

SAĞLIK HİZMETLERİNDE

MR TABANLI BEYİN TÜMÖRÜ TEŞHİSİ İÇİN DERİN ÖĞRENME DESTEKLİ BİR KLİNİK KARAR DESTEK SİSTEMİ

MRI ANALYSIS

T1-weighted
T2-weighted
FLAIR
DWI



DEEP LEARNING



AI PREDICTION



☒	Glioma	98.7%
☐	Meningioma	1.1%
☐	Pituitary	0.1%
☐	No Tumor	0.1%

CLINICAL DECISION SUPPORT SYSTEM



ÖMER ÇELİK

İmtiyaz Sahibi • Yaşar Hız

Genel Yayın Yönetmeni • C. Cansın Selin Temana

Kapak & İç Tasarım • Serüven Yayınevi

Birinci Basım • © Temmuz 2026

ISBN • 978-625-8810-95-0

© copyright

Bu kitabın yayın hakkı Serüven Yayınevi'ne aittir.

Kaynak gösterilmeden alıntı yapılamaz, izin almadan hiçbir yolla çoğaltılamaz.

Serüven Yayınevi

Adres: Kızılay Mah. Fevzi Çakmak 1. Sokak

Ümit Apt No: 22/A Çankaya/ANKARA

Telefon: 05437675765

web: www.seruvenyayinevi.com

e-mail: seruvenyayinevi@gmail.com

Baskı & Cilt

Sertifika No: 42488

SAĞLIK HİZMETLERİNDE
MR TABANLI BEYİN
TÜMÖRÜ TEŞHİSİ İÇİN
DERİN ÖĞRENME
DESTEKLİ BİR KLİNİK
KARAR DESTEK SİSTEMİ

ÖMER ÇELİK

İÇİNDEKİLER

GİRİŞ.....	1
BÖLÜM I	
SAĞLIK BİLİŞİMİ VE KARAR VERME	7
BÖLÜM II	
SAĞLIK HİZMETLERİNDE YAPAY ZEKA	17
BÖLÜM III	
SAĞLIK HİZMETLERİNDE BİR KLİNİK KARAR DESTEK UYGULAMASI: BEYİN TÜMÖRÜ TEŞHİS ÖRNEĞİ	27
BÖLÜM IV	
ARAŞTIRMADA KULLANILAN YÖNTEM	35
BÖLÜM V	
ARAŞTIRMANIN BULGULARI VE TARTIŞMA.....	55
SONUÇ VE ÖNERİLER.....	67
KAYNAKÇA	69

TEŞEKKÜR

Bu çalışma, TÜBİTAK 2214-A Yurt Dışı Araştırma Burs Programı (2024/1 dönemi, Proje No: 1059B142401398) kapsamında desteklenmiştir. Sağladığı katkıdan dolayı TÜBİTAK'a teşekkür ederim.

Ömer ÇELİK

ISPARTA-2025

(ÇELİK, Ömer, Sağlık Hizmetlerinde Yapay Zekâ: MR Tabanlı Beyin Tümörü Teşhisi İçin Derin Öğrenme Destekli Klinik Karar Sistemi, Doktora Tezi, Isparta, 2025.)

KISALTMALAR DİZİNİ

AI	: Yapay Zekâ (Artificial Intelligence)
BT	: Bilgisayarlı Tomografi
CAD	: Bilgisayar Destekli Tanı (Computer Aided Diagnosis)
CADx	: Bilgisayar Destekli Teşhis (Computer Aided Diagnosis)
CAM	: Kanal Dikkat Modülü (Channel Attention Module)
CBAM	: Evrişimsel Blok Dikkat Modülü (Convolutional Block Attention Module)
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
DL	: Derin Öğrenme (Deep Learning)
ECA	: Verimli Kanal Dikkati (Efficient Channel Attention)
ESK	: Elektronik Sağlık Kayıtları (Electronic Health Records)
GAM	: Global Dikkat Mekanizması (Global Attention Mechanism)
GLCM	: Gri Seviye Eş Oluşum Matrisi (Gray Level Co-occurrence Matrix)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
IARC	: Uluslararası Kanser Araştırma Ajansı
KDS	: Karar Destek Sistemi
KKDS	: Klinik Karar Destek Sistemi (Clinical Decision Support System)
ML	: Makine Öğrenmesi (Machine Learning)
MLP	: Çok Katmanlı Algılayıcı (Multi-Layer Perceptron)
MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
MSS	: Merkezi Sinir Sistemi
NAS	: Sinirsel Mimari Arama (Neural Architecture Search)

ResMLP	: Kalan Tabanlı MLP (Residual Multi-Layer Perceptron)
SAM	: Uzamsal Dikkat Modülü (Spatial Attention Module)
SE	: Squeeze and Excitation Block
STN	: Uzamsal Dönüştürücü Ağlar (Spatial Transformer Networks)
TDK	: Türk Dil Kurumu
WOS	: Web of Science
YZ	: Yapay Zekâ

GİRİŞ

Son on yılda teknolojik alanda yaşanan önemli ilerlemeler, veriye dayalı karar destek sistemlerinin gelişimini hızlandırmış ve bu sistemler disiplinler arası bir perspektifle çeşitli sektörlerde köklü dönüşümlere yol açmıştır. Özellikle sağlık sektörü, söz konusu dönüşümden en fazla etkilenen alanlardan biri olarak öne çıkmakta; tanı, tedavi ve hasta yönetimi süreçlerinde yenilikçi yaklaşımların benimsenmesine olanak sağlamaktadır. Sağlık sektörü, sistemleri ve süreçleriyle teknolojik gelişmelere son derece duyarlıdır. İnsan hayatının önemi ve değeri, derin tıbbi bilgi birikimi ve zaman alıcı karar süreçleri, etkin tanı ve tedavi yöntemlerinin geliştirilmesini zorunlu kılmaktadır. Bu dinamikler, sağlık hizmetlerini yenilikçi teknolojilere bağımlı hâle getirmiştir. Bu durumdaki etkileşim özellikle sağlık hizmetleri ile yeni nesil teknolojilerin entegrasyonunda daha fazla görülmektedir.

Sağlık sistemlerinin etkili yönetimi, karmaşık bilgi işleme sürecine dayanmaktadır. Bu süreç, sağlık hizmetlerinin kalitesini ve etkinliğini artırmak için sistemin çeşitli yönlerini organize etmeyi, bilgiyi yönetmeyi ve finansal kaynakları optimal şekilde kullanmayı içermektedir. Buna ek olarak, daha verimli, nitelikli ve daha ucuz sağlık hizmetlerine yönelik artan talep, yeni teknolojik çözümleri motive etmektedir (Dehe & Bamford, 2017).

Sağlık hizmetlerinin sunumu, iki temel bilgi işleme görevinden oluşur: İlk olarak, sağlık profesyonelleri hastalıkları geçmiş veriler, klinik muayeneler ve araştırmalar ışığında sınıflandırır ve teşhis eder. İkinci olarak ise, tedavi süreci belirli hedeflere ulaşmak için planlama, uygulama ve izleme aşamalarını kapsayan çok adımlı bir süreçtir. Bu süreçler, bireysel ve toplumsal sağlık hedeflerine ulaşmada kritik rol oynar (Atun et al., 2013; Panch et al., 2018). Bu konuları anlama ve sistemleştirme ihtiyacı sağlık bilişimini doğurmuştur.

