşları (2022) beyin tümörü tespiti için yaptıkları çalışmada ESA mimarilerinden olan VGG 16, ResNet50 ve InceptionV3 modellerini kullanmışlardır. Bu çalışmayı 256 beyin MR verisi üzerinde yapmışlardır. Aktivasyon fonksiyonu olarak RELU'yu kullanan yazarlar elde ettikleri başarı oranları sırasıyla, VGG16 %96, InceptionV3 %78 ve ResNet50 %95 olarak kayda geçmişlerdir.

Anitha ve Raja (2017) Çalışmalarında, MR görüntüleri üzerinde sınıflandırmak amacı ile rastgele orman algoritması önermişlerdir. Ön işleme uygulamasından sonra MR görüntülerine uyarılama medyan filtre uygulanmıştır. Bunu uygulamalarının nedeni görüntünün kenarlarını bozmamaktır. Bu işlemden sonra hastalıklı bölge tespit edilip, özellik çıkarımı yapılmıştır. Tümörlü bölgeyi tümörsüz bölgeden ayırmak amacı ile beyin görüntülerinin diğer teknik ile ağırlıklı oylama rastgele algoritması orman kullanılmıştır.

Asif ve arkadaşları (2023) Xception, VGG16, DenseNet201, ResNet152V2, Inception ResNetv2 ESA modellerini karşılaştırmak için 3064 adet MR görüntüsünden oluşan bir veri seti üzerinde RELU aktivasyon fonksiyonunu, ADAM optimizasyon fonksiyonunu ve kategorik çapraz entropi kayıp fonksiyonunu kullanarak sırasıyla modellerde elde ettikleri başarı oranları Xception %91.83, VGG16 %93.54, DenseNet %97.22, Resnet152V2 %95.58, inceptionResNetv2 %95,75 olmuştur.

Amin ve arkadaşları (2020) Yaptıkları çalışmada, beyin tümörlerinin segmente edilmesi ve sınıflandırılması amacıyla otomatik bir sistem önerileri olmuştur. Beynin yoğunluğu, şekli ve dokusal olmak üzere farklı bölümlere ayırdıktan sonra tümörlü ve tümörlü olmayan görüntülerin farklı aşamalarını sınıflandırmak amacıyla Destek Vektör Makinesi (DVM) algoritması uygulanmıştır. Sonuçlar göz önüne alındığında önerilen yaklaşımın tümör tespit etmede oldukça hızlandırdığını göstermiştir.

Uzun ve arkadaşları (2022) Çalışmalarında BRATS 2020 veri seti üzerinde beyin tümörlerinin otomatik segmentasyonu için 512x512 filtre boyutlarına sahip U-Net mimarisi önermişlerdir. U-Net mimarisi görüntüleri hızlı ve hassas bir şekilde bölümlere ayırdığı için tercih edilen bir ESA mimarisidir. Eğitilen model gerekli standart

iyileştirmeler yapılarak test ortamında analiz edilmiştir. Elde edilen sonuçlar, %91,38'lik bir başarı oranı elde etmişlerdir.

Bhagat ve Kaur (2022) yaptıkları çalışmada, daha sağlıklı segmente edilmesi için multimodal bilgilerin daha yeterli bir şekilde kullanılmasını amaçlayan, multimodal MRG'da derin semantik ve kenar bilgilerinin füzyonuna dayanan bir beyin tümörü segmentasyon yöntemi önermişlerdir. Önerilen yöntem temelde semantik segmentasyon modülü, bir kenar algılama modülü ve bir özellik füzyon modülünden oluşmaktadır. Çalışmanın doğruluk oranı %99,24 olarak elde edilmiştir.

Pashaei ve arkadaşları (2018) Yaptıkları çalışmada beyin tümörleri için önerdikleri iki aşamalı yöntemde, önce ESA ile öznitelikleri elde etmişler ardından kernel aşırı öğrenen makineler (KELM: Kernel Extreme Learning Machines) ile tümörleri sınıflandırmışlardır. Çalışmada önerilen yöntemin doğruluk değeri %93,68'dir.

Bhanothu ve arkadaşları (2020) Çalışmalarında tümör bölgelerini tespit etmek ve bunları glioma, menenjiyom ve hipofiz tümörü olmak üzere üç kategoriye ayırmak için Faster R-CNN algoritmasını kullanmışlardır. Hızlı bölgesel ESA (HB-ESA) ağı ile ilgili bölgelere ayrılmış görüntüleri hem tümör bölgeleri tespit edilmiş hem de sınıflandırılmışlardır. Çalışmanın, ortalama kesinlik değeri %77,60 olarak tespit edilmiştir. Kullandıkları ESA yapısında VGG16 ağının ağırlıkları modele transfer edilmiştir.

Kabir (2020) Yaptığı çalışmada bir beyin tümörü tespit etmek için destek vektör makinesi (DVM) algoritması ve yapay sinir ağı temelli algoritmayı önermiştir. Bu algoritmada, gradyan yoğunluğu yumuşatma tabanlı kenar koruma, görüntü geliştirme, DVM tabanlı segmentasyon, öznitelik çıkarma gibi birkaç adımdan ve sınıflandırmadan oluşmaktadır. Kullandığı veri seti üzerinde yaptığı deneysel çalışmalar sonucunda, önerilen algoritmanın %97,7 gibi yüksek bir doğruluk ile diğer algoritmalarından daha iyi performans gösterdiğini ortaya koymuştur.

Havaei ve arkadaşları (2017) Yaptıkları çalışmada Derin Sinir Ağları (DNN, Deep Neural Networks) kullanarak yeni bir model kullanarak tespit çalışmaları yapmışlardır. Kullandıkları veri seti üzerinde başarılı veriler elde etmişlerdir. Önerilen yöntemde tümörün şekli, boyutu ve görüntü özellikleri dikkate alınmadan otomatik bir yöntem geliştirmişlerdir. Modellerin evrişimli doğası ve verimli GPU uygulamasının kullanılması sayesinde ortaya çıkan segmentasyon sistemi çok hızlıdır. Bu CNN mimarilerinden herhangi biriyle bir beynin tamamını segmentlere ayırmak için gereken

süre 25 saniye ile 3 dakika arasında değişen ve bu da onları pratik segmentasyon yöntemleri haline getirmişlerdir.

Arı ve Hanbay (2019) Çalışmalarında, en yaygın algoritmalarından biri olan derin Bölgesel tabanlı evrimsel sinir ağı (BESA) altyapısını kullanarak beyin MRG tümörün tanısını ve yerinin tespit edip uzmanlara karar destek sistemi sağlayan yapı geliştirilmiştir. Bölgesel tabanlı evrimsel sinir ağı, evrimsel sinir ağını esas alan bir yapıdır. Bu yapı, mimarinin giriş görüntüsüne ek olarak tümör çıkarımı yapılan bölgenin de giriş olarak kullanıldığı bir sistem olarak düşünülebilir. Önerilen bu algoritma ile Harvard, Benchmark, Rembrandt veri setleri üzerinde test işlemleri yapılmıştır. Bu test işlemleri sonucunda Benchmark veri seti %99,10 en yüksek doğruluk değeri elde etmişlerdir.

Aqhaei (2022) Yaptığı çalışmada, beyin tümörlerini tespit etmek için genetik ve destek vektör makinesi tekniklerini birleştirerek hibrit bir teknik oluşturmuştur. Araştırmayı Ulusal Kanser Enstitüsü yürüttü ile beraber yürütmüştür. Bu tekniği kullanarak görüntüler bölümlenerek beyin tümörünün kesin tanısına için büyük bir kolaylık sağlamıştır. Yanlış teşhisi önlemek gri tonlama ve medyan filtreler uygulanarak ön işleme tabi tutulmuştur. Görüntü havuzlama yöntemi kullanılarak bölümlere ayrıldıktan sonra genetik özellikler analiz edilmiştir. Daha sonra toplanan verilerden bilgi edinmek ve beyin tümörünü doğru teşhisini sağlamak için DVM algoritması uygulanmıştır. Doğruluk %95, kesinlik %97 ile bulunan değerlerin önerilen yöntemin kayda değerler elden etmiştir.

Lukas ve arkadaşları (2014) Çalışmalarında beyin tümörü teşhisi konulmuş hastaların evrelerini tahmin etmek için beyin tümörü olan hastaların, Doğrusal Ayırma Analizi, Destek Vektör Makineleri tekniği ile LS, RBF çekirdeklerini kullanarak sınıflandırmışlardır. MR Spektroskopinin bütün spektrumunu kullandıkları çalışmalarında Doğrusal Ayırma Analizi (PCA/LDA) tekniğinde %64,69 başarı ile Destek Vektör Makineleri tekniğinin (DVM), LS çekirdeğini kullanarak yaptıkları çalışmada %93,98 başarı ile RBF çekirdeği ile yapılan çalışmada %97,8142 başarı sağlamışlardır.

Arizmendi ve arkadaşları (2014) Çalışmalarında beyin tümörü evresini tahmin etmeye yönelik olarak çalışma yapmıştır. Çalışmalarında MRS spektral görüntüleri kullanılmıştır. Bu çalışmada MRS ile elde edilen metabolit değerleri yerine grafikler kullanılmış ve çalışma Gaussian Ayırması ve Yapay Sinir Ağları teknikleri ile yürütülmüştür. Gaussian Ayırması uygulanarak ilgisi az olan veriler sistemden düşürülmüştür. Çalışmalarında %93,84 ile yüksek bir doğruluk değeri elde edilmiştir.

Kazdal ve arkadaşları (2015) Çalışmalarında MR görüntüleri ile beyin tümörünü ortaya çıkarmaya çalışmışlardır. Yaptıkları çalışmada tümörün yapısal ve biçimsel özellikler ile kural tabanlı bir tespit sistemi öne sürmüşler. Görüntüleri sırasıyla ön işleme, bölütleme, ilgili alanları belirleme ve son olarak tümörün tespit edilmesi adımı gerçekleştirilmişler. Çalışma kullandıkları veri setinde 10 hastaya ait 497 beyin MR görüntüsü kullanılmış ve %84,26'lık bir başarı yüzdesi elde edilmiştir.

Almadhoun ve Abu-Naser (2022) Çalışmalarında on bin adet MR verisi kullanmışlardır. Veri seti eğitim, doğrulama ve test verisi olarak bölmüşler. Tümörlü görüntüler tüm bölümlerde yer almıştır. Çalışmalarında kullandıkları görüntüleri 200x200 boyutlarında ön işleme tabi tutarak kullanmışlar. Bu verileri tasarladıkları 12 katmanlı bir modelde eğitilmişler. Dört farklı ESA modelini kullanmışlardır. Kullandıkları mimariler elde ettikleri başarı oranları sırasıyla şu şekilde olmuştur. VGG16 ile %99, MobileNet ile %88,98, ResNet50 ile %98,14, InceptionV3 ile %99,88'lik gibi yüksek bir başarı oranı yakalamışlar.

Bu tez çalışmasında, Python programlama dili yardımıyla Tensorflow kütüphanesi kullanarak transfer öğrenme yöntemi ile ESA yardımıyla ağ eğitimi VGG19, Inception V3 ve MobileNet derin öğrenme mimari kullanılarak gerçekleştirilmiştir. ESA modeli oluşturularak, bu modelin beyin tümörü veri setleri üzerindeki başarısı ve performansı değerlendirilmiştir.

Tablo 1.1. Beyin tümörü veri setleri ile yapılan çalışmalar

Çalışma	Kullanılan Model/Sınıflandırma	Doğruluk Oranı
Amin ve ark., (2018)	Derin Konvolüsyonel Sinir Ağları	%92.50
Çınar ve Yıldırım (2020)	Hibrit Konvolüsyonel Sinir Ağı Mimarisi	%90.30
Dong ve ark., (2017)	U-Net Tabanlı Tamamen Konvolüsyonel Ağlar	%87.20
Şeker (2020)	Transfer Öğrenme (InceptionV3, VGG16)	%89.50
Wu ve ark., (2007)	Renk Tabanlı K-means Kümeleme Segmentasyonu	%85.60
Chandra ve Rao (2016)	Genetik Algoritma	%88.00
Bingol ve Alatas (2021)	AlexNet, GoogLeNet, ResNet50	%85.71 (ResNet50)
Nanda ve ark., (2023)	Saliency-K-means Segmentasyon ile SSO-RBNN	%93.20
Demir ve ark., (2022)	R-CNN Modeli ve LINSR Özellik Seçimi	%91.70
Asif ve ark., (2022)	Derin Transfer Öğrenme Modelleri	%94.50
Alnabhan ve ark., (2022)	EVO Tekniği ile Hyper-Tuned CNN	%90.80

Mahmud ve ark., 2020	CNN, ResNet-50, VGG16, Inception V3	93.3% (CNN)
ZainEldin ve ark., 2020	Adaptive Dynamic Sine-Cosine Fitness Grey Wolf Optimizer	99.98%
Musallam ve ark., 2020	DCNN	97.72%
Wozniak ve ark., 2020	Correlation Learning Technique (CLM)	96%
Garg ve ark., 2020	Çeşitli ML Modelleri	97.305%
Ranjbarzadeh ve ark., 2021	Hybrid CNN-SVM	%97,5
Pareek ve ark., 2020	KSVM	97%
Stadlbauer ve ark., 2020	Dokuz farklı ML modeli	98.95%
Srikanth ve ark., 2020	VGG-16	%98
Rezai ve ark., 2020	ResNet-34	%96,9
Sachdeva ve ark., 2020	RezNet	%95,2
Ahmet ve ark., 2020	Hybrid deep learning	%96,4
Waghmare	CNN	%98,51
Abdar ve ark.,	Two-stage deep learning	%98,2
Bu çalışma	VGG19/K-NN	%84.83
	VGG19/DVM	%84.83
	MobileNet/DVM	%78,17
	MobileNet/K-NN	%78,17
	Incepiton/DVM	%75,83
	Incepiton/K-NN	%79,0

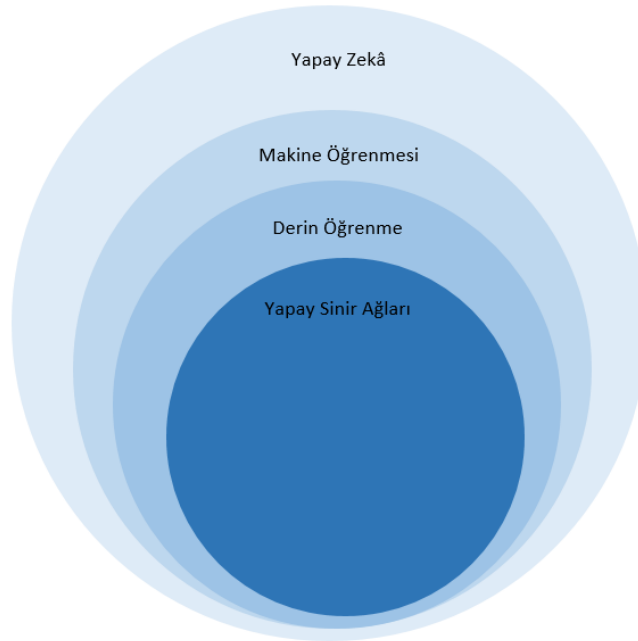
2. MATERYAL VE YÖNTEM

2.1. Yapay Zekâ

Yapay zekâ(YZ), bilgisayar sistemlerinin insan benzeri zekâ davranışlarını sergilemesini sağlayan bir alandır ve problem çözme, öğrenme, dil anlama gibi görevleri içerir (Russell ve Norvig, 2020). 1950'lerde Alan Turing'in "Turing Testi" ile başlayan YZ çalışmaları, 1956'da Dartmouth Konferansı'nda John McCarthy ve diğer öncüler tarafından bağımsız bir araştırma alanı olarak tanıtıldı.