Sağlık bilişimi, sağlık hizmetlerinin sonuçlarını ve sunumunu iyileştirmek için teknoloji ve veri analitiğini birleştiren disiplinlerarası bir alandır (Robert, 2024). Sağlık bilişiminin ana taşıyıcısı veridir. Bununla birlikte, sağlık hizmetleri gerçek bir büyük veri sektörüdür ve depolanan dünya verilerinin %30'unun sağlık sektörü verisi olduğu bildirilmektedir (Faggella, 2018). Dijital sağlık verileri sadece hacimsel olarak çok büyük olmakla birlikte çok çeşitli ve çok hızlı elde edildiği için geleneksel yazılımların sınırlarını zorlamaktadır (Fang et al., 2016). Bu zorlukların üstesinden gelmek YZ'nin veriye aç algoritmaları ile mümkün olabilmektedir.

Sağlık hizmetlerinde YZ, makine öğrenimi (ML), özellikle derin öğrenme (DL) algoritmaları, veri analitiğini ve otomasyonu kullanarak, tıbbi karar alma, teşhis ve tedavi sonuçlarını iyileştirerek, üretkenliği, bakım kalitesini artırma ve maliyetleri düşürme potansiyeline sahip bir paradigma dönüşümüne neden olduğu söylenebilir (Bajwa et al., 2021; Faiyazuddin et al., 2025). Aynı zamanda bu teknolojik gelişmeler ölçeklenebilir, esnek ve etkili bir sağlık sistemi tasarlamasına imkân verebilmektedir (Bohr & Memarzadeh, 2020; Faiyazuddin et al., 2025; Johnson et al., 2021).

Yapay zekâ, göğüs röntgenlerinde radyolog analizlerinin elde edilme sürecini önemli ölçüde hızlandırdığı sonuca bir çalışmada bulunmuştur. Aynı çalışmada, yapay zekâ sistemi raporların teslim süresini 11,2 günden yalnızca 2,7 güne düşürerek, otomatik triaj sistemlerinin sağlık hizmeti süreçlerini optimize etmedeki etkisini ve hasta bakım standartlarını yükseltme potansiyelini ortaya koymuştur (Annarumma et al., 2019). Başka bir çalışmada, YZ'nın radyolojiye entegrasyonu, tümör ilerlemesinin verimli ve hassas bir şekilde izlenmesine yol açarak genel tedavi değerlendirmesini ve hasta bakımını önemli ölçüde geliştirebileceği sonucuna ulaşılmıştır (Najjar, 2023). Bu teknolojiler, çok sayıda sağlık kuruluşunda iş yükünün önemli bir bölümünü oluşturan kanser görüntülemesinde aktif olarak araştırılmakta ve benimsenmektedir (Koh et al., 2022).

YZ'nin son yıllarda hızlanan gelişimi, büyük verideki artış ve hesaplama gücündeki ilerlemelerin sinerjik etkileşiminin bir sonucudur. Elektronik sağlık kayıtlarının (EHR'ler), tıbbi görüntüleme arşivlerinin ve açıklamalı veri kümelerinin yaygın olarak yayılması, bol miktarda eğitim verisi sağlarken, grafik işleme birimleri (GPU'lar) ve dağıtılmış bilgi işlem dahil olmak üzere donanımdaki ilerleme, hesaplama açısından zorlu YZ algoritmalarının dağıtımını hızlandırmıştır (Najjar, 2023).

YZ, tek bir çözümden ziyade esnek bir araç takımıdır, veriyi bir enerji kaynağı olarak değerlendiren ve zaman-mekân kısıtlarını zorlayan algoritmalarıyla sağlık sektörüne entegre olmuştur. Özellikle klinik karar destek sistemlerinde YZ'nin kullanımı, tanı ve tedavi süreçlerinde devrimsel bir potansiyel taşımaktadır. YZ, insan zekasının temel işlevlerini modelleyen, veri analizi yoluyla öğrenme yeteneği kazanan ve karmaşık problemleri algoritmik yaklaşımlarla çözümleyen sistemler tasarlamayı amaçlayan aynı zamanda disiplinler arası alandan faydalanan bir bilim dalıdır (Dicuonzo et al., 2023).

Yapay zeka, insan hayatı üzerinde derin bir etkiye sahip devrim niteliğinde bir teknolojidir (Myers et al., 2024; Zador, 2019). YZ görüntü işleme otomasyonu, makine öğrenimi ve derin öğrenme gibi yenilikçi hesaplama yöntemleri ile tıbbi uygulamalarda önemli bir rol oynamaktadır. Derin öğrenme, özellikle büyük veri kümelerindeki karmaşık örüntüleri otomatik olarak çıkarabilme yeteneğiyle öne çıkmaktadır (M. Lubbad et al., 2024). Bu

algoritmalar, tıbbi görüntü analizinden ilaç keşfine kadar pek çok alanda yüksek başarı oranlarına ulaşabilmektedir (Karaman, Pacal, et al., 2023; Kolides et al., 2023; Kunduracioglu & Pacal, 2024; Ullah et al., 2022; Ullah, Usman, Latif, & Gwak, 2023). YZ, tedavi planlamasına yönelik daha doğru, veriye dayalı ve özelleştirilmiş bir yaklaşım geliştirdikçe, paradigma hasta merkezli sağlık hizmeti yöntemlerine doğru kaymaktadır. Bu, tıbbi müdahalelerin her hastanın özelliklerine uygun bir şekilde tasarlanıp sunulduğu bir zamana işaret etmektedir (Faizyuddin et al., 2025; Johnson et al., 2021; Paul et al., 2021).

Derin öğrenme destekli teknikler, özellikle işleme hızının kritik önem taşıdığı ve yanlış yorumlamanın ciddi maliyetler ve riskler doğurabileceği biyolojik görüntü analizi gibi alanlarda büyük fayda sağlamaktadır (Karaman, Pacal, et al., 2023). Bilgisayar destekli yaklaşımlar, üretkenliği ve teşhis doğruluğunu artırarak geleneksel tıbbi görüntü analiz yöntemlerinin yerini almaktadır. Derin öğrenme tabanlı bilgisayar destekli tanı (CAD) çözümlerinin etkinliği, bu alanı araştırmacılar için önemli ve aktif bir çalışma alanı hâline getirmiştir (Ullah, Usman, Latif, et al., 2023).

CAD uygulamalarında, derin öğrenme algoritmaları—özellikle Evrişimli Sinir Ağları (CNN’ler)—geleneksel makine öğrenimi yöntemlerine kıyasla önemli bir ilerlemeyi temsil etmektedir (M. A. Lubbad et al., 2024). Geleneksel teknikler genellikle yalnızca zaman alıcı değil, aynı zamanda alan uzmanlarının uzmanlığına da büyük ölçüde bağımlı bir süreç olan elle hazırlanmış özelliklere dayanmaktadır. Bununla birlikte, CNN’ler, ilgili özellikleri görüntülerden otonom bir şekilde çıkararak ve emek yoğun özellik mühendisliğine olan ihtiyacı etkili bir şekilde atlayarak bu alanda kayda değer nitelikte bir iş başarabilmektedir.