Bu dönemde, Newell ve Simon'ın "Logic Theorist" gibi programları, YZ problem çözme yeteneklerini gösterdi. Ancak, 1970'ler ve 1980'lerde yaşanan "YZ kışı" olarak bilinen duraklama dönemi, yüksek beklentilerin karşılanmaması ve sınırlı hesaplama kaynakları nedeniyle bu alanda araştırmalarda yavaşlamaya yol açtı (Crevier, 1993).

1990'lardan itibaren hesaplama gücündeki artış ve büyük veri setlerinin kullanımı, makine öğrenme ve DÖ alanlarında önemli gelişmeler sağladı, bu da YZ geniş çapta benimsenmesine yol açtı (Goodfellow ve ark., 2016).



Şekil 2.3. Yapay zekânın kapsamı

YZ, modern dünyada büyük bir öneme sahiptir çünkü pek çok alanda devrim niteliğinde değişiklikler yapmaktadır. Sağlık sektöründe, YZ tabanlı sistemler

hastalıkların erken teşhisi ve tedavi planlamasında kullanılmakta, bu sayede hasta sonuçları iyileşmektedir (Topol, 2019). Ekonomide, YZ, verimliliği artırarak ve maliyetleri düşürerek işletmelerin rekabet gücünü artırmaktadır (Brynjolfsson ve McAfee, 2014).

Eğitim alanında, kişiselleştirilmiş öğrenme deneyimleri sunarak öğrencilerin bireysel ihtiyaçlarına daha iyi cevap vermektedir (Luckin ve ark., 2016). Ayrıca, yapay zekanın çevresel izleme ve yönetim sistemlerinde kullanımı, iklim değişikliği ile mücadelede önemli katkılar sağlamaktadır (Rolnick ve ark., 2019).

Sonuç olarak, YZ, yaşam kalitesini artırma, ekonomik büyümeyi teşvik etme ve küresel sorunlara çözümler sunma potansiyeliyle, geleceğin en kritik teknolojilerinden biri olarak kabul edilmektedir.

2.2. Makine Öğrenmesi

Makine öğrenmesi(MÖ), bilgisayar sistemlerinin açıkça programlanmadan verilerden öğrenmesini ve bu öğrendiklerini gelecekteki görevlerde uygulamasını sağlayan bir YZ dalıdır (Mitchell, 1997).

1950'lerde Alan Turing'in çalışmaları ve 1959'da Arthur Samuel'in dama oynayan programı ile temelleri atılan MÖ, Samuel'in "makine öğrenmesi" terimini ortaya atmasıyla önemli bir ivme kazandı (Samuel, 1959).

1960'lar ve 1970'lerde öğrenme teorisi ve istatistiksel yöntemlerin gelişimi ile teorik temelleri güçlenen bu alan, 1980'lerde karar ağaçları, yapay sinir ağları ve genetik algoritmalar gibi tekniklerin popüler hale gelmesiyle daha da ilerledi (Quinlan, 1986).

1990'larda hesaplama gücündeki artış ve veri miktarındaki büyüme, destek vektör makineleri ve Bayes ağları gibi yöntemlerin geliştirilmesine olanak tanıyarak MÖ'nün yeniden canlanmasına vesile oldu(Vapnik, 1995).

2000'lerin başlarından itibaren, DÖ teknikleri, özellikle büyük veri setleri ve güçlü GPU'lar sayesinde önemli ilerlemeler kaydetti ve derin sinir ağları, görüntü ve ses tanıma gibi birçok alanda üstün performans sergiledi (Hinton ve ark., 2006).

MÖ, sağlık alanında hastalık teşhisi, kişiselleştirilmiş tedavi, tıbbi görüntü analizi, elektronik sağlık kayıtları (EHR) ve ilaç keşfi gibi birçok önemli uygulamaya sahiptir. Bu teknoloji, kanser ve diyabet gibi hastalıkların erken teşhisine yardımcı olur, genetik analizler yoluyla bireysel tedavi planları oluşturur ve tıbbi görüntüleri analiz ederek doktorların teşhis koyma sürecini hızlandırır. Ayrıca, EHR verilerini analiz ederek hasta

bakımını iyileştirir ve yeni ilaçların keşfi ve geliştirilmesinde rol oynar. Makine öğrenmesi, büyük veri setlerini analiz ederek sağlık hizmetlerinin doğruluğunu ve verimliliğini artırmakta önemli katkılar sağlar (Esteva ve ark., 2017; Topol, 2019; Litjens ve ark., 2017; Miotto ve ark., 2016; Chen ve ark., 2018).

2.3. Derin Öğrenme

Derin öğrenme (DÖ), MÖ bir alt dalıdır ve çok katmanlı YSA kullanarak karmaşık veri yapılarını modelleme ve öğrenme yeteneğine sahiptir. İnsan beyninin işleyişine benzer şekilde, bu sinir ağları büyük miktarda veriyi analiz eder ve desenleri tanıır. DÖ, özellikle büyük veri (big data) ve yüksek hesaplama gücü gerektiren uygulamalarda önemli başarılar elde etmiştir (LeCun ve ark., 2015).

DÖ, görüntü ve ses tanıma gibi alanlarda insan performansını aşan sonuçlar elde etmiştir. DÖ algoritmaları, büyük veri kümeleri üzerinde çalışarak öğrenme ve sınıflandırma işlemlerini otomatikleştirir ve bu süreçte insan müdahalesine gerek kalmaz. Örneğin, bir yüz tanıma görevinde, derin öğrenme algoritmaları çeşitli katmanlarda kenarları, yüz parçalarını ve nihayetinde tüm yüzleri tanıyarak yüksek doğrulukta sınıflandırma yapabilir (Goodfellow ve ark., 2016).

DÖ algoritmalarının başarısı, büyük ölçüde büyük veri kümeleri ve yüksek hesaplama gücü sayesinde mümkün olmuştur. Bu algoritmalar, yüksek boyutlu veriler üzerinde çalışarak karmaşık desenleri ve ilişkileri ortaya çıkarabilir ve bu sayede daha genel ve dayanıklı modeller oluşturabilir. DÖ, birçok endüstri ve bilim dalında devrim niteliğinde değişikliklere yol açmıştır ve halen gelişimini sürdürmektedir (Krizhevsky ve ark., 2012).

2.3.1. Kullanım alanları ve önemi

- **Sağlık Sektörü:** DÖ, tıbbi teşhis ve tedavi süreçlerinde önemli bir rol oynamaktadır. Örneğin, DÖ algoritmaları, tıbbi görüntülerdeki anomalileri tespit etmede insan uzmanlara göre daha yüksek doğruluk oranları sağlayabilmektedir (Litjens ve ark., 2017). Bu teknolojinin uygulanması, erken teşhis ve tedavi süreçlerinde büyük avantajlar sağlamaktadır.
- **Görüntü Tanıma:** Bilgisayarlı görü alanında DÖ, nesne tanıma ve görüntü sınıflandırma gibi görevlerde üstün performans göstermektedir. Özellikle, 2012

yılında AlexNet'in ImageNet yarışmasında birinci olması, bu teknolojinin potansiyelini geniş kitlelere göstermiştir (Krizhevsky ve ark., 2012).

- **Doğal Dil İşleme:** Doğal dil işleme (NLP) uygulamalarında da DÖ büyük ilerlemeler kaydetmiştir. Metin sınıflandırma, dil modeli oluşturma ve duygu analizi gibi görevlerde DÖ algoritmaları, insan benzeri performans sergileyebilmekte ve dilin karmaşıklığını anlayabilmektedir (Young ve ark., 2018).
- **Otonom Araçlar:** Otonom sürüş teknolojilerinde DÖ, çevresel algılama ve karar verme süreçlerinde kritik bir rol oynamaktadır. DÖ algoritmaları, çevresel verileri işleyerek nesnelere tanıyabilir ve bu bilgileri güvenli sürüş kararları almak için kullanabilir (Bojarski ve ark., 2016).
- **Finans ve İş Dünyası:** Finansal analiz, kredi riski değerlendirme ve ticaret stratejileri geliştirme gibi finansal uygulamalarda DÖ önemli avantajlar sağlamaktadır. Büyük veri kümelerini analiz ederek trendleri ve anormallikleri tespit edebilir, bu da daha iyi yatırım ve iş stratejileri geliştirilmesine olanak tanır (Heaton ve ark., 2017).

2.4. Yapay Sinir Ağları

Yapay sinir ağları (YSA), biyolojik sinir ağlarından esinlenerek geliştirilmiş bilgi işlem sistemleridir. Bu ağlar, birbirine bağlı yapay nöronlardan oluşur ve öğrenme süreci boyunca veriler arasındaki ilişkileri tanımlamak için tasarlanmıştır. YSA, verileri katmanlar aracılığıyla işleyerek karmaşık desenleri ve ilişkileri öğrenir.

Temel yapısı, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her bir katman, önceki katmandan gelen verileri işler ve bir sonraki katmana aktarır (Heaton ve ark., 2017; Krizhevsky ve ark., 2012).

2.4.1. Yapay sinir ağı katmanları

YSA, farklı görevleri yerine getiren katmanlar halinde düzenlenmiştir. Her katman, veri işleme ve öğrenme sürecinde belirli bir rol oynar. İşte YSA 'nın temel katmanları ve görevleri:

2.4.1.1. Giriş katmanı

Fonksiyonu: Giriş katmanı, ağıın aldığı ham verileri temsil eder. Her bir nöron, modelin öğrenmesi gereken özelliklere karşılık gelir.

Özellikleri: Bu katmanda, sinir ağıının dış dünyadan aldığı tüm girdiler yer alır. Görüntü işleme uygulamalarında bu, her pikselin bir nörona karşılık gelmesi anlamına gelir (LeCun ve ark., 2015).

2.4.1.2. Gizli katmanlar

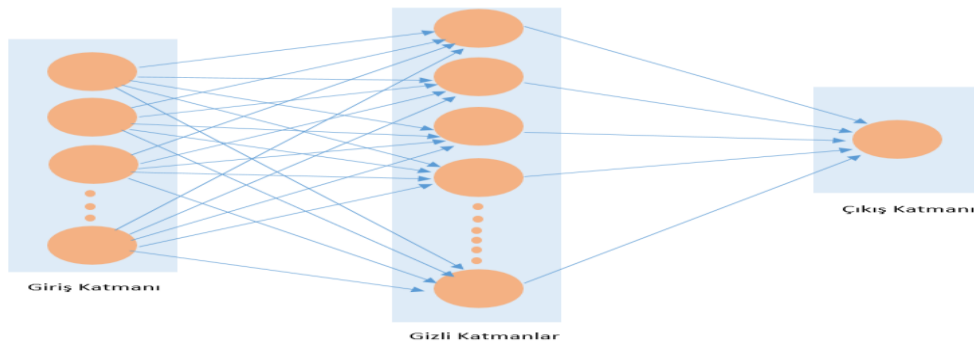
Fonksiyonu: Gizli katmanlar, girdilerin işlenmesi ve karmaşık desenlerin öğrenilmesi görevini üstlenir. Bu katmanlarda, veriler çeşitli ağırlıklar ve aktivasyon fonksiyonları kullanılarak işlenir.

Özellikleri: Bir yapay sinir ağı, bir veya daha fazla gizli katmana sahip olabilir. Her nöron, önceki katmandaki tüm nöronlarla bağlantılıdır ve bu bağlantılar, öğrenme sürecinde ayarlanır. Yaygın aktivasyon fonksiyonları arasında sigmoid, tanh ve ReLU bulunur (Goodfellow ve ark., 2016)

2.4.1.3. Çıkış katmanı

Fonksiyonu: Çıkış katmanı, ağıın sonucunu verir. Çıkış, ağıın çözmesi gereken probleme bağlı olarak yapılandırılır; örneğin, bir sınıflandırma probleminde her sınıf için bir nöron bulunur.

Özellikleri: Bu katman, modelin nihai kararını veya tahminini temsil eder. Çıkış katmanı genellikle softmax veya sigmoid gibi aktivasyon fonksiyonları kullanır, bu da sınıflandırma veya regresyon problemlerine uygun sonuçlar sağlar (Murphy, 2012).



Şekil 2.4. Yapay sinir ağıının genel yapısı

2.4.2. Kullanım alanları ve önemi

YSA'nın kullanım alanları oldukça geniştir ve birçok sektörde önemli yenilikler getirmiştir.

- **Sağlık Sektörü:** YSA, tıbbi teşhis ve görüntü analizi gibi alanlarda önemli işlere imza atmaktadır. Özellikle, tıbbi görüntülerin analizi ve hastalık teşhisi gibi görevlerde yüksek doğruluk oranları sağlayabilir. Örneğin, sinir ağları, röntgen, MRI ve BT taramaları gibi tıbbi görüntülerde anormallikleri tespit etmede kullanılmaktadır (Litjens ve ark., 2017).
- **Finans ve İş Dünyası:** Finansal analiz ve piyasa tahmini gibi uygulamalarda da YSA büyük önem taşır. Sinir ağları, büyük veri kümelerini analiz ederek trendleri ve anormallikleri tespit edebilir, bu da yatırım kararlarını daha güvenilir hale getirir. Örneğin, borsa tahmini ve kredi riski değerlendirme gibi alanlarda kullanılır (Heaton, ve ark., 2017).
- **Görüntü Tanıma:** Bilgisayarlı görü (BG) alanında, YSA nesne tanıma ve görüntü sınıflandırma görevlerinde üstün performans göstermektedir. Özellikle DÖ teknikleri ile birlikte kullanıldığında, sinir ağları görüntü işleme görevlerinde insan performansına yakın sonuçlar verebilir (Krizhevsky ve ark., 2012).
- **Doğal Dil İşleme:** DDİ uygulamalarında da YSA önemli bir rol oynar. Metin sınıflandırma, dil modeli oluşturma ve duygu analizi gibi görevlerde sinir ağları, dilin karmaşıklığını ve bağlamını anlamada büyük avantajlar sağlar (Young ve ark., 2018).
- **Otonom Sistemler:** Otonom araçlar ve robotik sistemlerde YSA, çevresel algılama ve karar verme süreçlerinde kritik bir rol oynamaktadır. Bu sistemler, çevresel verileri işleyerek nesnelere tanıyabilir ve güvenli sürüş kararları alabilir (Bojarski ve ark., 2016).