CNN’lerin üstünlüğü, özellikle tıbbi görüntü analizinde daha iyi performanslarıyla öne çıkmaktadır (Krizhevsky et al., 2017; LeCun et al., 2015). Örneğin, CNN’ler çeşitli beyin tümörü tiplerini ve diğer tıbbi durumları yüksek doğrulukla tanımlayabilmektedir. Bu modellerin en önemli avantajı, kritik bilgileri doğrudan görüntülerden çıkarabilme yeteneğidir, bu da özellik seçiminde insan müdahalesine olan ihtiyacı ortadan kaldırabilmektedir (Pacal, 2024a). Bu otomatik özellik çıkarma yeteneği yalnızca bilgisayar destekli tanı sürecini kolaylaştırmakla kalmaz, aynı zamanda doğruluğunu ve verimliliğini de artırır (Celard et al., 2023; Pacal & Kılıcarslan, 2023; Wang et al., 2021).

CNN’leri kullanarak, CAD sistemleri tıbbi görüntüleri hassas bir şekilde hızlı ve güvenilir bir şekilde kategorize edebilir ve böylece daha hızlı teşhis ve tedavi kararları kolaylaştırılabilir (Karaman, Karaboga, et al., 2023). Bu özellik, klinisyenlere ham verilerden türetilen değerli içgörüler sunarak hasta bakımında daha bilinçli kararlar alınmasını olanak sağlamaktadır (Pacal & Karaboga, 2021).

CNN'lerden farklı bir mimari sunan görüntü dönüştürücüler, beyin tümörleri gibi karmaşık tıbbi durumların analizinde umut vaat eden sonuçlar göstermiştir (Çelik & İnık, 2024). CNN'lerin aksine, görüntü dönüştürücüler bir dikkat mekanizması kullanarak görüntü yamaları arasındaki uzun menzilli bağımlılıkları yakalayabilmekte ve karmaşık görsel örüntüleri daha etkili bir şekilde modelleyebilmektedir. Bu mimari özellikle doğal dil işleme alanında başarılı olmuş ve son yıllarda bilgisayarlı görü görevlerinde de dikkat çekmiştir. Beyin tümörü sınıflandırması bağlamında, görüntü dönüştürücüler hem küresel (bilgisayar biliminde genel anlamında kullanılır) hem de yerel (lokal) özellikleri entegre ederek daha kapsamlı ve hassas bir analiz sunmaktadır. Bu yetenek, tıbbi görüntülerdeki ince detayları ayırt etmede önemli bir avantaj sağlamakta ve tanı doğruluğunu artırmaktadır (Pacal, 2024b).

Beyin tümörü sınıflandırmasında derin öğrenme modellerinin karşılaştığı başlıca sınırlılıklar arasında etiketli veri eksikliği, model optimizasyonu zorlukları, aşırı uyum (overfitting) ve sınıflar arası veri dengesizliği yer almaktadır. Bu kısıtlamalar, modellerin genel performansını ve klinik uygulanabilirliğini olumsuz etkileyebilmektedir. Özellikle, aşırı uyum modellerin genelleme yeteneğini zayıflatırken, yorumlanabilirlik eksikliği klinisyenlerin bu teknolojilere olan güvenini azaltabilmektedir. Ancak, bu sınırlılıklar aynı zamanda daha gelişmiş yöntemlerin ve stratejilerin geliştirilmesi için bir fırsat sunmaktadır.

Tıbbi görüntü tanıma ve segmentasyon alanında, özellikle manyetik rezonans görüntüleme (MRI) tabanlı beyin tümörü tespitinde, derin öğrenme teknolojileri önemli ilerlemeler kaydetmiştir. Bununla birlikte, mevcut yöntemler klinik ortamlarda etkinlik ve kabul açısından önemli sınırlamalarla karşı karşıyadır. Bu zorluklar arasında yeterli ve çeşitli veriye erişim eksikliği, erken evre tümörlerin tespitindeki yetersizlik, hastalar arası tümör görünümündeki yüksek varyasyon ve derin öğrenme modellerinin “kara kutu” niteliği bulunmaktadır. Özellikle şeffaflık ve yorumlanabilirlik eksikliği, klinik uygulamalarda güven oluşturmaya ve içgörülerin eyleme dönüştürülmesini zorlaştırmaktadır.

Bu araştırmanın temel motivasyonu sağlık hizmetlerinin kalitesini ve etkinliğini artırmak amacıyla yenilikçi teknolojilere odaklanmak ve yapay zekânın klinik karar destek sistemlerine entegrasyonunu örnek bir uygulamayla göstermektir. Bu bağlamda, bu tezin hipotezi, YZ tabanlı derin öğrenme modellerinin beyin tümörü teşhisinde radyologlara yardımcı olabileceği ve mevcut tanı yöntemlerine kıyasla daha yüksek doğruluk, hız ve tutarlılık sağlayabileceği yönündedir. Özellikle beyin tümörlerinin erken teşhisi, teşhis doğruluğunun artırılması ve hasta sağkalım oranlarının iyileştirilmesi bu çalışmanın odak noktasıdır. Ayrıca, dikkat mekanizmalarının CNN mimarilerine entegre edilmesiyle geliştirilen hibrit bir model, literatürdeki

performans açığını kapatmayı hedeflemektedir.

Araştırma özellikle aşağıdaki temel katkılarla öne çıkmaktadır:

- Öncelikle sağlık bilişimi alanındaki yenilikçi teknolojilerden bahsetmekle birlikte bu alandaki güncel literatür taranmış ve güncel istatistiki bilgilerle bu alandaki ilerlemelerin haritası ortaya konulmaya çalışılmıştır.
- İkinci bölümde sağlıkta YZ ve ilgili gelişmeler ele alınmış ayrıca bu alandaki tartışmalı noktalar güncel literatür bağlamında değerlendirilmiş ve yapay zekânın klinik süreçlere entegrasyonunun etik ve pratik tartışmaları irdelemiştir.
- Üçüncü bölümde ise YZ kullanılarak sağlıkta bir uygulama örneği geliştirilmiştir. Bu uygulamanın (beyin tümörü otomatik sınıflandırma modeli) literatüre katıları aşağıdaki gibi özetlenmiş;
 - Önerilen model, erken evre tümörlerin ince özelliklerini tespit edebilme yeteneğiyle mevcut modellerden ayrılmaktadır.
 - Dikkat mekanizmaları sayesinde, model farklı hasta popülasyonlarındaki tümör çeşitliliğine uyum sağlayabilmektedir.
 - Hastalar arasında tümör görünümündeki değişkenlik zorluğunu ele alan modelin, dikkat mekanizmalarının uygulanmasıyla beyin tümörü teşhisi için yeniden tasarlanması, geniş bir yelpazedeki tümör sunumlarına etkili bir şekilde uyum sağlamasını ve sınıflandırmadaki genelleme yeteneğini önemli ölçüde artırmasını sağlayabilmektedir.
 - Geniş bir kamu veri setinde %99,76 test doğruluğu elde edilerek, klinik uygulamalarda hata payının azaltılması hedeflenmiştir.
 - Dikkat mekanizmalarını EfficientNetv2 (Tan & Le, 2021) çerçevesine entegre eden çalışma, MRI taramalarındaki beyin tümörü görüntülerinin karmaşıklıkları için özel olarak tasarlanmış gelişmiş bir CNN mimarisi sunmaktadır. Küresel Dikkat Mekanizması (GAM) (Y. Liu et al., 2021) ve Verimli Kanal Dikkatinin (ECA) (Wang et al., 2020) dahil edilmesi, derin öğrenme modellerine yönelik yenilikçi bir yaklaşımı temsil etmektedir.