2.5. Evrişimsel Sinir Ağları


DÖ mimarilerinden biri olan Evrişimli Sinir Ağı (ESA), çok katmanlı ileri yönlü bir yapay sinir ağıdır. Bu yapay sinir ağının en önemli özelliğinden biri diğer ağ modellerine göre daha az eğitime ve daha az parametreyle işlem yapabilmesidir. ESA, verilen görüntü üzerinde nesne tanıma, görüntü analizi ve doğal dil işleme gibi birçok çalışmada kullanılmaktadır. Doğal dil ifadelerden metin analizi, cümle analizi ve bunların

sınıflandırılması gibi çalışmalar ESA bu alandaki uygulanabilirliğini ortaya koymaktadır(Somuncu ve Atasoy,2022).

ESA, görüntü ve video işleme gibi yüksek boyutlu verilerin kullanımında veya analizinde tercih edilen bir DÖ modelleme türüdür. ESA'ları, verilerdeki uzamsal hiyerarşileri ve örüntüleri otomatik olarak öğrenmek için evrişim (convolution) işlemleri kullanır. Bu ağlar, katmanlar halinde düzenlenmiş olup her katman belirli bir işlevi yerine getirir.

2.5.1. Evrişimsel sinir ağları katmanları

ESA'lar görüntü ve video işleme gibi yüksek boyutlu verilerin analizinde kullanılan DÖ modellerinin bir türüdür. ESA'lar, verilerdeki uzamsal hiyerarşileri ve örüntüleri otomatik olarak öğrenmek için evrişim (convolution) işlemleri kullanır. Bu ağlar, Şekil 5'te görüldüğü gibi katmanlar halinde düzenlenmiş olup her katman belirli bir işlevi yerine getirir.



Şekil 2.5. Evrişimsel sinir ağlarının yapısı

2.5.2. Evrişim katmanı

Evrişim Katmanı, ESA içinde kritik bir bileşendir ve verilerdeki yerel özellikleri çıkarmak için kullanılır. Bu katman, çeşitli filtreler (kerneller) kullanarak giriş verisi üzerinde kaydırma (convolution) işlemi gerçekleştirir. Bu işlem sonucunda, verideki belirli desenleri ve özellikleri tespit eden özellik haritaları (feature maps) oluşturulur.

Özellik haritalarına uygulanan aktivasyon fonksiyonları, modelin doğrusal olmayan ilişkileri öğrenmesine olanak tanır, bu da özellikle görüntü işleme ve BG uygulamalarında önemlidir.

Evrişim katmanları, nesne tanıma ve yüz tanıma gibi alanlarda yüksek doğruluk oranlarına ulaşılmasını sağlar, çünkü verideki yerel özellikleri etkili bir şekilde çıkarır ve işler (Goodfellow ve ark., 2016; Krizhevsky ve ark.,2012; LeCun ve ark., 2015; Scherer v ve ark., 2010).

2.5.3. Havuzlama katmanı

Havuzlama Katmanı (Pooling Layer), ESA içinde yer alan ve özellik haritalarının boyutunu küçültme amacıyla için kullanılan bir ara katmandır. Bu katman, verinin uzamsal boyutlarını azaltarak modelin hesaplama yükünü düşürmeyi amaçlar ve genelleştirme yeteneğini artırır. İki yaygın havuzlama türü vardır: Maksimum Havuzlama (Max Pooling) ve Ortalama Havuzlama (Average Pooling).

Maksimum havuzlama, belirli bir bölgedeki en yüksek değerli pikseli seçerken, ortalama havuzlama, bölgedeki tüm piksel değerlerinin ortalamasını alır. Bu işlemler, modelin daha küçük ve daha anlamlı temsilciler oluşturmasına yardımcı olur (Goodfellow ve ark., 2016; Scherer ve ark., 2010). Ayrıca, havuzlama katmanları, ağıın konum değişikliklerine karşı duyarlılığını azaltarak, nesne tanıma ve görüntü sınıflandırma gibi görevlerde performansı artırır (LeCun ve ark., 2015).

2.5.4. Tam bağlantılı katman

Tam Bağlantılı Katman (Fully Connected Layer), ESA ve diğer YSA'da yer alan ve tüm nöronların birbirine bağlı olduğu bir katmandır. Bu katman, özellik haritalarından gelen verileri düzleştirir ve bu verileri sınıflandırma veya regresyon görevleri için kullanır.

Tam bağlantılı katmanlar, her nöronun önceki katmandaki tüm nöronlarla bağlantılı olduğu bir yapıya sahiptir ve bu, ağıın öğrenme kapasitesini artırır (Goodfellow, ve ark., 2016). Ayrıca, bu katmanlar genellikle ağıın sonuna eklenir ve son sınıflandırma veya karar verme aşamasında önemli bir rol oynar (Krizhevsky ve ark., 2012).

Tam bağlantılı katmanlar, özellikle karmaşık karar sınırlarının öğrenilmesinde ve temsil gücünün artırılmasında etkilidir (LeCun ve ark., 2015).

2.5.5. Seyreltme katmanı

YSA'nın eğitim sürecinde aşırı öğrenmeyi (overfitting) önlemek için kullanılan bir düzenleme tekniğidir. Bu katman, her eğitim iterasyonunda rastgele seçilen nöronların belirli bir oranını geçici olarak devre dışı bırakır (Seyreltir), böylece ağıın belirli nöronlara aşırı bağımlılığını azaltır ve daha genel bir model öğrenilmesini sağlar. Bu teknik, ağıın öğrenme sürecinde nöronların birbirine bağımlılığını azaltarak, modelin daha iyi genelleme yapabilmesine olanak tanır (Srivastava ve ark., 2014).

Seyreltme katmanının etkisi, ağıın farklı alt kümelerinin eğitilmesiyle çeşitliliği artırması ve sonuç olarak modelin daha dayanıklı ve genelleştirilebilir olmasını sağlamasıdır (Goodfellow ve ark.,2016).

2.6. ESA'da eğitiminde kullanılan hiper parametreler

ESA eğitiminde kullanılan hiperparametreler, eğitilen modelin performansını optimize etmek ve eğitim sürecini kontrol etmek için hayati önem taşır. Bu hiperparametreler, modelin öğrenme sürecini, doğruluğunu ve genelleme yeteneğini doğrudan etkiler. Model eğitilirken kullanılan bazı yaygın hiperparametreler ve bunların kullanılma nedenleri ve önemi aşağıda açıklanmıştır.

2.6.1. Öğrenme oranı

Öğrenme oranı bir YSA modelinin eğitim sürecinde kullanılan en önemli hiperparametrelerden biridir. Modelin ağırlıklarının her güncelleme adımında ne derecede değişeceğini belirle amacı ile kullanılır. Öğrenme oranı, genellikle η (eta) (eta) sembolü ile gösterilir ve öğrenme sürecinde gradyan inişi algoritmasının hızını kontrol eder. Öğrenme oranı küçükse, model daha yavaş öğrenir; büyükse, model daha hızlı öğrenir, ancak bu durumda optimal çözüme ulaşamama veya dengesiz öğrenme riski artar (Goodfellow ve ark., 2016).

Gradyan inişi algoritması, maliyet fonksiyonunun türevini kullanarak modelin ağırlıklarını günceller. Her iterasyon adımında ağırlıklar şu şekilde güncellenir (2.1).

$$W_{t+1} = W_{t-\eta} \cdot \Delta J(W_t) \quad (2.1)$$

Burada:

W_t : t zamanındaki ağırlıklar

η : Öğrenme oranı

$\nabla J(W_t)$: Ağırlıklar için maliyet fonksiyonunun gradyanı

Optimal Çözüm: Uygun bir öğrenme oranı, modelin hızlı ve doğru bir şekilde öğrenmesini sağlar. Yanlış ayarlanmış bir öğrenme oranı, modelin ya çok yavaş öğrenmesine ya da hiç öğrenmemesine de neden olabilir.

Stabilite: Doğru bir öğrenme oranı, modelin eğitim sürecini kararlı hale getirir. Çok yüksek bir öğrenme oranı, modelin ağırlıklarının optimal olmayan değerlere zıplamasına neden olabilir (Sutskever ve ark., 2013).

Eğitim Süresi: Öğrenme oranı, eğitim süresini doğrudan etkiler. Daha yüksek öğrenme oranları, daha hızlı eğitim sağlar ancak genellikle daha düşük doğruluk ve stabilite ile sonuçlanır.

2.6.2. Epoch sayısı

Epoch sayısı, bir MÖ modelinin eğitim sürecinde, tüm eğitim veri setinin model tarafından kaç kez işlenebileceği adımdır. Programcı veri setinin kaç tur işlenmesini isterse o sayı da tur attırır. Bir epoch, veri setinin baştan sona bir kez geçirilmesini temsil eder. Eğitim sürecinde genellikle birden fazla epoch kullanılır, bu da modelin veri setindeki tüm desenleri öğrenmesine yardımcı olur.

- **Öğrenme Süreci:** Epoch sayısı, modelin tüm veri seti üzerinde ne kadar süreyle eğitim göreceğini belirler. Yeterli sayıda epoch, modelin veri setindeki tüm desenleri öğrenmesini sağlar.
- **Aşırı Uyum (Overfitting) ve Eksik Uyum (Underfitting):** Çok az epoch sayısı eksik uyuma neden olabilirken, çok fazla epoch sayısı aşırı uyum riskini artırabilir. Doğru epoch sayısı, modelin genel performansını optimize etmede en uygun yoldur. (Goodfellow ve ark., 2016).
- **Eğitim Süresi ve Maliyet:** Daha fazla epoch, daha uzun eğitim süresi ve daha fazla hesaplama kaynağı anlamına gelir. Bu nedenle, uygun epoch sayısının belirlenmesi, verimli bir eğitim süreci için en önemli detaydır (Bengio, 2012).

2.6.3. Batch boyutu

Batch boyutu, MÖ modelinin eğitim sürecinde, modelin ağırlıklarını güncellemek için kullanılan veri örneklerinin sayısını ifade eder. Eğitim veri seti genellikle daha küçük parçalara (batch'lere) bölünür ve her bir batch, model tarafından işlenir. Bu süreç, modelin öğrenme sürecini hızlandırır ve daha verimli hale getirir.

Batch boyutu, modelin ağırlıklarının her iterasyon sonunda güncellenmesini sağlar ve mini-batch, stochastic, batch gradient descent gibi çeşitli türlerde uygulanabilir. Mini-batch gradient descent en yaygın kullanılan yöntemdir ve genellikle 32, 64 veya 128 gibi boyutlar kullanılır. Stochastic gradient descent'te batch boyutu 1'dir ve her veri örneği için ağırlıklar güncellenir, bu yöntem daha fazla varyans içerir ancak genelleştirme performansı açısından faydalı olabilir (Bottou, 2010).

Batch gradient descent ise tüm veri seti üzerinde hesaplama yapar ve büyük veri setlerinde pratik değildir (Ruder, 2016). Batch boyutunun uygun seçimi, eğitim süresi, bellek kullanımı ve modelin genelleştirme performansı üzerinde önemli bir etkiye sahiptir (Keskar ve ark., 2016).

Eğitim sırasında, modelin ağırlıkları şu şekilde güncellenir:

$$W_{t+1} = W_t - \eta \cdot \nabla J(W_t) \quad (2.2)$$

Burada:

W_t : t zamanındaki ağırlıklar

η : Öğrenme oranı

$\nabla J(W_t)$: Ağırlıklar için maliyet fonksiyonunun gradyanı

2.7. Görüntü Segmentasyonu

Görüntü segmentasyonu, dijital görüntülerin analiz edilmesinde ve işlenmesinde kullanılan yaygın bir tekniktir. Bu yöntem, bir görüntüyü, daha anlamlı ve kolay analiz edilebilir parçalara veya segmentlere bölmeyi amaçlar. Segmentasyon, her bir pikselin belirli bir nesneye veya sınıfa ait olduğu şekilde görüntüyü bölerek gerçekleştirilir. Bu


işlem, nesnelere arka plandan ayırmak, nesne sınırlarını belirlemek ve görüntüdeki belirli bölgeleri tanımlamak için kullanılır. Segmentasyon, tıbbi görüntüleme, otonom araçlar, uydu görüntüleri analizi ve yüz tanıma sistemleri gibi birçok alanda kritik bir rol oynar (Shen ve ark., 2017).

Tıbbi görüntüleme, MR ve BT taramaları gibi tıbbi görüntülerde tümör veya anormal yapıların tespiti ve sınıflandırılması için kullanılır (Ronneberger ve ark.,2015). Otonom araçlar, yol, yaya, araç ve trafik işaretlerinin tanımlanması ve izlenmesi için segmentasyon tekniklerini kullanır (Chen ve ark., 2018). Görüntü segmentasyonu, kenar tespiti, kümeleme ve DÖ tabanlı yöntemler gibi çeşitli teknikler kullanılarak gerçekleştirilebilir. Özellikle ESA gibi DÖ modelleri, segmentasyon görevlerinde yüksek doğruluk ve etkinlik sağlar (Long ve ark., 2015).

3. METODOLOJİ

3.1. Veri Seti

Bu veri kümesi, beyin tümörlerinin tespit edilmesi amacıyla MÖ modellerini geliştirmeyi kolaylaştırmak için hazırlanmıştır. Beynin MR taramalarını içeren bu veri seti, üç ana klasöre ayrılmıştır.



Şekil 3.1. veri setinin test, eğitim, doğrulama klasörleri

Birinci klasör olan "evet", tümör bulunan MR taramalarını içerir. İkinci klasör olan "hayır", tümör bulunmayan MR taramalarını barındırır. Üçüncü klasör olan "pred" ise, test amaçlı etiketlenmemiş MR taramalarını içermektedir. Bu veri kümesi, MÖ modellerinin eğitim ve değerlendirme süreçlerinde kullanılmak üzere düzenlenmiştir.

Tablo 3.1. Veri Setinin eğitim, doğrulama ve test olarak bölünmesi

Veri Seti	Evet	Hayır
Eğitim Veri Seti	900	900
Doğrulama Veri Seti	300	300
Test Veri Seti	300	300

3.2. Veri Ön İşleme

Veri ön işleme, MÖ ve veri madenciliği projelerinde ham verilerin analiz için uygun hale getirilmesi için gerekli olan bir dizi işlem sürecidir. Bu süreç, verinin kalitesini artırmayı ve modelin performansını iyileştirmeyi amaçlar.



Şekil 3.2. Verinin ön işleme aşamaları


Veri ön işleme, ham verilerin gürültüsüz, eksiksiz ve analiz edilebilir bir forma dönüştürülmesini sağlar (Han ve ark., 2012).

Veri ön işlemenin temel adımları şunlardır:

3.2.1. Veri temizleme

Eksik verilerin işlenmesi: Eksik değerler, veri setinden çıkarılabilir, ortalama veya medyan gibi özet istatistiklerle doldurulabilir ya da tahmin yöntemleriyle tamamlanabilir (Little ve Rubin, 2019).