Tezin son bölümü şu şekilde düzenlenmiştir; derin öğrenme tekniklerini kullanan beyin tümörleri üzerine yapılan çalışmaları inceleyen bir literatür taraması yürütülmüş ve yaklaşımda kullanılan materyallerin, veri kümelerinin ve önerilen çerçevenin kapsamlı bir açıklaması ve kullanılan tüm modellerin kısa bir analizi sunulmuştur. Ayrıca hem nicel hem de nitel çalışmaları kapsayan önerilen yaklaşımın kapsamlı bir performans değerlendirmesi sunulmuş ve YZ modellerinin karar alma sürecine değerli içgörüler sunmada Grad-CAM yöntemlerinin önemini vurgulanmıştır. Ek olarak, beyin tümörü

sınıflandırma modellerinin karşılaştırmalı bir analizini içermektedir. En son bölümde ise önerilen yaklaşımdan elde edilen sonuçlar tartışmaktadır.

BÖLÜM I:

SAĞLIK BİLİŞİMİ VE KARAR VERME

1.1. Sağlık Bilişimi ve Dijitalleşme

Bilimsel literatürde, elektronik dijital bilgisayarların tıbbi uygulanmasıyla ilgili ilk referanslar, biyomühendislik yayınlarında 1950’lerin sonlarında ortaya çıkmıştır. O zamanlar biyomühendislik terimi, biyoloji, mühendislik ve teknolojinin tüm yönlerini kapsamaktadır. Sonraki yirmi yıl boyunca bu yeni disipline, elektronik veri işleme veya otomatik veri işleme gibi genel terimlerin yanı sıra, tıbbi bilişim, tıbbi bilgisayar bilimi, bilgisayar tıbbi, tıbbi bilgi bilimi, tıbbi yazılım mühendisliği ve tıbbi bilgisayar teknolojisi gibi alana özgü isimler de verilmiştir. Bu terimler genellikle değişken bir şekilde kullanılmış -örneğin, tıbbi bilgi bilimi ile tıbbi bilgisayar bilimi - sanki işlenen şey (bilgi) ve nasıl işlendiği (bilgisayar tarafından) benzer şekilde açıklamaktadır (Collen & Shortliffe, 2015).

İnsan, bilgi ve teknolojinin etkileşiminden bilişim ortaya çıkmıştır. Kavramsal olarak Türk Dil Kurumu bilişimi; *“İnsanoğlunun teknik, ekonomik ve toplumsal alanlardaki iletişimde kullandığı ve bilimin dayanağı olan bilginin özellikle elektronik makineler aracılığıyla düzenli ve akla uygun bir biçimde işlenmesi bilimi; enformatik”* şeklinde tanımlamaktadır (TDK, 2025).

Köken olarak bu terim 1957’de Almanya’dan Karl Steinbuch veya 1962’de Fransa’dan Philippe Dreyfus’a atfedilmiştir. Avrupa’da bu terim, bilginin kullanımıyla ilgili bilgi işlem (sayısal hesaplama) sorunlarına odaklanmıştır, bu da günümüzde özellikle sağlık bağlamında kullandığımız anlamdan biraz farklıdır. Sağlık bilişimi kavram olarak 1973 yılında, tıbbi bilişim terimi ise ilk olarak 1974’te kullanıldığı düşünülmektedir (Hersh, 2022).

1970’lerin başlarında bu yeni alan için bir isim üzerinde anlaşmanın gerekliliği ortaya çıkmıştır. O zamanlar tıp ve tıbbi terimler üzerinde anlaşmak özellikle tartışmalı değil, çünkü herhangi bir standart sözlük bu terimleri hastalıkları önleme, teşhis etme ve tedavi etme araştırması, öğretimi ve uygulaması ile ilgili olarak tanımlamaktadır. Ancak, yıllar içinde bazı profesyoneller, disiplinin hastalıkları tedavi etmek kadar sağlığı korumak ve hastalığı önlemekle ilgili olduğunu iddia ederek, sıfat olarak sağlık tercih ettiklerini açıkça belirtmişlerdir (Collen & Shortliffe, 2015).

2000’li yıllardan bu yana, bilişim genişledikçe tıbbi bilişim fikri de dünya çapında popülerlik ve kullanım kazanmıştır. Ancak biyoinformatik konusu büyüdükçe, “sağlık bilişimi” ve “sağlık hizmetleri bilişimi” isimleri, bu alanın sadece tıp uzmanlarını değil, aynı zamanda diğer sağlık ve yaşam bilimleri uzmanlarını da kapsadığını ifade etmek için daha yaygın olarak kullanılmaya başlanmıştır (Demirhan & Güler, 2011).

Sağlık Bilişimi birden çok alanın birleşmesi ve etkileşiminden doğmuştur. Bu alanlar tıp, bilgisayar bilimleri ve sağlık kurumları gibi yoğun bir şekilde veri üreten, işleyen ve bunları çeşitli iş süreçlerine entegre eden uygulamalı alandır. Bu yüzden multidisiplinerdir. Coiera sağlık bilişimini sağlık hizmetlerinin mantığı olarak ifade etmiştir (Coiera, 2015). Başka bir tanımda ise ABD Sağlık Bakanlığı sağlık bilişimini “sağlık hizmetleri sunumunda, yönetiminde ve planlamasında BT tabanlı yeniliklerin tasarımı, geliştirilmesi, benimsenmesi ve uygulanmasına yönelik disiplinler arası bir çalışma” şeklinde ifade etmektedir.




Şekil 1. Sağlık Bilişimi ve Dijitalleşme ile İlgili-İlişkili Alanlara Hardy “Health Informatics: An Interprofessional Approach” 3. Baskısından Faydalanarak Hazırlanmıştır (Hardy, 2023)

Şekil 1’de de görüleceği üzere, sağlık bilişimi ve sağlık alanında dijitalleşme, multidisipliner bir perspektifle ele alındığında oldukça kapsamlı ve çok boyutlu bir yapı sergilemektedir. Özellikle veri kaynaklarının artması ve bu

verileri işlemeye olanak sağlayan güçlü bilgi işlem sistemlerinin gelişmesi, sağlık alanında bilgi temelli sistemlerin kurulmasını ve uygulamalı problemlerin çözümünde yaygın bir şekilde kullanılmasını mümkün kılmaktadır. Büyük veri ve yapay zekâ gibi yeni teknolojilerin klinik karar destek sistemlerinin entegrasyonu özellikle hekimlerin hızlı ve doğru karar vermelerine imkân tanımaktadır. Bu bağlamda sağlıkta dijitalleşmeyle birlikte sağlık hizmetlerinin sunumunda zaman ve mekân mevhumları giderek değişmektedir. Sağlık hizmetlerinde dijital dönüşüm, iş süreçlerinde değişiklikleri, verimlilik, maliyet düşüşlerini ve iyileştirilmiş hasta deneyimini teşvik ettiği için yeni iş modelleri geliştirmek için bir sıçrama tahtası olabilmektedir (Yang & Hsiao, 2009).