- **Gürültülü verilerin düzeltilmesi:** Anormal veya yanlış veri noktaları tespit edilerek düzeltilir ya da çıkarılır.
- **Tutarsız verilerin düzeltilmesi:** Veri tutarsızlıkları, mantıksal kurallar veya alan bilgisi kullanılarak düzeltilir.




Şekil 3.3. Görüntülerdeki fazlalıkların temizlenmesi

3.2.2. Veri entegrasyonu

Farklı kaynaklardan gelen verilerin birleştirilmesi: Veri entegrasyonu, farklı veri kaynaklarından gelen verileri arasındaki uyumsuzluğun kaldırılması beraber işlenebilir hale getirilerek tek bir veri setinde birleştirilmesi sürecidir (Chaudhuri ve ark., 2011).

3.2.3. Veri dönüşümü

Normalizasyon: Verilerin belirli bir ölçek veya aralıkta normalize edilmesi, özellikle MÖ algoritmalarında önemlidir.



Şekil 3.4. Verilerdeki orantısızlığın giderilmesi

Özellik mühendisliği: Verilerden yeni özellikler türetme veya mevcut özellikleri dönüştürme sürecidir (Guyon ve Elisseeff, 2003).

3.2.4. Veri azaltma

- **Öznitelik seçimi:** Modelin performansını artırmak ve hesaplama maliyetlerini azaltmak için gereksiz veya fazla özelliklerin çıkarılması işlemidir.
- **Örnekleme:** Büyük veri setlerinde, veriyi temsil eden küçük bir alt kümenin seçilmesini anlatır.

3.2.5. Veri ayrıştırma

Sürekli verilerin kategorik verilere dönüştürülmesi: Özellikle karar ağaçları gibi algoritmalar için sürekli verilerin belirli aralıklara ayrılması gerekebilir (Fayyad ve Irani, 1993).

Veri ön işlemenin bu adımları, analiz ve modelleme süreçlerinin temelini oluşturur ve daha doğru, güvenilir ve geliştirilebilir sonuçlar elde edilmesini sağlama açısından çok büyük önem arz etmektedir.


3.2.6. Verilerden öznitelik çıkarma

Öznitelik çıkarma (feature extraction) süreci, ham verilerden anlamlı ve kullanılabilir özniteliklerin elde edilmesi işlemi kapsar. Bu süreç, MÖ modellerinin performansını artırmak için kritik bir önem taşımaktadır. Öznitelik çıkarma aşamaları genellikle aşağıdaki adımlardan oluşur.

3.2.7. Ham veri toplama ve inceleme

İlk adım, ham verilerin toplanması ve veri setinin anlaşılmasıdır. Verilerin yapısı, formatı ve içeriği incelenir. Bu aşamada, verilerin hangi özellikleri içerdiği ve hangi özelliklerin çıkarılması gerektiği belirlenir (Guyon ve Elisseeff, 2003).

Artırılmış Görüntüler



Şekil 3.5. Tek görüntüden çeşitli teknikler ile veri artırma

3.2.8. Özelliklerin seçimi

Tüm mevcut özellikler arasından en anlamlı ve modelin performansını en çok artıracak olanların seçilmesi sürecidir. Bu aşama, gereksiz veya fazla bilgi taşıyan

özelliklerin çıkarılmasını içerir. İstatistiksel testler, bilgi kazancı, Gini katsayısı gibi yöntemler kullanılabilir (Liu ve Motoda, 2007).

3.2.9. Özellik dönüşümü

Ham verilerden yeni özellikler oluşturma veya mevcut özellikleri daha uygun bir forma dönüştürme sürecidir. Bu aşamada, ölçekleme (normalization), standartlaştırma (standardization), polinomal özellikler çıkarma ve log dönüşümleri gibi teknikler kullanılabilir (Jain ve ark., 2000).

3.2.10. Özellik inşası

Verilerden yeni öznitelikler türetme sürecidir. Örneğin, tarih ve zaman verilerinden gün, hafta veya ay bilgileri çıkarılabilir. Bu aşama, özellikle karmaşık ve yüksek boyutlu veri setlerinde önemlidir (Zheng ve Padmanabhan, 2006).

3.2.11. Özellik seçimi ve doğrulama

Çıkarılan özelliklerin doğruluğunu ve model performansına katkısını değerlendirme aşamasıdır. Bu aşamada çapraz doğrulama (cross-validation) ve çeşitli değerlendirme metrikleri kullanılarak, en iyi performansı sağlayan özellikler belirlenir (Kohavi ve John, 1997).

3.3. Geliştirilen Derin Öğrenme Modelleri

3.3.1. Kullanılan makine öğrenme sınıflandırıcıları

3.3.1.1. k-En yakın komşu

K en yakın komşu (K-NN) sınıflandırma, makine öğreniminde hem sınıflandırma hem de regresyon problemleri için kullanılan temel bir gözetimli öğrenme algoritmasıdır. Bu algoritma, yeni bir veri noktasının sınıfını belirlemek için en yakın k komşunun sınıflarını dikkate alır. Genellikle Öklidyen mesafe gibi bir uzaklık metriği kullanarak komşuları belirler ve sınıflandırma için çoğunluğun sınıfı yeni veri noktasına atanır (Cover ve Hart, 1967).

K-NN algoritmasının avantajlarından biri, parametrik olmaması ve bu sayede veri dağılımına herhangi bir ön kabulde bulunmamasıdır. Ancak, algoritmanın performansı, komşu sayısı k ve seçilen uzaklık metriğine oldukça duyarlıdır. Küçük k değerleri modelin varyansını artırırken, büyük k değerleri modelin biasını artırabilir. Ayrıca, yüksek boyutlu veri kümelerinde hesaplama maliyeti artar ve performans düşebilir, bu durum “curse of dimensionality” olarak bilinir. Yine de, K-NN küçük ve iyi ayrılmış veri kümelerinde yüksek doğruluk sağlar ve uygulaması kolaydır (Peterson, 2009).

K-NN 'nin bir diğer önemli özelliği de öğrenme sürecinin hızlı olmasıdır çünkü model parametreleri öğrenmez; bunun yerine tüm eğitim verilerini saklar ve tahmin aşamasında bu verilere dayanarak karar verir. Bu özelliği, özellikle büyük veri setlerinde tahmin yapmayı hesaplama açısından pahalı hale getirebilir (Fix ve Hodges, 1951).

K-NN algoritması, yeni bir veri noktasının sınıfını belirlemek için en yakın k komşusunu kullanır. En yaygın mesafe metriği Öklidyen mesafedir ve iki nokta arasındaki Öklidyen mesafeyi hesaplamak için kullanılan formül şu şekildedir:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.1)$$

Burada:

$d(x, y)$: İki veri noktası arasındaki mesafe

x_i ve y_i : Veri noktalarının i . bileşenleri

n : Özelliklerin sayısı

3.3.1.2. Destek vektör makineleri (DVM)

Destek Vektör Makineleri (DVM), makine öğreniminde hem sınıflandırma hem de regresyon analizinde kullanılan güçlü bir algoritmadır. DVM, veriyi yüksek boyutlu bir uzaya projeler ve bu uzayda iki sınıfı en iyi ayıran hiper düzlemi bulur. Bu hiper düzlem, sınıflar arasındaki marjini maksimize eder. Destek vektörleri, karar sınırını tanımlayan bu hiper düzleme en yakın veri noktalarıdır (Cortes ve Vapnik, 1995).

DVM'nin önemli bir avantajı, yüksek boyutlu veri kümeleriyle başa çıkabilmesidir. Ayrıca, lineer olarak ayrılabilir olmayan veriler için çekirdek hileleri (kernel tricks) kullanarak karmaşık karar sınırları oluşturabilir.

Yaygın olarak kullanılan çekirdek fonksiyonları arasında doğrusal, polinomial, radyal bazlı fonksiyon (RBF) ve sigmoid bulunur. Bu çekirdek fonksiyonlar, veriyi daha yüksek boyutlara dönüştürerek daha iyi ayırıcı hiper düzlemler bulunmasını sağlar (Schölkopf ve Smola, 2002).

DVM, aşırı öğrenmeyi önleme konusunda da oldukça etkilidir. Bunun nedeni, karar sınırının sadece birkaç kritik veri noktası tarafından belirlenmesi ve bu sayede modelin genel kalıpları öğrenmesi, aşırı detaylara takılmamasıdır. Ancak, DVM'nin eğitim süreci büyük veri setlerinde ve özellikle çekirdek hilelerinin kullanıldığı durumlarda oldukça zaman alıcı olabilir (Burges, 1998).

DVM, iki sınıfı ayıran en geniş marjlı hiper düzlemi bulmaya çalışır. Bu hiper düzlem, aşağıdaki optimizasyon problemi ile tanımlanır.

$$\min_{w,b} \frac{1}{2} \|w\|^2 \text{ subject to } y_i(w \cdot x_i + b) \geq 1, \forall i \quad (3.2)$$

Burada:

w : Hiper düzlemin ağırlık vektörü.

b : Hiper düzlemin bias terimi.

x_i : Eğitim veri noktası.

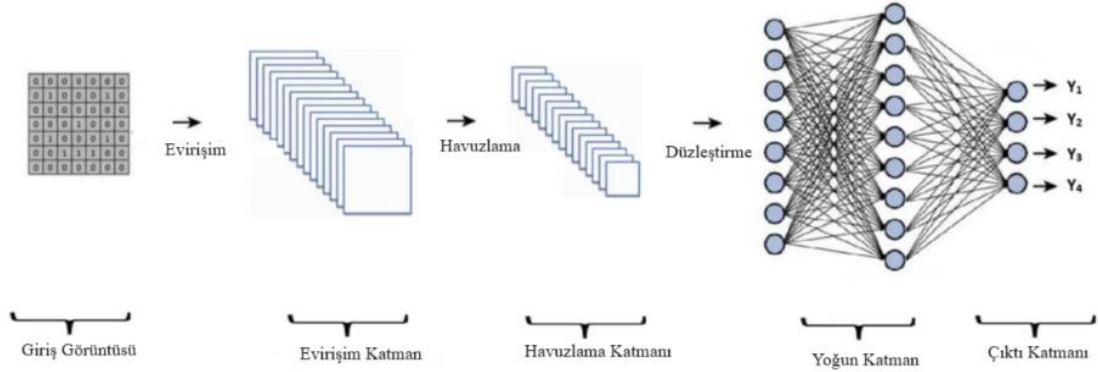
y_i : Veri noktasının etiketi (+ veya -1).

$\|w\|^2$: Hiper düzlemin normu, yani ağırlık vektörünün karesi.

3.3.2. Kullanılan derin öğrenme modelleri

3.3.2.1. VGG19

VGG19, Oxford Üniversitesi Görsel Geometri Grubu tarafından geliştirilen ve DÖ alanında yaygın olarak kullanılan bir konvolüsyonel sinir ağı modelidir. Model, toplamda 19 katmandan oluşur; bunlar arasında 16 konvolüsyonel katman, 3 tam bağlantılı katman ve 5 maks havuzlama katmanı bulunmaktadır.



Şekil 3.6. VGG19 yapısı


VGG19'un en belirgin özellikleri, küçük 3x3 filtre boyutları ve her katmandan sonra uygulanan ReLU aktivasyon fonksiyonlarıdır. Bu mimari, büyük veri setlerinde (örneğin, ImageNet) yüksek doğruluk oranları sağlar ve önceden eğitilmiş ağırlıklarla transfer öğrenme için oldukça uygundur (Simonyan ve Zisserman, 2014). Ancak, derin yapısı ve çok sayıda parametresi nedeniyle yüksek hesaplama gücü ve bellek gereksinimi doğurur, bu da eğitimin yavaşlamasına ve aşırı uyum riskine yol açabilir (Deng ve ark., 2009). Bu nedenle, büyük veri setleri ve düzenleme teknikleri kullanılarak eğitilmesi önerilir.

VGG19'un derinliği, görüntü sınıflandırma ve nesne tanıma görevlerinde üstün performans göstermesini sağlar, ancak bu aynı zamanda modelin eğitimi sırasında yüksek hesaplama kaynakları gerektirmesi anlamına gelir. Ek olarak, derin ağ yapısı nedeniyle model, parametre sayısının fazla olması sebebiyle aşırı uyuma meyilli olabilir (Krizhevsky ve ark., 2012). VGG19, genellikle ince ayar (fine-tuning) için güçlü bir başlangıç noktası olarak kullanılır ve tıbbi görüntü işleme gibi spesifik alanlarda yaygın olarak uygulanmaktadır (Shen ve ark., 2017).

3.3.2.2. Inception V3

Inception V3, Google tarafından geliştirilen bir DÖ modeli olup, görüntü sınıflandırma ve nesne tanıma görevlerinde yüksek doğruluk sağlamak amacıyla tasarlanmıştır. Bu model, Inception mimarisinin üçüncü versiyonudur ve 48 katmandan oluşur. Inception V3'ün temel avantajları arasında daha düşük hesaplama maliyeti ile yüksek doğruluk sağlama yeteneği bulunmaktadır. Bunun nedeni, modelin, bilgi yoğunluğu düşük olan özellik haritalarının hesaplama maliyetini azaltmak amacıyla tasarlanmış olmasıdır (Szegedy ve ark., 2016).

Inception V3'ün yapısı, farklı boyutlardaki filtreleri paralel olarak uygulayarak özelliklerin daha zengin bir temsilini elde etmeyi amaçlayan Inception modüllerine dayanır. Bu modüller, modelin derinliğini artırmadan daha geniş bir yapıya sahip olmasını sağlar, bu da hesaplama verimliliğini artırır ve aşırı uyum riskini azaltır (Szegedy ve ark., 2016). Model ayrıca, hesaplama yükünü daha da düşürmek için faktörizasyon tekniklerini ve etiketli verilerin daha verimli kullanılmasını sağlamak amacıyla yardım eden ek düzenleme katmanlarını içerir.



Şekil 3.7. Inception V3'ün yapısı(Kaya ve ark., 2024)


Inception V3'ün bazı dezavantajları da vardır; Modelin karmaşık yapısı, hiperparametre ayarlamalarını ve eğitimi zorlaştırabilir. Ayrıca, büyük veri kümeleri üzerinde eğitilmesi gerektiği için yüksek bellek ve işlem gücü gerektirir (Szegedy ve ark., 2016). Bu nedenle, modelin eğitim süreci uzun olabilir ve yüksek performanslı donanım gerektirir. Bununla birlikte, önceden eğitilmiş ağırlıklarla transfer öğrenme kullanarak bu zorluklar bir ölçüde hafifletilmesi mümkündür, bu da modelin farklı uygulama alanlarında kullanılabilirliğini artırır (Canziani ve ark., 2016).