Bu alandaki hızlı gelişimin kapsamlı bir şekilde anlaşılabilmesi için, mevcut çalışmaların niceliksel boyutunun ortaya konulması da fayda vardır. Bu doğrultuda anahtar kavram olarak “sağlık bilişimi” veya “dijital sağlık” veya “tıp bilişimi” veya “sağlık bilgi sistemleri” veya “biyomedikal bilişim” gibi beş temel sağlık bilişimi kavramı seçilerek ve Scopus veri tabanı kullanılarak aşağıdaki bilgilere ulaşılmıştır.

Tablo 1. Scopus Veri Tabanında Sağlık Bilişimi ile İlgili Yapılmış 1962-2024 Yılları Arası Çalışmaların Sayısı
Yıllara Göre Doküman Sayıları (1962-2024)




Tablo 1’de gösterildiği gibi 1962-2024 yılları arasında yukarıda ifade edilen anahtar kelimeler kullanılarak toplam 70 bin 155 çalışmaya ulaşılmıştır. Bu

çalışmaların ağırlıklı kısmı son yirmi yılda yapılmıştır. Özellikle 2019 yılından sonra çok yoğun bir şekilde bu alanda akademik yayın yapılmıştır.


Tablo 2. Scopus Veri Tabanında 1962-2024 Yılları Arasında Sağlık Bilişimi Alan Bazlı Gösterimi

Konu Alanlarına Göre Doküman Sayıları



Tablo 3. Scopus Veri Tabanında 1962-2024 Yılları Arasında Sağlık Bilişimi Alan Bazlı Gösterimi

Konu Alanlarına Göre Doküman Dağılımı (%)




Tablo 2 ve 3'te alan bazlı olarak bakıldığında yapılmış çalışmaların %43,6 Tıp alanında olduğu görülmektedir. Yaklaşık %11,6 Mühendislik ve %11,0 Sağlık Profesyonelleri alanlarında yapılmıştır. Ayrıca Bilgisayar Bilimleri, Sos-

yal Bilimler, Hemşirelik ve Biyokimya, Genetik ve Moleküler Biyoloji alanlarında çalışmaların yapıldığı gösterilmektedir.

Tablo 4'te ise akademik literatürde yaygın kabul gören ve hızla gelişmekte olan sağlık bilişimi alanı, Web of Science veri tabanında da sistematik olarak incelenmiştir. Web of Science (WOS) veri tabanında 1980-2025 yılları arasında “sağlık bilişimi”, “dijital sağlık”, “tıp bilişimi”, “sağlık bilgi sistemleri” veya “biyomedikal bilişim” gibi anahtar kelimeleri aratıldığında, yaklaşık 24 bin 503 akademik araştırmanın bulunduğu ve 1980 yılında 5 ilk çalışmanın yayınlandığı görülmüştür. 2017 yılında konuyla ilgili 1084 akademik makale yayınlanırken, takip eden yıllarda yaklaşık dört kat artmıştır.

Tablo 4. Sağlık Bilişimi Araştırma Alanının Web of Science Analizi (1980-2025)



*Not: 2025 verileri veri toplama tarihine kadar olan yayınları içermektedir.

Sağlık bilişimi alanında yayın sayıları 2010-2019 döneminde önemli bir sıçrama göstermiş, tüm yayınların yaklaşık %45'i bu dönemde gerçekleşmiştir. 2020-2025 dönemi henüz tamamlanmamış olmasına rağmen, bu kısa sürede bile toplam yayınların %38,5'i yayınlanmıştır. Bu durum, alanın hızla büyümeye devam ettiğini göstermektedir.

Şekil 2: 2000-2024 Yılları Arası Yıllık Yayın Sayısı Değişimi



1.1.1. Elektronik Sağlık Kayıtları


Sağlıkta dijitalleşmenin temel bileşenlerinden biri Elektronik Sağlık Kayıtları (ESK) oluşturmaktadır. Bu sistemler, hasta bilgilerinin saklanması, yönetilmesi ve paylaşılması için dijital çözümler sunarak sağlık hizmeti sunumunun kolaylaştırmaktadır (Adeniyi et al., 2024). ESK hastanın tıbbi ve ilaç geçmişi, semptomları, şikayetleri, tedavisi, prosedürleri ve testleri, kesin tanısı, taburculuk ilaçları, tedavi notları veya sevk notları gibi hastalar hakkında

zaman içinde takip edilebilecek kısa bilgiler içermektedir (A. Ahmed et al., 2023). ESK'lerin etkinleştirilmesi, klinik karar verme altyapısını geliştirmek için heyecan verici beklentiler sunmaktadırlar. ESK laboratuvar sonuçları, doktor ilaçları ve klinik notlar gibi yapılandırılmış, yapılandırılmamış ve yarı yapılandırılmış gibi iki/üç biçimde veri üretmektedir (Johnson et al., 2016; Nuthakki et al., 2019).

1.1.2. Veri Analitiği ve Büyük Veri Uygulamaları

Büyük ve karmaşık veri kümeleri genellikle “büyük veri analitiği” olarak adlandırılır ve muazzam miktarda sağlık verisinin işlenmesi ve hasta bakım standardının yükseltilmesi için gereklidir (Fang et al., 2016). Gartner tarafından “büyük veri” şu şekilde tanımlanmaktadır; “gelişmiş içgörü ve karar verme için uygun maliyetli, yenilikçi bilgi işleme biçimleri gerektiren yüksek hacimli, yüksek hızlı ve yüksek çeşitliliğe sahip bilgi varlıklarıdır.” (Gartner, 2014) Veri, sağlık bilişimi ve sağlıkta dijitalleşmenin önemli bir tetikleyicisidir. Sağlık kuruluşları sağlık bilgilerini yönetmek, bakımı iyileştirmek ve sağlık hizmetlerine erişimi artırmak için büyük veri çözümlerinden yararlanmaktadır.

Dijital sağlık verileri, yeni teknolojilerin hızla gelişmesi nedeniyle son yıllarda önemli ölçüde artmıştır. Yeni tıbbi gelişmelerin yanı sıra giyilebilir cihazlar, mobil uygulamalar ve sensörler gibi teknolojik ilerlemeler sayesinde ek veri kaynakları mümkün hale gelmiştir. Sonuç olarak sağlık sektörü, Elektronik Sağlık Kayıtları (elektronik tıbbi kayıtları içeren) ve Kişisel Sağlık Kayıtları (tıbbi geçmiş, test sonuçları ve reçeteli ilaçlar) dahil olmak üzere tüm sağlık bilgisi kaynaklarından büyük hacimlerde dijital veri üretmektedir (Fang et al., 2016). Sağlık hizmetlerinde büyük veri yaşam döngüsü, verilerin toplanmasını, depolanmasını, güvenli ve etkili bir şekilde işlenmesini ve anlamlı içgörüler sağlayacak ve hasta sonuçlarını iyileştirecek şekilde analiz edilmesini sağlamak için dikkatli planlama ve yürütme gerektiren karmaşık bir süreçtir (Sukumar et al., 2015)



Şekil 2. 6G Sağlık Hizmeti Büyük Veri Analitiğinin Örnek Bir Modeli (Ahmad et al., 2023)

Büyük Veri Analitiği, makine öğrenimi, veri madenciliği ve tahmine dayalı analitik dahil olmak üzere bu zorlukların üstesinden gelmek için tasarlanmış bir teknik ve teknolojiler koleksiyonudur. Sağlık hizmetleri bağlamında, literatür genellikle İngilizce altı V'ye atıfta bulunur (A. Ahmed et al., 2023);

- Hacim (Volume): Sağlık hizmetlerinde üretilen ve toplanan büyük miktarda bilgiyi gösteren verilerin boyutunu ifade eder.

- Çeşitlilik (Variety): Yapılandırılmış, yapılandırılmamış ve yarı yapılandırılmış veriler gibi farklı veri türlerini ve biçimlerini kapsayan verilerin karmaşıklığını temsil eder.
- Hız (Velocity): Verilerin üretilme, iletilme ve işlenme hızını belirtir ve sağlık verilerinin gerçek zamanlı doğasını vurgular.
- Doğruluk (Veracity): Doğruluk, tutarlılık ve güvenilirlik gibi faktörleri göz önünde bulundurarak verilerin kalitesini ve güvenilirliğini ifade eder.
- Değer (Value): Verilerden elde edilebilecek bilgi ve içgörülerini temsil eder ve veri analizinin sağlık hizmetlerinde sağlayabileceği potansiyel faydaları ve eyleme geçirilebilir bilgileri vurgular.
- Değişkenlik (Variability): Verilerin değişkenliğini ve dinamik doğasını yansıtır, zaman içinde veri modellerinde ve özelliklerinde meydana gelen dalgalanmaları ve değişiklikleri hesaba katar.

Bu altı V, akademisyenlere ve uygulayıcılara sağlık hizmetlerinde büyük verinin temel yönlerini anlamaları için bir çerçeve sunarak verimli veri yönetimi ve analizini kolaylaştırmaktadır.

Son tahlilde sağlık bilişimi alanında büyük veri, hasta sonuçlarını iyileştirmek amacıyla büyük, karmaşık ve çeşitli veri kümelerini yönetmek, düzenlemek ve manipüle etmek için kullanılan araçlar, teknolojiler ve yöntemler topluluğunu ifade etmektedir. Sağlık bilişiminde büyük verinin temel avantajları üç ana başlıkta özetlenebilir: Birincisi, klinik karar destek sistemleri aracılığıyla hastaların zamanında ve etkin tedavisine olanak sağlayan geniş ölçekli veri analizi kapasitesi sunmasıdır. İkincisi, hastaya özgü tedavi protokolleri geliştirilmesine imkân vererek kişiselleştirilmiş tıp uygulamalarını mümkün kılmasıdır. Üçüncü ve en kapsamlı avantajı ise sağlık sisteminin tüm paydaşlarını (yönetim birimleri, ödeme kuruluşları, sağlık hizmet sağlayıcıları ve hastaları) kapsayan bütünlük bir veri ekosistemi oluşturmaktır (Fang et al., 2016).

1.1.3. Hastane Bilgi Sistemleri

Sağlık bilişimi ve dijitalleşmenin önemli bir başka birleşeni hastane bilgi sistemleridir. Hastaların randevu, muayene ve tedavi süreçlerini, idari ve mali süreçleri ve kurumun yatırım, planlama, etkinlik ve verimlilik gibi tüm kararla alma süreçlerini destekleyen karar destek sistemlerinin bütünüdür (Küçük & Çelik, 2023). Hastaneler, hasta bakımını koordine eden büyük departmanlar ve birimler içeren benzersiz özelliklere sahip son derece karmaşık yapılardır. Hizmet ve uygulamaları iyileştirmek amacıyla teşhis, yönetim ve eğitimi desteklemek için hastane bilgi sistemlerine (HBS) büyük ölçüde kullanılmaktadır (Abdelaziz & Rosa, 2024). Ayrıca, bu sistemler sağlık kurumundaki tüm

operasyonel süreçlerin entegre bir şekilde işlemlerini sağlamaktadır. Işık ve Akbolat'ın hastane bilgi sistemleri sınıflandırmasına göre, bu entegrasyon üç temel modül üzerinden gerçekleşmektedir: (1) klinik bilgi sistemleri, (2) idari ve mali sistemler, (3) stratejik karar destek sistemleri (Işık & Akbolat, 2010).

1.2. Karar Destek Sistemleri

Karar destek sistemi, bilgileri yöneterek, hatırlatıcılar ve uyarılar göndererek ve önerilerde bulunarak kullanıcıların karar vermelerine yardımcı olmak için tasarlanmış bir sistemdir. KDS, iş kararlarını desteklemeye ve iyileştirmeye odaklanan bilgi sistemleri alanı olarak bilinmektedir. Profesyonel uygulama açısından bakıldığında KDS; veri ambarı, iş zekası, çevrimiçi analitik işleme sistemleri, lider destek sistemleri, grup destek sistemleri ve bireysel karar destek sistemlerini kapsamaktadır (Arnott et al., 2004). Geleneksel KDS, kodlanmış insan uzmanlığına veya yetkili klinik yönergeler dayandırırken, YZ(AI)-KDS'deki bilgi tabanı kanıt sentezine değil, istatistiksel hesaplamalara veya desen tanımayaya dayanmaktadır (Cresswell et al., 2023). YZ-KDS'nin uzun bir geçmişi olmamasına rağmen, derin öğrenmedeki ilerlemeler ve artan bilgi işlem gücü, son yıllarda sağlık hizmetlerinde yapay zekaya olan ilginin hızla yeniden canlanmasına yol açmıştır (Scott et al., 2019). Bu, YZ tabanlı sistemlerin geliştirilmesi ve uygulanmasına yönelik hükümet ve özel sektör yatırımlarının yoğun bir şekilde yapılmasıyla birlikte gerçekleşmektedir.

Yukarda ifade edilen ilgiye rağmen uygulamada daha çok klinik veya dar hastane operasyonlarında kullanılmaktadır. Bu konuda yapılmış detaylı bir çalışmada 1997-2018 yılları arasında yayınlanan 3.397 makale taranmış, 80 makale analiz edilmiş ve yapay sinir ağlarının (YSA) (yapay zekânınım temeli budur) sağlık hizmetleri yönetiminde bir karar destek sistemi olarak kullanımı araştırılmıştır. Bulgular, YSA'nın sağlık hizmetlerini daha verimli ve ekonomik bir şekilde sunmak için en yaygın olarak mikro düzeyde kullanıldığını, ancak mezo ve makro düzeylerde kullanımının sınırlı olduğunu göstermektedir (Shahid et al., 2019). Bu durumun temel nedenlerinden biri, sağlık sistemlerinde saklanan büyük ölçekli verilerin kişisel verilerin korunması kanunu kapsamında olmasıdır. Söz konusu sistemlerdeki verilerin anonimleştirilerek araştırmacılar ve hizmet planlamacıları tarafından kullanılabilmesi büyük önem arz etmektedir.

1.3. Klinik Karar Destek Sistemleri

Sağlık kurumları, klinik karar destek sistemleri ve elektronik sağlık kayıtları gibi gelişmiş bilgisayar tabanlı sistemleri kullanarak hastalık teşhisi, tedavi planlaması ve hasta bakım süreçlerinde karar vericilere önemli destek sağlamaktadır. (Abdelaziz & Rosa, 2024). Klinik karar destek sistemleri (KKDS), sağlık kurumları tarafından sağlanan bakımın kalitesini artırma nihai hedefiyle sağlık hizmetlerinde karar verme sürecini iyileştirmeyi amaçlamaktadır (Montani & Striani, 2019; Osherooff et al., 2012).