3.3.2.3.MobileNet

MobileNet, Google tarafından geliştirilen ve mobil cihazlarda ve gömülü uygulamalarda kullanılmak üzere optimize edilmiş hafif bir ESA mimarisidir. Temel amacı, hesaplama ve bellek gereksinimlerini en aza indirerek hızlı ve verimli DÖ modelleri oluşturmaktır. MobileNet mimarisi, derin ayırık konvolüsyonları (depthwise separable convolutions) kullanarak standart konvolüsyonların hesaplama yükünü önemli ölçüde azaltır.

Bu teknik, her bir konvolüsyonu iki aşamaya ayırır: derin ayırık konvolüsyonlar ve nokta konvolüsyonları (pointwise convolutions). Bu yapı, modelin parametre sayısını ve hesaplama maliyetini büyük ölçüde azaltır (Howard ve ark., 2017).

MobileNet'in düşük hesaplama ve bellek gereksinimleri, hızlı sonuç elde süresi ve mobil ve gömülü cihazlar için uygunluk bulunur. Bu özellikler, MobileNet'i sınırlı kaynaklara sahip cihazlarda bile yüksek doğruluk oranları elde etmeye uygun hale getirir. Ayrıca, modelin modüler yapısı, çeşitli görevler ve uygulamalar için kolayca uyarlanabilir ve genişletilebilir olmasını sağlar (Howard ve ark., 2017).



Şekil 3.8. Mobilenet Yapısı

MobileNet'in bazı dezavantajları da vardır. Modelin hesaplama verimliliği sağlama amacıyla yaptığı optimizasyonlar, bazı görevlerde doğruluk kaybına yol açabilir. Ayrıca, daha derin ve geniş ağlarla karşılaştırıldığında, özellikle çok karmaşık veri setlerinde performansının biraz daha düşük olabileceği gözlemlenmiştir (Sandler ve ark., 2018).

MobileNet'in yapısı, temel olarak mobil cihazlarda kullanım için optimize edilmiş, hafif ve modüler bir mimari olarak özetlenebilir. Bu model, mobil uygulamalarda görüntü sınıflandırma, nesne tespiti ve benzeri görevlerde yaygın olarak kullanılır ve yüksek doğrulukla birlikte hızlı performans sunar (Howard ve ark., 2017; Sandler ve ark., 2018).

4. UYGULAMA VE DEĞERLENDİRME

4.1. Çalışmada Kullanılan Programlama Dili

Bu çalışmada, veri analizi ve model geliştirme için akademik çalışmalarda yaygın olarak kullanılan Python programlama dili tercih edilmiştir. Python, zengin kütüphane desteği yanında geniş topluluk kaynakları sayesinde MÖ ve DÖ projeleri için ideal bir araç olarak tercih edilmiştir (Van Rossum ve ark., 2009).

Python, açık kaynak kodlu ve yüksek seviyeli bir programlama dilidir. Kolay okunabilir söz dizimi ve geniş kütüphane desteği ile veri bilimi ve MÖ projelerinde yaygın olarak tercih edilir (Lutz, 2013).

Bu çalışmada, Python'un özellikle veri işleme, görselleştirme ve model geliştirme süreçlerinde sunduğu esneklikten yararlanılmıştır. Kullanılan çevrimiçi ortamlar kodların yazılması ve çalıştırılması için Kaggle platformu kullanılmıştır.

Kaggle, veri bilimi ve makine öğrenimi yarışmaları, veri setleri ve kod paylaşımı için popüler bir çevrimiçi platformdur. Bu platform, kullanıcıların Python ve R gibi programlama dillerini kullanarak analizler yapmalarına olanak tanır (Kaggle, 2021).

4.2. Bu Çalışmada Kullanılan Kütüphaneler

4.1.1. NumPy

NumPy, bilimsel hesaplamalar için kullanılan ve Python dilinde yazılmış bir kütüphanedir. Büyük boyutlu diziler ve matrislerle etkin bir şekilde çalışabilmesi ile tanınır. NumPy, bu veri yapılarına hızlı ve verimli matematiksel işlemler yapma yeteneği sunan çeşitli fonksiyonlar sağlar. Kütüphanenin en önemli veri yapılarından biri olan ndarray, yüksek performanslı veri işleme ve hesaplama için optimize edilmiştir (Oliphant, 2006).

NumPy, veri analizi, makine öğrenimi ve derin öğrenme gibi alanlarda yaygın olarak kullanılmakta ve diğer birçok bilimsel kütüphanenin temelini oluşturmaktadır (Harris ve ark., 2020).

4.1.2. Pandas

Pandas, veri manipülasyonu ve analizi için güçlü araçlar sunan bir Python kütüphanesidir. DataFrame ve Series gibi veri yapıları, veriyi temizleme, verileri dönüştürme ve veriyi görselleştirme işlemlerini kolaylaştırır (McKinney, 2010). Pandas, veri biliminde yaygın olarak kullanılır ve veri yükleme, filtreleme, gruplama, birleştirme ve yeniden şekillendirme gibi işlemler için zengin fonksiyonlar sunar.

4.1.3. Matplotlib ve seaborn

Matplotlib, Python için temel grafik çizim kütüphanesidir ve veri görselleştirme için geniş kapsamlı araçlar sunar. Çizgi grafikleri, çubuk grafikleri, histogramlar ve saçılım grafikleri gibi çeşitli grafik türlerini oluşturmak için kullanılır (Hunter, 2007).

Seaborn, Matplotlib'in üstüne inşa edilmiş ve istatistiksel veri görselleştirme için daha çekici ve bilgilendirici grafikler sunmayı hedefleyen bir kütüphanedir (Waskom, 2021).

4.1.4. Scikit-learn

Scikit-Learn, Python programlama dili için geliştirilmiş, açık kaynaklı bir makine öğrenimi kütüphanesidir. Bu kütüphane, sınıflandırma, regresyon, kümeleme ve boyut indirgeme gibi makine öğrenimi görevleri için geniş bir araç seti sunar. Scikit-Learn, basit ve tutarlı bir API tasarımı ile kullanım kolaylığı sağlar ve NumPy ile iyi entegrasyon sunar (Pedregosa ve ark., 2011).

4.1.5. TensorFlow ve keras

TensorFlow, Google Brain ekibi tarafından geliştirilen ve MÖ ile derin öğrenme modelleri oluşturmak için kullanılan açık kaynaklı bir yazılım kütüphanesidir. Keras ise, TensorFlow üzerinde çalışan, kullanımı kolay bir yüksek seviyeli DÖ kütüphanesidir. Keras, hızlı model prototipleri geliştirme, kolay okunabilirlik ve modülerlik özellikleri ile öne çıkar (Chollet, 2015).

4.3. Model Performans Metrikleri

Çalışmanın bu bölümünde, sınıflandırma algoritmalarının performansının değerlendirilmesi için sınıfların gerçek ve tahmini değerlerinin karışıklık matrisi ile karşılaştırıldığı bölümdür (Polat ve ark., 2017). Alıcı işletim karakteristiği (ROC), sınıflandırma performansının ölçülmesinde biyoinformatikte sıkça kullanılan bir yöntemdir (Lasko ve ark., 2005).

- **Doğru Pozitif :** Pozitif olan bir örneğin doğru sınıflandırılmasıdır (örneğin, hasta olan bir kişiye hasta demek) (Hastie ve ark., 2009).
- **Doğru Negatif:** Negatif olan bir örneğin doğru sınıflandırılmasıdır (örneğin, hasta olmayan bir kişiye hasta değil demek) (Hastie ve ark., 2009).
- **Yanlış Pozitif:** Negatif olan bir örneğin yanlış sınıflandırılmasıdır (örneğin, hasta olmayan bir kişiye hasta demek) (Hastie ve ark., 2009).
- **Yanlış Negatif:** Pozitif olan bir örneğin yanlış sınıflandırılmasıdır (örneğin, hasta olan bir kişiye hasta değil demek) (Hastie ve ark., 2009).

Veri setindeki tüm örneklerin sınıf etiketlerinin sınıflandırılması için algoritmanın performans değerlendirmesi doğruluk oranı (accuracy) ile ölçülür. Doğruluk oranı, doğru olarak sınıflandırılan örneklerin yüzdesi olarak ifade edilir.

4.3.1. Doğruluk

Doğruluk, bir modelin toplam doğru tahmin sayısının toplam tahmin sayısına oranını ifade eder (1)'de gösterilen formül ile hesaplanır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+TN+FN} \quad (4.1)$$

Bu metrik, modelin genel performansını değerlendirirken kullanılır ve hem pozitif hem de negatif sınıfların doğru şekilde tahmin edilmesini içerir. Doğruluk, tüm sınıflar arasında dengeli bir dağılım varsa etkili bir metrik olabilir, ancak dengesiz veri kümelerinde yanıltıcı olabilir çünkü nadir sınıfların doğru tahmin edilmesi genel doğruluk üzerinde büyük bir etkiye sahip olmayabilir (Powers, 2011).

4.3.2. Hassasiyet

Hassasiyet, modelin pozitif olarak tahmin ettiği örneklerin kaç tanesinin gerçekten pozitif olduğunu gösterir. Yani, pozitif olarak tahmin edilen örnekler içinde gerçekte pozitif olanların oranını ifade eder(4.2).

$$Hassasiyet = \frac{TP}{TP+FP} \quad (4.2)$$

Bu metrik, özellikle yanlış pozitiflerin maliyetinin yüksek olduğu durumlarda önemlidir. Örneğin, tıbbi teşhislerde yanlış pozitiflerin sayısının düşük olması isteniyorsa, hassasiyet önemli bir değerlendirme kriteri olacaktır (Sokolova ve Lapalme, 2009).

4.3.3. Duyarlılık

Duyarlılık, gerçek pozitif örneklerin model tarafından doğru bir şekilde pozitif olarak tahmin edilme oranını gösterir. Yani gerçekte pozitif olan örneklerin ne kadarının doğru pozitif olarak tahmin edildiğini gösterir (4.3).

$$Duyarlılık = \frac{TP}{TP+FN} \quad (4.3)$$

Bu metrik, pozitif örneklerin ne kadarının doğru tahmin edildiğini ölçer ve özellikle yanlış negatiflerin maliyetinin yüksek olduğu durumlarda önemlidir. Tıbbi teşhislerde, hastaların hastalığını kaçırmamak için duyarlılığın yüksek olması arzu edilir (Davis ve Goadrich, 2006).

4.3.4. F1 Skoru

F1 skoru, hassasiyet ve duyarlılığın harmonik ortalamasını temsil eder ve bu iki metriğin dengeli bir değerlendirmesini sağlar(4.4).

$$F1 Skoru = 2 * \frac{Duyarlilik * Kesinlik}{Duyarlilik + Kesinlik} \quad (4.4)$$

F1 skoru, özellikle sınıflar arasında dengesizlik olduğunda, hem yanlış pozitifleri hem de yanlış negatifleri dikkate alarak model performansını ölçer. Yüksek bir F1 skoru, modelin hem yüksek hassasiyet hem de yüksek duyarlılığa sahip olduğunu gösterir (Chinchor, 1992).

4.3.5. ROC-AUC

ROC-AUC (Alıcı İşletim Karakteristiği eğrisinin altındaki alan), bir modelin sınıflandırma performansını değerlendirmek için kullanılan bir metrik olup, duyarlılık ve 1-spesifiklik (yanlış pozitif oranı) arasındaki ilişkiyi gösterir (4.5).

$$AUC = \int_0^1 TPR(t) dFPR(t) \quad (4.5)$$

ROC eğrisi, modelin çeşitli eşik değerlerindeki performansını gösterir ve AUC (eğri altındaki alan), modelin ayırt edici yeteneğini özetler. Yüksek bir AUC değeri, modelin pozitif ve negatif sınıfları iyi ayırt edebildiğini gösterir (Fawcett, 2006).

5. BULGULAR VE TARTIŞMA

5.1. VGG19

K-NN ve DVM sınıflandırma ile VGG19 modelinden elde edilen özelliklerle eğitilmesi ve test edilmesi sonucu elde edilen performans metriklerini karşılaştırarak, her bir modelin performansına dair detaylı bir analiz tablolar ile gösterilmiştir.

5.1.1. k En yakın komşu sınıflandırma

Eğitim Verisi: K-NN modelinin doğruluk oranı %87.22 olarak hesaplanmıştır. Bu, modelin eğitim verileri üzerinde oldukça iyi performans gösterdiğini, ancak doğrulama ve test setlerinde biraz daha düşük performans gösterebileceğini işaret eder.


Gerçek Sınıflar	Hayır	871	29
	Evet	201	699
		Tahmin Edilen Sınıflar	

Şekil 5.1. VGG19/K-NN eğitim verisi karmaşıklık matrisi

K-NN modelinde 0 (Hayır) ve 1 (Evet) sınıfları için yanlış pozitif ve yanlış negatif oranları bulunmaktadır. Özellikle 201 yanlış negatif tahmini modelin sınırlamalarını göstermektedir.

Doğrulama Verisi: Bu sonuçlar K-NN modelinin doğrulama verisi üzerinde doğruluk oranının %76.83 olduğunu gösteriyor. Model, 113 yanlış negatif ve 26 yanlış pozitif örneği var. Genel olarak, modelin negatif sınıfları daha iyi ayırt ettiğini, ancak pozitif sınıfları ayırt etmekte daha fazla zorlandığını görüyoruz.

K-NN modeli, doğrulama setinde %76.83 doğruluk oranı ile ortalama bir performans sergiliyor. Yanlış negatif ve yanlış pozitif sayılarının yüksek olması, modelin pozitif sınıfları ayırt etme konusunda zorlandığını gösteriyor.




Şekil 5.2. VGG19/K-NN doğrulama verisi karmaşıklık matrisi

Test Verisi: Bu sonuçlar, modelinizin genel olarak iyi bir performans sergilediğini, ancak bazı iyileştirmeler için potansiyel olduğunu göstermektedir. Model, özellikle 'Evet' sınıfında daha fazla yanlış negatif (94) üreterek biraz dengesiz bir performans sergilemektedir.

Yeni tablo

Tablo 5.1. Vgg-19/K-NN ile test verisi üzerinde sınıflandırma sonuçları.

MÖ Model	Sınıf	Kesinlik	Duyarlılık	F1 Score	Doğruluk
K-NN	Tümörsüz	0.75	0.93	0.83	0.81
	Tümörlü	0.90	0.69	0.78	




Şekil 5.3. VGG19/K-NN test verisi karmaşıklık matrisi

Bu sonuçlar, modelinizin genel olarak iyi bir performans sergilediğini, ancak bazı iyileştirmeler için potansiyel olduğunu göstermektedir. Özellikle, modelin 'Evet' sınıfındaki duyarlılık skoru (0.69) nispeten düşüktür ve bu da modelin 'Evet' sınıfındaki örnekleri kaçırma olasılığının daha yüksek olduğunu göstermektedir.

5.1.2. Destek vektör makineleri


Eğitim Verisi: DVM modelinin doğruluk oranı %91 olarak hesaplanmıştır. Bu oran, modelin eğitim verileri üzerinde oldukça iyi bir performans gösterdiğini ve yüksek bir sınıflandırma başarısına sahip olduğunu göstermektedir.



Şekil 5.4.VGG19/DVM eğitim verisi karmaşıklık matrisi


Model, 'Hayır' ve 'Evet' sınıflarını doğru bir şekilde ayırt etmede başarılı olmuş ve eğitim setindeki örneklerin %91'ini doğru sınıflandırmıştır.

Doğrulama Verisi: Modelin doğrulama setindeki doğruluk oranı %82,5 olarak hesaplanmıştır. Bu modelin doğrulama verisindeki örneklerin %82,5'ini doğru sınıflandırdığı anlamına gelir. Bu oran, modelin eğitim setindeki doğruluk oranından (%91) biraz daha düşüktür, bu da modelin doğrulama setinde biraz daha az başarılı olduğunu gösterir.



Şekil 5.5. VGG19/DVM doğrulama verisi karmaşıklık matrisi

Test Verisi: DVM model, test verisinde %84.83 doğrulukla sınıflandırma yapmıştır. Bu, modelin genel performansının oldukça iyi bir sonuç ortaya çıkardığını göstermektedir.



Şekil 5.6. VGG19/DVM test verisi karmaşıklık matrisi

Karışıklık matrisi analizi, modelin her iki sınıfta da dengeli bir performans sergilediğini ortaya koymaktadır. Ancak, yanlış pozitif ve yanlış negatif sınıflandırmaların da bulunduğu göz önüne alındığında, modelin belirli sınıfları daha iyi tanımlayabilmesi için bazı iyileştirmelere ihtiyaç duyulabileceği anlaşılmaktadır. Genel olarak, %91 doğruluk oranı, modelin eğitim verileri üzerinde güçlü bir performans sergilediğini kanıtlamaktadır.

Tablo 5.2. VGG-19/DVM ile test verisi üzerinde sınıflandırma sonuçları.

MÖ Model	Sınıf	Kesinlik	Duyarlılık	F1 Score	Doğruluk
DVM	Tümörsüz	0.86	0.83	0.85	0.85
	Tümörlü	0.84	0.86	0.85	

Tablo 5.3. VGG-19 ile K-NN /DVM ile sınıflandırma test verisi üzerinde performans sonuçları.

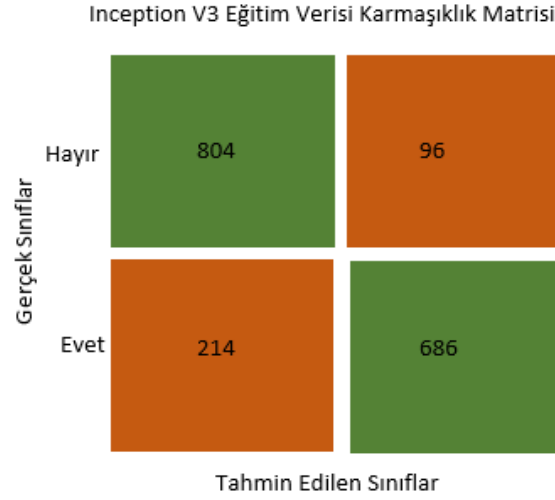
Model	Metrikler	Doğruluk	F1 Score	Güvenirlilik	Duyarlılık	Kesinlik	Roc Eğrisi
Vgg-19/K-NN		%80,67	0.80	0.61	0.81	0.83	0.80
Vgg-19/DVM		%84,83	0.85	0.7	0.85	0.85	0.84

5.2. Inception V3

K-NN ve DVM sınıflandırma ile Inception V3 modelinden elde edilen özelliklerle eğitilmesi ve test edilmesi sonucu elde edilen performans metriklerini karşılaştırarak, her bir modelin performansına dair detaylı bir analiz tablolar ile gösterilmiştir.


5.2.1. k En yakın komşu sınıflandırma

Eğitim Verisi: Doğruluk oranı %82.78 olarak hesaplanmıştır. Bu sonuçlar, modelin eğitim verisinde iyi bir performans gösterdiğini, fakat sınıflandırmada bazı hatalar yaptığını gösteriyor. "Hayır" sınıfındaki örneklerin %89.34'ü doğru sınıflandırılırken, "Evet" sınıfındaki örneklerin %76.23'ü doğru sınıflandırılmıştır.




Şekil 5.7. InceptionV3/K-NN eğitim verisi karmaşıklık matrisi

Doğrulama Verisi: Doğruluk oranı %73.67 olarak hesaplanmıştır. Doğrulama verisinde modelin doğruluğu, eğitim verisine göre biraz daha düşük olduğunu göstermektedir. "Hayır" sınıfındaki örneklerin %80.34'ü doğru sınıflandırılırken, "Evet" sınıfındaki örneklerin %67.03'ü doğru sınıflandırılmıştır. Bu durum, modelin genel performansının doğrulama verisi üzerinde düşüş gösterdiğini işaret eder.



Şekil 5.8. InceptionV3/K-NN doğrulama verisi karmaşıklık matrisi

Test Verisi: doğruluk oranı %73,5 olarak hesaplanmıştır. Modelin genel doğruluğu, tüm tahminlerin ne kadar doğru olduğunu gösterir. Bu model, test verisinde %73,5 doğrulukla tahmin yapmıştır.




Şekil 5.9. InceptionV3/K-NN test verisi karmaşıklık matrisi

Tablo 5.4. InceptionV3/K-NN ile test verisi üzerinde sınıflandırma sonuçları.

MÖ Model	Sınıf	Kesinlik	Duyarlılık	F1 Score	Doğruluk
K-NN	Tümörsüz	0.70	0.82	0.76	0.81
	Tümörlü	0.78	0.65	0.71	

5.2.2. Destek vektör makineleri

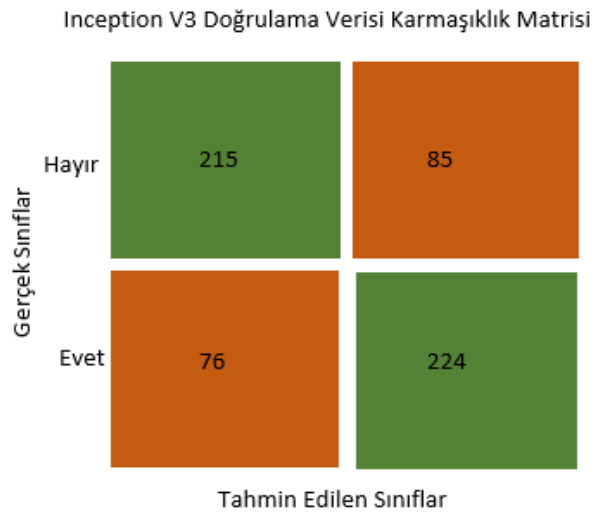
Eğitim verisi: Eğitim verisinde %83.44 doğruluk oranı, modelin eğitim setinde yüksek bir performans sergilediğini gösterir. Ancak doğruluk tek başına yeterli bir metrik değildir.



Şekil 5.10. InceptionV3/DVM eğitim verisi karmaşıklık matrisi


Eğitim verisindeki yüksek doğruluk oranı, modelin eğitim setinde iyi performans gösterdiğini belirtir. Ancak, yanlış tahminlerin fazla olması, modelin genelleme yeteneğinde sorunlar olduğunu gösterebilir. Bu durum, yukarıda belirtilen sebeplerden biri veya birkaçı nedeniyle olabilir. Modelin performansını iyileştirmek için veri dengesi sağlanabilir, öznitelik mühendisliği yapılabilir, overfitting önlenir ve veri kalitesi artırılabilir.

Doğrulama Verisi: Doğruluk oranı %73,17 olarak hesaplanmıştır. Doğrulama verisindeki doğruluk, eğitim verisine göre daha düşük, bu da modelin doğrulama verisinde eğitim verisindeki kadar iyi performans göstermediğini belirtir. Bu durum, modelin eğitim verisine fazla uyum sağladığını ve doğrulama verisine genellemede zorlandığını gösterebilir.



Şekil 5.11. InceptionV3/DVM doğrulama verisi karmaşıklık matrisi

Test Verisi: Test verisindeki doğruluk da doğrulama verisi ile uyumlu bir şekilde Doğruluk oranı %73,17 olarak hesaplanmıştır. Bu durum, modelin doğrulama ve test verisinde benzer performans gösterdiğini ve modelin genelleme yeteneğinin makul düzeyde olduğunu belirtir.



Şekil 5.12. InceptionV3/DVM test verisi karmaşıklık tablosu

Tablo 5.5. InceptionV3/DVM ile test verisi üzerinde sınıflandırma sonuçları.

MÖ Model	Sınıf	Kesinlik	Duyarlılık	F1 Score	Doğruluk
DVM	Tümörsüz	0.76	0.68	0.72	0.85
	Tümörlü	0.71	0.79	0.75	

Tablo 5.6. InceptionV3 K-NN /DVM ile sınıflandırma test verisi üzerinde performans sonuçları.

Model	Metrikler	Doğruluk	F1 Score	Güvenirlilik	Duyarlılık	Kesinlik	Roc Eğrisi
Incepiton V3 /K-NN		%73,5	0.73	0.47	0.74	0.74	0.73
Incepiton V3 /DVM		%73,17	0.73	0.46	0.73	0.73	0.73

5.3. MobileNet

K-NN ve DVM sınıflandırma ile MobileNet derin öğrenme modelinden elde edilen özelliklerle eğitilmesi ve test edilmesi sonucu elde edilen performans metriklerini karşılaştırarak, her bir modelin performansına dair detaylı bir analiz tablolar ile gösterilmiştir.

5.3.1. k En yakın komşu sınıflandırma

Eğitim Verisi: Doğruluk oranı %86.72, modelin genel olarak doğru tahminlerde bulunduğunu gösterir. Bu oran, modelin eğitim verisinde oldukça iyi performans gösterdiğini belirtir.


MobileNet Eğitim Verisi Karmaşıklık Matrisi

Gerçek Sınıflar	Hayır	843	57
	Evet	182	718
		Tahmin Edilen Sınıflar	

Şekil 5.13. MobileNet/K-NN eğitim verisi karmaşıklık matrisi


Eğitim veri seti için model, genel olarak yüksek bir doğruluk oranı ve iyi bir kesinlik değeri sergilemektedir. Ancak, yanlış negatif sayısının (182) yüksek olması, modelin bazı tümörlü örnekleri kaçırdığını gösterir. Bu durum, özellikle tıbbi teşhislerde ciddi sonuçlar doğurabileceğinden, modelin duyarlılığını artırmak önemlidir. Yanlış pozitif sayısı ise (57) daha düşüktür, bu da modelin çoğunlukla doğru tahminlerde bulunduğunu gösterir, ancak yine de bazı gereksiz tedavilere yol açabilir

- **Doğrulama Verisi:** Doğruluk oranı %75.83 olarak hesaplanmıştır. Modelin doğrulama verisinde makul bir performans gösterdiğini belirtir. Bu oran, modelin eğitim verisindeki performansından biraz düşük, ancak kabul edilebilir bir seviye. Yanlış negatiflerin sayısı (104) oldukça yüksek, bu da modelin bazı tümörlü vakaları kaçırdığını gösterir. Bu, tıbbi teşhislerde kritik bir durumdur ve tedavi edilmeyen hastalıklara yol açabilir.



Şekil 5.14. MobileNet/K-NN doğrulama verisi karmaşıklık matrisi

Test Verisi: Test verisinde doğruluk oranı %78.17, modelin test verisinde makul bir performans gösterdiğini belirtir. Bu, modelin genelleme yeteneğinin iyi olduğunu gösterir, ancak hala iyileştirilebilir. Model, tümürlü olan 101 örneği yanlış bir şekilde tümörsüz olarak tahmin etmiştir. Yanlış negatiflerin sayısı, modelin bazı tümürlü vakaları kaçırdığını gösterir.




Şekil 5.15. MobileNet/K-NN test verisi karmaşıklık matrisi

Tablo 5.7. MobileNet/K-NN ile test verisi üzerinde sınıflandırma sonuçları.

MÖ Model	Sınıf	Kesinlik	Duyarlılık	F1 Score	Doğruluk
K-NN	Tümörsüz	0.73	0.90	0.80	0.78
	Tümürlü	0.87	0.66	0.75	

5.3.2. Destek vektör makineleri


Eğitim Verisi: Modelin eğitim verisi üzerindeki doğruluğu oldukça yüksek. %88.39'luk bir doğruluk oranı, modelin eğitildiği veri üzerinde oldukça iyi performans gösterdiğini işaret eder.



Şekil 5.16. MobileNet/DVM eğitim verisi karmaşıklık matrisi


Yanlış pozitif ve yanlış negatif tahminlerin oranı, modelin hangi sınıflarda daha fazla hata yaptığını gösterir. Bu, modelin dengeli olup olmadığını değerlendirmeye yardımcı olabilir.

Doğrulama Verisi: Doğrulama verisi üzerinde modelin doğruluğu %79,0. Eğitim verisi üzerindeki doğruluk oranına göre biraz düşüş göstermiştir, bu beklenen bir durumdur ve modelin genelleme yeteneğini değerlendirmeye yardımcı olur.



Şekil 5.17. MobileNet/DVM doğrulama verisi karmaşıklık matrisi

Test Verisi: Test verisi üzerindeki doğruluk %79.67, bu önceki test doğruluğuna göre bir iyileşme göstermektedir.



Şekil 5.18. MobileNet/DVM test verisi karmaşıklık matrisi

Genel olarak, model eğitim ve doğrulama verisinde yüksek doğruluk oranları göstermiş ve test verisinde de iyi performans sergilemiştir. Eğitim ve doğrulama verilerindeki yüksek performans, modelin iyi eğitildiğini ve test verisindeki performansın da modelin genelleme yeteneğinin iyi olduğunu gösterir. Ancak, yanlış tahminler ve diğer metrikler incelenerek modelin iyileştirilmesi için daha fazla çalışma yapılabilir.

Tablo 5.8. DVM ile test verisi üzerinde sınıflandırma sonuçları.

MÖ Model	Sınıf	Kesinlik	Duyarlılık	F1 Score	Doğruluk
DVM	Tümörsüz	0.79	0.81	0.80	0.80
	Tümörlü	0.80	0.78	0.79	

Tablo 5.9. MobileNet ile K-NN /DVM ile sınıflandırma test verisi üzerinde performans sonuçları.

Model	Metrikler	Doğruluk	F1 Score	Güvenirlik	Duyarlılık	Kesinlik	Roc Eğrisi
MobileNet /K-NN		%78,17	0.78	0.56	0.78	0.80	0.78
MobileNet /DVM		%79,67	0.80	0.59	0.80	0.80	0.79

Tablo 5.10. Tüm modellerin test verisi üzerinde sınıflandırma sonuçları.