Tıbbi çizelgelerdeki dijitalleşmenin kapsamını ve EKS sistemlerinin işlevselliğini anlamak, klinik ortamlarda kullanımlarını optimize etmek için çok önemlidir (Abdelaziz & Rosa, 2024). Klinikte yapay zekâ önerilerine güven, problemin karmaşıklığı, model performansı, veri kalitesi, popülasyon uyumu, aktarılabilirlik ve klinisyen denetimi gibi faktörlere bağlıdır (Cresswell et al., 2023).

Klinik Karar Destek Sistemleri (KKDS), sağlık profesyonellerinin hasta sonuçlarını tahmin etmelerine yardımcı olmak için Makine öğrenimi (ML) ve Derin Öğrenme destekli YZ uygulamalarını kullanmaktadırlar. Sağlık profesyonelleri, bu yeni KKDS'leri çok daha hızlı bir şekilde çok sayıda hasta verisine dayalı önerilerde bulunabilir. Bunu yaparken, daha kişiselleştirilmiş tedaviler, daha iyi hasta sonuçları ve daha düşük sağlık hizmeti maliyetleri sağlayabilirler (Kim, 2018).

BÖLÜM II:

SAĞLIK HİZMETLERİNDE YAPAY ZEKA

2.1. Yapay Zekâ

YZ, insan zekasının gerektirdiği düşünme, muhakeme ve analiz gibi bilişsel süreçleri gerçekleştirebilen makineler geliştirmeyi amaçlayan ve hızla ilerleyen bir bilgisayar bilimi dalıdır (Alowais et al., 2023). Yapay zeka tabanlı bilgisayar sistemleri, görsel algı, desen tanıma, konuşma tanıma, hızlı veri karşılaştırmaları ve projeksiyonları, diller arasında çeviri ve belirli seçenekler arasında karar alma gibi normalde insan bilişsel becerilerinin unsurlarını gerektiren görevleri gerçekleştirebilmektedir (Cresswell et al., 2023).

YZ, Christopher Strachey'nin 1951'de ilk YZ programını geliştirmesinden bu yana çok gelişmiştir. O zamanlar YZ henüz emekleme aşamasında ve öncelikli olarak akademik araştırmaların konusu olmuştur. 1956'da John McCarthy Dartmouth Konferansı'na ev sahipliği yaptığı zaman ve ilk olarak burada "Yapay Zeka" terimini ortaya konulmuştur. Bu olay, yapay zekanın modern çağının başlangıcını işaret etmektedir. 1960'larda ve 1970'lerde YZ araştırmaları kural tabanlı sistemlere ve uzman sistemlere odaklanmıştır. Ancak bu yaklaşım daha fazla hesaplama gücüne ve veriye duyulan ihtiyaç nedeniyle sınırlı kalmıştır (McCorduck & Cfe, 2004).

Tablo 5'te belirtildiği gibi YZ çeşitli alanlarda birbirinden farklı uygulamalarla gelişme göstermiştir. Ancak, özellikle son on yılda birçok multi-medya cihaz ve ortamdan elde edilen veriler ve güçlü bilgisayarlar sayesinde devrimsel nitelikte bir popüler teknolojiye dönüşmüştür. Bu teknoloji, yoğun bilgi ve gerçek zamanlı çözümlerle birlikte kullanılması, çok değişkenli ve çok katmanlı olan sağlık alanında hızlı bir şekilde kullanılmaya başlanmıştır.

Tablo 5. Yapay Zekâ'nın Tarihsel Yolculuğu (Alowais et al., 2023)

Yıl	Önemli Olay	Açıklama
1942	Enigma yapay zekâ ile kırıldı	Enigma kodunun yapay zekâ kullanılarak kırılması.
1950	Alan Turing'in makine zekâsı testi	Turing Testi'nin başlangıcı.
1955	Yapay zekânın babası- John McCarthy	John McCarthy'nin "Yapay Zekâ" terimini ortaya atması.

1964	İlk chatbot - Eliza	İlk chatbot'un tanıtımı.
1995	Chatbot ALICE	Doğal dil işleme chatbot'u ALICE'in geliştirilmesi.
1997	İnsan vs. Makine- DeepBlue satranç efsanesini yenmiştir.	IBM'in DeepBlue bilgisayarının satranç büyükustası Garry Kasparov'u yenmesi.
1998	Duygusal donanımlı robot- Kismet	Duyguları tanıma ve tepki verme yeteneğine sahip bir robotun oluşturulması.
2008	Ses tanıma özelliği	Konuşma tanıma teknolojilerindeki ilerlemeler.
2011	Soru-cevap bilgisayar sistemi- IBM Watson	IBM Watson'ın "Jeopardy!" yarışmasında insan rakipleri yenmesi.
2020	Otomatik konuşmalar için devrim niteliğinde bir araç- GPT modelleri	Gelişmiş dil modelleri olan GPT gibi modellerin yükselişi.
2021	AlphaFold 2 ile protein katlanma problemi çözüldü	DeepMind'in AlphaFold 2 ile protein yapılarını yüksek doğrulukla tahmin etmesi, tıpta büyük bir ilerlemeye neden olmuştur.
2022	DALL-E 2 ve görsel üretim modelleri	Metinden görsel üreten AI modellerinin (DALL-E 2, MidJourney) sanat ve tasarım alanında yaygınlaşması.
2023	ChatGPT'nin küresel etkisi ve AI etiği tartışmaları	OpenAI'nın ChatGPT'sinin toplumsal adaptasyonu ve AI düzenlemelerine yönelik küresel çağrılar.
2024	Yapay Zekâ Ajanlarının Yükselişi	Gelişmiş yapay zekâ ajanları, karmaşık görevleri bağımsız olarak yerine getirerek iş süreçlerini optimize etmektedir.
2025	Kişiselleştirilmiş tıp ve AI destekli tedavi planlaması	Hastalık teşhisi ve tedavi planlamasında AI'nın doktorlarla entegre çalışması, kişiye özel tıp uygulamaları.

Sağlık verilerinin artan bulunabilirliği ve analitik tekniklerin hızla ilerlemesiyle desteklenen sağlık hizmetleri bir paradigma değişimi ile karşı karşıyadır (Jiang et al., 2017). Sağlık alanında, ümit verici sonuçlar gösteren son YZ gelişmeleri, özellikle radyolojide görüntü analizi ve yorumlama gibi klinisyen odaklı uygulamalar için veri odaklı yaklaşımlardır sunmaktadır (Lau & Staccini, 2019; Shaban-Nejad et al., 2018; Ventola, 2014).

YZ'nin sağlık hizmetlerinde, özellikle tanısal radyoloji alanında genişlemesi, hasta bakımının kalitesini ve verimliliğini artırmak için benzeri görül-

memiş fırsatlar sunmaktadır (Najjar, 2023). Örneğin, Nature Medicine’da 2025 yılında yayınlanmış bir çalışmada, Almanya’daki ulusal mamografi tarama programında YZ destekli 12 farklı merkezde gerçekleştirmiş, 119 radyolog katıldığı ve toplam 463,094 kadının mamografi taraması incelendiği araştırmada YZ destekli tarama grubunda meme kanseri tespit oranı 6.7/1,000 olarak bulunmuştur. Bu oran, geleneksel yöntemle göre %17,6 daha yüksek ve istatistiksel olarak anlamlı olduğu ortaya konulmuştur (Eisemann et al., 2025). Aynı zamanda, radyologların iş yükünü azaltma potansiyeline de sahip olduğu belirtilmiştir.