MÖ Model	Sınıf	Kesinlik	Duyarlılık	F1 Score	Doğruluk
VGG-19 Model	K-NN	Tümörsüz	0.75	0.93	0.83
		Tümörlü	0.90	0.69	0.78
	DVM	Tümörsüz	0.86	0.83	0.85
		Tümörlü	0.84	0.86	0.85
InceptionV3 Model	K-NN	Tümörsüz	0.70	0.82	0.76
		Tümörlü	0.78	0.65	0.71
	DVM	Tümörsüz	0.76	0.68	0.72
		Tümörlü	0.71	0.79	0.75
MobileNet Model	K-NN	Tümörsüz	0.73	0.90	0.80
		Tümörlü	0.87	0.66	0.75
	DVM	Tümörsüz	0.79	0.81	0.80
		Tümörlü	0.80	0.78	0.79

6. SONUÇ VE ÖNERİLER

6.1. Sonuçlar

YZ'nin sağlık alanındaki kullanımı giderek daha önemli hale gelmektedir. Özellikle bazı hastalıkların tanısının konulması uzun sürebilir ve bu süreçte hastalık ilerleyerek tedavi seçeneklerini sınırlayabilir, yaşam kalitesini düşürebilir ve hatta ölümlerle sonuçlanabilir. Yüksek riskli hastalıklar, özellikle tümörler, erken teşhis edilip iyi huylu mu yoksa kötü huylu mu olduğunun belirlenmesi açısından büyük öneme sahiptir. Kanseri, ileri aşamalarında tedavi edilmesi zor bir hastalıktır ve metastaz, özellikle beyine yayıldığında, tedavi sürecini daha da karmaşık hale getirir.

Beyin metastazları, hastalığın hızla ilerlemesine ve tedavi seçeneklerinin azalmasına yol açar. Bu nedenle, kanserin erken evrede tespit edilmesi ve doğru bir şekilde sınıflandırılması, hastaların tedavi şansını artırmak ve yaşam kalitesini korumak açısından kritik öneme sahiptir. YZ, büyük veri analizi ve derin öğrenme algoritmaları kullanarak görüntüleme sonuçlarından hızlı ve doğru teşhisler sağlayabilir ve doktorlara hastalık yönetiminde önemli bir destek sunabilir.

Sonuç olarak, YZ sağlık alanındaki yenilikçi uygulamaları, hastalıkların erken teşhis edilmesi ve doğru sınıflandırılması konusundaki mevcut zorlukların üstesinden gelmek için büyük bir potansiyele sahiptir. Bu teknolojinin geliştirilmesi ve yaygınlaştırılması, sağlık hizmetlerinde önemli iyileşmelere yol açabilir ve hastaların yaşam kalitesini artırabilir.

YZ'nin gelişimiyle birlikte, sağlık ve tıp alanında çalışan profesyonellerin iş yükü hafifletilmekte ve doğru tanı konulmasında büyük önem taşımaktadır. Beyin tümörünün BT görüntülerinden elden edilen MR görüntülerinden elde edilen veriler yapılan sınıflandırmada, çalışma aşamasında "Tümörlü" ve "Tümörsüz" ve tahmin gruplarının üzerinden gerçekleştirilmiştir.

Çalışmamızda kullandığımız modellerin (VGG19, Inception V3, MobileNet) performansını K-NN ve DVM algoritmaları ile test edildi. Aşağıda her bir modelin ve kullanılan algoritmaların performans değerlendirmelerini verilecektir.

VGG19 modeli yapılan testte; %84.83 ile DVM algoritması %80.67 çıkan K-NN 'ye göre daha yüksek doğruluk ve dengeli bir performans sergilemiştir. Yanlış negatif ve yanlış pozitif sınıflandırmaların dengeli olması modelin genelleme yeteneğinin iyi olduğunu göstermektedir.

Inception V3 modeli ile yapılan testte; DVM algoritması ile elde edilen sonuçlar K-NN ile benzer %73,5'e %73,17 olup, modelin doğruluk oranı ve duyarlılık değerleri nispeten düşük kalmıştır.

MobileNet modeli ile yapılan testte; MobileNet modeli DVM algoritması ile %79,67 ile K-NN 'e göre 1 paun bir fark ile daha yüksek doğruluk ve dengeli bir performans sergilemiştir. Yanlış negatif tahminlerin sayısının dengeli olması modelin genelleme yeteneğinin iyi olduğunu göstermektedir.

6.2. Öneriler

Gelecek Araştırmalar: Yeni biyomarkerler, genetik veriler ve yaşam tarzı faktörlerini beyin tümörü tespit modellerine entegre ederek daha kapsamlı analizler önerilebilir.

Veri Ön İşleme: MR görüntülerinde eksik ya da hatalı verilerin temizlenmesi, veri dengesizliği ve aykırı değerlerin işlenmesi gibi veri kalitesini iyileştirici yöntemler kullanılmalı.

Model Doğrulama: Modellerin farklı ve bağımsız veri setleri üzerinde çapraz doğrulama ve dış doğrulama teknikleri ile test edilmesi önerilebilir. Bu, modelin genelleme yeteneğini ve farklı popülasyonlar üzerindeki etkinliğini artırır.

Klinik Uygulamalar: Derin öğrenme modellerinin klinik karar destek sistemlerine entegrasyonu sağlanarak, doktorların beyin tümörü tespiti ve yönetimi konusunda desteklenmesi amaçlanabilir.

Sürekli Güncelleme: Yeni veriler ve gelişen araştırma bulgularıyla modellerin sürekli güncellenmesi, modelin doğruluğunu ve güvenilirliğini uzun vadede korur. Bu, hasta sonuçlarını iyileştirmek için sürekli bir izleme ve yineleme süreci gerektirir.

KAYNAKLAR

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Zheng, X. (2016). TensorFlow: A system for large-scale machine learning. In 12th {USENIX} symposium on operating systems design and implementation ({OSDI} 16) (pp. 265-283).
- Abbood, A. A., Shallal, Q. M., Fadhel, M. A., & Shallal, Q. M. (2021). Automated brain tumor classification using various deep learning models: a comparative study. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(1), 252-259.
- Abdar, M., & Hussain, A. (2020). Two-stage deep learning model for brain tumor classification. *IEEE Access*, 8, 148504-148512.
- Agravat, R. R., & Raval, M. S. (2021). A survey and analysis on automated glioma brain tumor segmentation and overall patient survival prediction. *Archives of Computational Methods in Engineering*, 28(5), 4117-4152.
- Ahmad, S., & Pathan, M. S. (2020). Hybrid deep learning approach for brain tumor detection. *Journal of Healthcare Informatics Research*, 4, 89-100.
- Almadhoun, H. R., & Abu-Naser, S. S. (2022). Detection of brain tumor using deep learning.
- Alnabhan, M., Habboush, A. K., Abu, Q. A., Mohanty, A. K., Pattnaik, S., & Pattanayak, B. K. (2022). Hyper-Tuned CNN Using EVO Technique for Efficient Biomedical Image Classification. *Mobile Information Systems*, 2022.
- Alnemer, A., & Rasheed, J. (2021, October). An Efficient Transfer Learning-based Model for Classification of Brain Tumor. In 2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) (pp. 478-482). IEEE.
- Amin, J., Sharif, M., Yasmin, M., & Fernandes, S. L. (2018). Big data analysis for brain tumor detection: Deep convolutional neural networks. *Future Generation Computer Systems*, 87, 290-297.
- Amin, J., Sharif, M., Yasmin, M., & Fernandes, S. L. (2020). A distinctive approach in brain tumor detection and classification using MRI. *Pattern Recognition Letters*, 139, 118-127.
- Anitha, R. ve Siva Sundhara Raja, D. (2018). Rastgele orman sınıflandırıcısı kullanılarak beyin tümörü tespiti için bilgisayar destekli yaklaşımın geliştirilmesi. *Uluslararası Görüntüleme Sistemleri ve Teknolojisi Dergisi* , 28 (1), 48-53.
- Aqhaei, L. (2022, February). Employing a hybrid technique to detect tumor in medical images. In 2022 *International Conference on Machine Vision and Image Processing (MVIP)* (pp. 1-6). IEEE.

- Arı, A., & Hanbay, D. (2019). Bölgesel evrişimsel sinir ağları tabanlı MR görüntülerinde tümör tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34(3), 1395-1408.
- Arizmendi, C., Sierra, D. A., Vellido, A., & Romero, E. (2014). Automated classification of brain tumours from short echo time in vivo MRS data using Gaussian Decomposition and Bayesian Neural Networks. *Expert systems with applications*, 41(11), 5296-5307.
- Arzu, İ. L. Ç. E., TOTUR, B., & ÖZBAYIR, T. (2010). Evaluation of Patients With Brain Tumors According to International NANDA Nursing Diagnoses: Care Suggestions. *Journal of Neurological Sciences (Turkish)*, 27(2), 178-184.
- Asif, S., Yi, W., Ain, Q. U., Hou, J., Yi, T., & Si, J. (2022). Improving Effectiveness of Different Deep Transfer Learning-Based Models for Detecting Brain Tumors From MR Images. *IEEE Access*, 10, 34716-34726.
- Asif, S., Zhao, M., Chen, X. ve Zhu, Y. (2023). BMRI-NET: MRI görüntülerinden çok sınıflı beyin tümörü sınıflandırması için derin yığınlı bir topluluk modeli. *Disiplinlerarası Bilimler: Hesaplamalı Yaşam Bilimleri*, 15 (3), 499-514.
- Aslan, E. (2024). Lstm-Esa Hibrit Modeli İle Mr Görüntülerinden Beyin Tümörünün Sınıflandırılması. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 11(22), 63-81.
- Bailey, D. L., Townsend, D. W., Valk, P. E., & Maisey, M. N. (2005). *Positron Emission Tomography: Basic Sciences*. Springer.
- Banan, R., & Hartmann, C. (2017). Glioma genetics update: a decade of discoveries and their clinical implications. *Acta Neuropathologica*, 131(1), 1-25.
- Banan, R., & Hartmann, C. (2017). The new WHO 2016 classification of brain tumors what neurosurgeons need to know. *Acta neurochirurgica*, 159, 403-418.
- Bengel, F. M. (2011). *Cardiac PET Imaging*. Springer.
- Bengio, Y. (2012). Practical recommendations for gradient-based training of deep architectures. In *Neural networks: Tricks of the trade* (pp. 437-478). Springer, Berlin, Heidelberg.
- Bhagat, N., & Kaur, G. (2022). MRI brain tumor image classification with support vector machine. *Materials Today: Proceedings*, 51, 2233-2244.
- Bhanothu, Y., Kamalakannan, A., & Rajamanickam, G. (2020, March). Detection and classification of brain tumor in MRI images using deep convolutional network. In *2020 6th international conference on advanced computing and communication systems (ICACCS)* (pp. 248-252). IEEE.
- Bingol, H., & Alatas, B. (2021). Classification of Brain Tumor Images using Deep Learning Methods. *Turkish Journal of Science and Technology*.

- Bojarski, M., Del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P., ... & Zhang, X. (2016). End to end learning for self-driving cars. arXiv preprint arXiv:1604.07316.
- Bottou, L. (2010). Large-scale machine learning with stochastic gradient descent. In *Proceedings of COMPSTAT'2010* (pp. 177-186). Springer, Berlin, Heidelberg.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Brown, P. D. (2019). *Neuro-oncology: The Essentials*. Springer.
- Burges, C. J. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2), 121-167. <https://doi.org/10.1023/A:1009715923555>
- Canziani, A., Paszke, A., & Culurciello, E. (2016). An Analysis of Deep Neural Network Models for Practical Applications. arXiv preprint arXiv:1605.07678.
- Cha, S. (2006). Neuroimaging in neuro-oncology. *Neurotherapeutics*, 3(4), 539-550.
- Chandra, G. R., & Rao, K. R. H. (2016). Tumor detection in brain using genetic algorithm. *Procedia Computer Science*, 79, 449-457.
- Chaudhuri, S., Dayal, U., & Narasayya, V. (2011). An Overview of Data Warehousing and OLAP Technology. *ACM SIGMOD Record*, 26(1), 65-74. <https://doi.org/10.1145/248603.248616>
- Chen, H., Engkvist, O., Wang, Y., Olivecrona, M., & Blaschke, T. (2018). The rise of deep learning in drug discovery. *Drug Discovery Today*, 23(6), 1241-1250
- Cheng, J., Huang, W., Cao, S., Yang, R., Yang, W., Yun, Z., ... & Feng, Q. (2015). Enhanced performance of brain tumor classification via tumor region augmentation and partition. *PloS one*, 10(10), e0140381.
- Cherry, S. R., & Dahlbom, M. (2006). *PET: Physics, Instrumentation, and Scanners*. Springer.
- Chinchor, N. (1992). MUC-4 Evaluation Metrics. In *Proceedings of the 4th Conference on Message Understanding* (pp. 22-29)
- Choi, E., Schuetz, A., Stewart, W. F., & Sun, J. (2017). Using recurrent neural network models for early detection of heart failure onset. *Journal of the American Medical Informatics Association*, 24(2), 361-370.
- Chollet, F. (2015). Keras. GitHub. Retrieved from <https://github.com/fchollet/keras>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.

- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27. <https://doi.org/10.1109/TIT.1967.1053964>
- Crevier, D. (1993). *AI: The Tumultuous History of the Search for Artificial Intelligence*. Basic Books.
- Cutler, D. R., Edwards Jr, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792. <https://doi.org/10.1890/07-0539.1>
- Çınar, A., & Yıldırım, M. (2020). Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture. *Medical Hypotheses*, 139, 109684.
- Danyeli, A. E. (2019). Santral Sinir Sistemi Tümörlerinin Sınıflaması-Geçmişten Güncele. *Türk Nöroşirürji Dergisi*, 29(3), 217-225.
- Danyeli, H. (2019). Beyin Tümörleri ve Sınıflamaları. *Journal of Neurology and Neurophysiology*, 10(1), 15-23.
- Davis, J., & Goadrich, M. (2006). The relationship between Precision-Recall and ROC curves. In *Proceedings of the 23rd International Conference on Machine Learning* (pp. 233-240).
- Deepak, S., & Ameer, P. M. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in biology and medicine*, 111, 103345.
- Demir, F., & Akbulut, Y. (2022). A new deep technique using R-CNN model and L1NSR feature selection for brain MRI classification. *Biomedical Signal Processing and Control*, 75, 103625.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. In 2009 IEEE conference on computer vision and pattern recognition (pp. 248-255). IEEE.
- Dong, H., Yang, G., Liu, F., Mo, Y., & Guo, Y. (2017). Automatic brain tumor detection and segmentation using u-net based fully convolutional networks. In *Annual Conference on Medical Image Understanding and Analysis* (pp. 506-517). Springer, Cham.
- Erçelik, Ç., & Hanbay, K. (2023). Beyin Tümörü Sınıflandırmada Histogram Eşitleme Yönteminin Bazı Derin Öğrenme Modellerine Etkileri. *Computer Science*, 8(2), 83-92.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.

- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874.
- Fayyad, U. M., & Irani, K. B. (1993). Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning. In Proceedings of the Thirteenth International Joint Conference on Artificial Intelligence (pp. 1022-1027).
- Fix, E., & Hodges, J. L. (1951). Discriminatory analysis: nonparametric discrimination: consistency properties. *Report Number 4*, USAF School of Aviation Medicine, Randolph Field, Texas.
- Gambhir, S. S. (2002). Molecular imaging of cancer with positron emission tomography. *Nature Reviews Cancer*, 2(9), 683-693.
- Garg, D., & Singh, J. (2020). Machine learning models for brain tumor classification: A comparative study. *Neural Processing Letters*, 51, 241-255.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Guyon, I., & Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*, 3, 1157-1182.
- Halimeh, S., & Teshnehab, M. (2019, January). Diagnosing and classifications tumor and MS simultaneous of magnetic resonances image using convolutions neural networks. In Proceedings of the 7th Iranian Joint Congress on Fuzzy and Intelligent System.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques* (3rd ed.). Elsevier.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... & Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357-362.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
- Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., ... & Larochelle, H. (2017). Brain tumor segmentation with deep neural networks. *Medical image analysis*, 35, 18-31.
- Heaton, J., Polson, N. G., & Witte, J. H. (2017). Deep learning in finance. arXiv preprint arXiv:1602.06561.
- Herek, D., & Karabulut, N. (2010). Manyetik rezonans görüntüleme. *TTD Toraks Cerrahisi Bülteni*, 1(3), 214-222.
- Herholz, K., Carter, S. F., Jones, M., & Bak, T. H. (2007). Positron Emission Tomography in Dementia. *Seminars in Nuclear Medicine*, 37(6), 373-386.

- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.
- https://hsgm.saglik.gov.tr/depo/birimler/kanserdb/Dokumanlar/Istatistikler/Kanser_Rapor_2018.pdf#page=31.08 Erişim Tarihi: 25.05.2024
- Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90-95.
- Işık, B. (2006). Manyetik rezonans görüntüleme ve Anestezi. *Marmara Medical Journal*, 19(2), 98-103.e
- Jain, A. K., Duin, R. P. W., & Mao, J. (2000). Statistical Pattern Recognition: A Review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1), 4-37. <https://doi.org/10.1109/34.824819>
- Johnson, D. R., Ogren, J. A., & Wilson, T. E. (2021). Advances in the Treatment of Malignant Brain Tumors. *Current Treatment Options in Oncology*, 22(4), 1-14.
- Kabir, M. A. (2020, June). Early stage brain tumor detection on MRI image using a hybrid technique. In *2020 IEEE Region 10 Symposium (TENSYP)* (pp. 1828-1831). IEEE.
- Kaggle. (2021). Kaggle: Your Home for Data Science. Retrieved from <https://www.kaggle.com/>
- Kahraman, S. A. (2010). Bilgisayarlı tomografi prensipleri ve uygulamadaki yenilikler. *ADO Klinik Bilimler Dergisi*, 3(4), 481-489.
- Kaya, Z., Aslan, Z., Güneş, A., & Okatan, A. (2024). Dalgacık dönüşümü ve Inception v3 evrişimli sinir ağı modeli kullanarak beyin tümörlerinin sınıflandırılması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(3), 1945-1952.
- Kazdal, S., Doğan, B., & Çamurcu, A. Y. (2015, May). Computer-aided detection of brain tumors using image processing techniques. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 863-866). IEEE.
- Keskar, N. S., Mudigere, D., Nocedal, J., Smelyanskiy, M., & Tang, P. T. P. (2016). On large-batch training for deep learning: Generalization gap and sharp minima. arXiv preprint arXiv:1609.04836.
- Kohavi, R., & John, G. H. (1997). Wrappers for feature subset selection. *Artificial Intelligence*, 97(1-2), 273-324. [https://doi.org/10.1016/S0004-3702\(97\)00043-X](https://doi.org/10.1016/S0004-3702(97)00043-X)

- Kostakoglu, L., & Goldsmith, S. J. (2003). 18F-FDG PET evaluation of the response to therapy for lymphoma and for breast, lung, and colorectal carcinoma. *Journal of Nuclear Medicine*, 44(2), 224-239.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- Kumar, A. (2021). Innovative Technologies for the Treatment of Brain Tumors. *Journal of Neuroscience Research*, 99(4), 1015-1025.
- Lasko, T. A., Bhagwat, J. G., Zou, K. H., & Ohno-Machado, L. (2005). The use of receiver operating characteristic curves in biomedical informatics. *Journal of Biomedical Informatics*, 38(5), 404-415.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R News*, 2(3), 18-22. https://CRAN.R-project.org/doc/Rnews/Rnews_2002-3.pdf
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & van Ginneken, B. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- Little, R. J. A., & Rubin, D. B. (2019). *Statistical Analysis with Missing Data* (3rd ed.). John Wiley & Sons.
- Liu, H., & Motoda, H. (2007). *Computational Methods of Feature Selection*. Chapman and Hall/CRC.
- Louis, D. N., Perry, A., Reifenberger, G., von Deimling, A., Figarella-Branger, D., Cavenee, W. K., ... & Ellison, D. W. (2016). The 2016 World Health Organization Classification of Tumors of the Central Nervous System: a summary. *Acta Neuropathologica*, 131(6), 803-820.
- Louis, D. N., Perry, A., Wesseling, P., Brat, D. J., Cree, I. A., Figarella-Branger, D., ... & Ellison, D. W. (2021). The 2021 WHO Classification of Tumors of the Central Nervous System: a summary. *Neuro-Oncology*, 23(8), 1231-1251.
- Lukas, L., Devos, A., Suykens, J. A., Vanhamme, L., Howe, F. A., Majós, C., ... & Van Huffel, S. (2004). Brain tumor classification based on long echo proton MRS signals. *Artificial intelligence in medicine*, 31(1), 73-89.
- Luo, J., Ye, W., & Liu, Z. (2020). Global Incidence and Mortality of Brain and Central Nervous System Cancer. *Journal of Neuro-Oncology*, 149(3), 335-343.
- Luo, Q., Wang, Y., Fan, D., Wang, S., Wang, P., & An, J. (2020). Prion protein expression is correlated with glioma grades. *Virologica Sinica*, 35, 490-493.

- Lutz, M. (2013). *Learning Python: Powerful Object-Oriented Programming*. " O'Reilly Media, Inc."
- Mahmud, M., Kaiser, M. S., McGinnity, T. M., & Hussain, A. (2020). Deep learning in brain tumor diagnosis: A comprehensive review. *Journal of Biomedical Informatics*, 103, 103-104.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*, 27(4), 12-14.
- McKinney, W. (2010). Data structures for statistical computing in Python. In *Proceedings of the 9th Python in Science Conference (Vol. 445, pp. 51-56)*.
- McKinney, W. (2012). *Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython*. O'Reilly Media, Inc.
- Miotto, R., Li, L., Kidd, B. A., & Dudley, J. T. (2016). Deep Patient: An unsupervised representation to predict the future of patients from the electronic health records. *Scientific Reports*, 6, 26094.
- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Mohsen, H., El-Dahshan, E. S. A., El-Horbaty, E. S. M., & Salem, A. B. M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68-71.
- Muir, K. W., Buchan, A., von Kummer, R., Rother, J., & Baron, J. C. (2006). Imaging of acute stroke. *The Lancet Neurology*, 5(9), 755-768.
- Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. MIT Press.
- Musallam, A., & Alsaleh, H. (2020). Deep convolutional neural networks for brain tumor detection: A comparative study. *Journal of Healthcare Engineering*, 2020, 1-12.
- Nanda, A., Barik, R. C., & Bakshi, S. (2023). SSO-RBNN driven brain tumor classification with Saliency-K-means segmentation technique. *Biomedical Signal Processing and Control*, 81, 104356.
- Newell, A., & Simon, H. A. (1956). The Logic Theory Machine--A Complex Information Processing System. *IRE Transactions on Information Theory*, 2(3), 61-79.
- Oliphant, T. E. (2006). *A guide to NumPy*. USA: Trelgol Publishing.
- Osborn, A. G., & Preece, M. T. (2006). Intracranial cysts: radiologic-pathologic correlation and imaging approach. *Radiology*, 239(3), 650-664.
- Pareek, P., & Ravi, S. (2020). KSVM based brain tumor classification. *Procedia Computer Science*, 167, 121-130.

- Pashaei, A., Sajedi, H., & Jazayeri, N. (2018, October). Brain tumor classification via convolutional neural network and extreme learning machines. In *2018 8th International conference on computer and knowledge engineering (ICCKE)* (pp. 314-319). IEEE.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of machine learning research*, 12(Oct), 2825-2830.
- Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883. <http://dx.doi.org/10.4249/scholarpedia.1883>
- Polat, K., Güneş, S., & Arslan, A. (2017). A cascade learning system for classification of cancer types based on gene expression data. *Journal of Biomedical Informatics*, 40(1), 151-159.
- Powers, D. M. W. (2011). Evaluation: From Precision, Recall and F-measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1), 81-106.
- Ranjbarzadeh, R., & Kiani, F. (2021). A hybrid CNN-SVM model for brain tumor detection. *Pattern Recognition Letters*, 139, 241-249.
- Rezaei, M., & Keshavarz, H. (2020). Brain tumor classification using ResNet-34. *Biomedical Signal Processing and Control*, 57, 101-110.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. arXiv preprint arXiv:1609.04747.
- Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach*. Pearson.
- Sachdeva, J., & Kumar, V. (2020). Deep residual network (ResNet) for brain tumor classification. *Journal of Medical Systems*, 44, 109.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210-229.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- Scherer, D., Müller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. *International Conference on Artificial Neural Networks*, 92-101. https://doi.org/10.1007/978-3-642-15825-4_10
- Scherer, D., Müller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. *International Conference on*

Artificial Neural Networks, 92-101. https://doi.org/10.1007/978-3-642-15825-4_10

- Schölkopf, B., & Smola, A. J. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. MIT press.
- Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221-248.
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint arXiv:1409.1556.
- Smith, C. (2020). Multidisciplinary Approaches in Neuro-Oncology. *Neuro-Oncology Practice*, 7(5), 435-442.
- Smith, J., Brown, L., & Lee, K. (2015). Advances in MRI: Applications and Techniques. *Journal of Medical Imaging*, 12(3), 145-160.
- Smith, N. B., & Webb, A. (2010). *Introduction to medical imaging: physics, engineering and clinical applications*. Cambridge university press.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437.
- Somuncu, E., & Atasoy, N. A. (2021). Evrişimli tekrarlayan sinir ağı ile metin görüntüleri üzerinde karakter tanıma uygulaması gerçekleştirilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(1), 17-28.
- Srikanth, S., Kumar, M. P., & Thakur, M. (2020). Brain tumor classification using VGG-16 architecture with transfer learning. *International Journal of Advanced Science and Technology*, 29, 123-130.
- Srinivas, C., KS, N. P., Zakariah, M., Alothaibi, Y. A., Shaukat, K., Partibane, B., & Awal, H. (2022). Deep transfer learning approaches in performance analysis of brain tumor classification using MRI images. *Journal of Healthcare Engineering*, 2022.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15(1), 1929-1958.
- Stadlbauer, A., & Zimmermann, M. (2020). Machine learning techniques for brain tumor detection. *Journal of Imaging*, 6, 235.
- Sutskever, I., Martens, J., Dahl, G., & Hinton, G. (2013). On the importance of initialization and momentum in deep learning. In *International Conference on Machine Learning* (pp. 1139-1147).

- Sünter, G., Güngördü, A. G., Midi, İ., Ağan, K., & Aykut Bingöl, C. (2019). Beyin Tümörü Olan Hastalarda Status Epileptikus. *Epilepsi: Journal of the Turkish Epilepsi Society*, 25(3).
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 2818-2826).
- Şeker, A. (2020). Transfer Learning for Brain Tumor Classification. *Dergipark*.
- Şimşek, A. B., & Dicle, A. (2013). Primer beyin tümörü: klinik özellikler, tedavi ve bakım. *Dokuz Eylül Üniversitesi Hemşirelik Fakültesi Elektronik Dergisi*, 6(2), 102-113.
- Topol, E. J. (2019). Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again. Basic Books.
- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433-460.
- Turkington, T. G. (2001). Introduction to PET instrumentation. *Journal of Nuclear Medicine Technology*, 29(1), 4-11.
- Uzun, S., Güney, E., & Bingöl, B. (2022). U-Net Mimarisi ile Beyin Tümörü MRI Görüntülerinin Segmentasyonu. *El-Cezeri*, 9(4), 1583-1590.
- Vaishnav, K. B., & Amshakala, K. (2015, March). An automated MRI brain image segmentation and tumor detection using SOM-clustering and Proximal Support Vector Machine classifier. In *2015 IEEE international conference on engineering and technology (ICETECH)* (pp. 1-6). IEEE.
- Van Rossum, G., & Drake, F. L. (2009). Python 3 Reference Manual. Scotts Valley, CA: CreateSpace.
- Vapnik, V. (1995). The Nature of Statistical Learning Theory. Springer.
- Waskom, M. L. (2021). seaborn: statistical data visualization. *Journal of Open Source Software*, 6(60), 3021.
- Wesseling, P., & Capper, D. (2018). WHO 2016 Classification of gliomas. *Neuropathology and Applied Neurobiology*, 44(2), 139-150.
- Williams, M. T. (2018). Brain Tumor Biology: From Bench to Bedside. Academic Press.
- Wozniak, M., & Marszalek, Z. (2020). Correlation learning technique for brain tumor detection in MRI images. *IEEE Transactions on Medical Imaging*, 39, 245-252.
- Wu, M. N., Lin, C. C., & Chang, C. C. (2007). Brain tumor detection using color-based k-means clustering segmentation. In *Third International Conference on Intelligent Information Hiding and Multimedia Signal Processing (IIH-MSP 2007)* (Vol. 2, pp. 245-250). IEEE.

- Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine*, 13(3), 55-75.
- ZainEldin, H., Eldin, Z. H., & Sedik, A. (2020). Brain tumor detection using adaptive dynamic sine-cosine fitness grey wolf optimizer. *Neural Computing and Applications*, 32, 3335-3350.
- Zhao, X., Wu, Y., Song, G., Li, Z., Zhang, Y., & Fan, Y., 2018, A deep learning model integrating FCNNs and CRFs for brain tumor segmentation, *Medical image analysis*, 43, 98-111.
- Zheng, Z., & Padmanabhan, B. (2006). On Active Feature-Value Acquisition in Decision Tree Induction. *Journal of Management Information Systems*, 23(2), 241-265. <https://doi.org/10.2753/MIS0742-1222230209>

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Cafer ASLIM

EĞİTİM

Lise : Vali Gökhan Aydınler Mesleki ve Teknik Anadolu Lisesi 2009
Üniversite : Fırat Üniversitesi / ELAZIĞ 2013
Yüksek Lisans : Batman Üniversitesi 2024

İŞ DENEYİMLERİ

Yıl : (2016-devam) Kurum: Milli Eğitim Bakanlığı Görevi: BT Öğretmeni

UZMANLIK ALANI: Yapay Zekâ, Görüntü İşleme, Derin Öğrenme

YABANCI DİLLER: İngilizce