Sağlık hizmetlerinde YZ üzerine yapılmış bir kapsam belirleme çalışmasında; YZ’nin sağlık hizmetlerinde önemli bir dönüşüm yaptığı, hastalık teşhisinde yüksek doğruluk sağladığı, tedavilerin kolayca kişiselleştirilebileceği ve öngörücü analitik ile riskleri önceden belirleyebildiği bulunmuştur. Ayrıca, YZ destekli araçlar iş akışlarını düzenleyerek verimliliği artırırken, robotik teknolojiler rehabilitasyon ve cerrahi görevleri otomatikleştirerek bakım kalitesi iyileştirdiği tespiti yapılmıştır (Olawade et al., 2024). Örneğin Kanada yapılmış bir bilimsel çalışmada; yoğun bir şekilde YZ uygulamalarını kullanan Humber River Hastanesi, ilaç sipariş ve dağıtım sürecinde yüksek teknoloji kullanarak hata oranını neredeyse sıfıra indirmiştir. Hastane, dijital sistemler ve otomatik robotlar sayesinde %0,0001 gibi son derece düşük bir ilaç hatası oranına ulaşmış, bu da sağlık sektöründe yüksek doğruluk ve güvenlik sağlamak için etkili bir yöntem olduğunu göstermektedir (Dicuonzo et al., 2023).

Geçtiğimiz on yıl içinde, tıptaki gelişmelerin hızlanmasının arkasında büyük bir veri patlaması yatmaktadır. Giyilebilir sensörlerden, tıbbi görüntüleme cihazlarına, kişisel sağlık kayıtlarından kamu sağlığı kuruluşlarına kadar birçok kaynaktan gelen sağlık verileri, muazzam bir artış göstermiştir. Bu verilerin işlenmesi ve analiz edilmesi, bulut bilişim, GPU’lar, FPGA’lar ve TPU’lar gibi güçlü hesaplama donanımları sayesinde daha etkili bir şekilde gerçekleştirilebilmektedir. Sonuç olarak, bu büyük veri yığınlarından değerli bilgiler elde edebilmek için esnek, hızlı ve karmaşık YZ teknikleri geliştirilmektedir. Bu ilerlemeler, sağlık alanında daha doğru ve hızlı çözümler üretilmesini sağlamaktadır (Hayat et al., 2024).

YZ’nin etkisi, tıbbi görüntüleme ve teşhis hizmetlerinde klinik durumların tespit edilmesinde, erken tanı ile koronavirüs hastalığı 2019 (COVID-19) salgınının kontrol altına alınmasında, YZ destekli araçlar kullanılarak sanal hasta bakımı sağlanmasında, elektronik sağlık kayıtlarının yönetilmesinde, hasta katılımının ve tedavi planına uyumun artırılmasında, sağlık çalışanlarının idari iş yükünün azaltılmasında, yeni ilaçlar ve aşılar keşfedilmesinde, tıbbi reçete hatalarının tespit edilmesinde, kapsamlı veri depolama ve analizi ile teknoloji destekli rehabilitasyonda kullanıldığı gözlemlenmektedir (Al Kuwaiti et al., 2023).

2.1.1. Makine Öğrenmesi

Dijital görüntü elde etme ve depolama tekniklerinin hızla yayılmasıyla birlikte, görüntülerin bilgisayar programları aracılığıyla yorumlanması, makine öğrenimi ve uygulamaya özgü araştırmalarda meraklı ve aktif bir konu haline gelmiştir (Helaly et al., 2024). Makine öğrenimi, en basit haliyle istatistiksel modellerin bilgisayarlar kullanılarak verilere uygulanmasıdır. Makine öğrenimi, tıpta tipik olarak kullanılanlardan daha geniş bir istatistiksel teknikler kümesi kullanılmaktadır (Panch et al., 2018).

Bir çalışmada altı makine öğrenmesi yaklaşımının beş yıllık sağ kalım tahmin performansları araştırılmış ve modellerin yüksek performansı, hassas tahmin yapılmasına aynı zamanda hastalara uygun tedavi önerilerinin sunulmasına yardımcı olabileceği bulunmuştur (Makond et al., 2021). Başlangıçta, sağlık hizmetlerindeki YZ uzman tıbbi bilgiye ve sağlam karar kurallarının formülasyonuna dayanmaktaydı. Günümüzde, karmaşık ilişkileri dikkate alan makine öğrenimi teknikleri, sağlık verilerini tanımak ve değerlendirmek için yapay zeka tarafından kullanılmaktadır (Deo, 2015; Dicuonzo et al., 2023).

2.1.2. Derin Öğrenme


Bir yükselişi temsil eden bir başka yapay zeka teknolojisi, birden çok katmana sahip sinir ağlarını içeren bir makine öğrenimi alt kümesi olan derin öğrenme modelleridir. Buradaki “derin” terimi katman sayısındaki çokluğa atıf olarak kullanılmaktadır (Elhaddad & Hamam, 2024). Derin öğrenme, insan beyninin karmaşık karar verme mekanizmasını modellemek için çok katmanlı yapay sinir ağlarına dayanan bir makine öğrenimi yöntemidir (Goodfellow et al., 2016; LeCun et al., 2015). Yapay Sinir Ağları büyük miktardaki verilerden öğrenme yeteneği olan derin öğrenmenin temelidir (Nielsen, 2015; Schmidhuber, 2015). Ağlar veya derin sinir ağları, birbirine bağlı olan ve ileri yayılma ve geri yayılma olarak bilinen süreçler yoluyla tahminleri veya sınıflandırmayı adım adım yineleyen ve iyileştiren birçok düğüme sahip katmanlardan oluşur (Russell & Norvig, 2016). Derin öğrenme modelleri, özellikle girdi öznitelikleri olarak ‘ham’ klinik zaman serisi verilerini kullanırken diğer tüm stratejilerden daha iyi performans gösterir (A. Ahmed et al., 2023).

Geleneksel makine öğrenimi algoritmaları tipik olarak etiketlenmiş ve biçimlendirilmiş verilere dayanırken, derin öğrenme modelleri ham ve yapılandırılmamış verileri işleyebilir (Esteva et al., 2017; Litjens et al., 2017). Bu yetenek onları son derece uyarlanabilir ve güçlü kılmaktadır (Miotto et al., 2018). Bu yetenekleri nedeniyle derin öğrenme, sağlık hizmetleri de dahil olmak üzere çeşitli sektörlerde kapsamlı bir şekilde uygulanmış ve hasta bakımı ve hastane protokollerini önemli ölçüde iyileştirmektedir (Rajkomar et al., 2018; Topol, 2019).

2.1.3. Derin Öğrenme ve Sağlık Hizmetleri

Derin öğrenme teknolojileri, çoğunlukla sağlık hizmetleri ortamında, elektronik sağlık kayıtlarının (ESK)'lerin ve diğer eşlik eden sağlık verilerinin işlenmesinde kullanılmaktadır. Bu yazılım, insan zekasının yönetemediği örüntü ve eğilimleri tanıma yoluyla tanı, teşhis ve tedaviyi iyileştirme yeteneğine sahiptir (Alowais et al., 2023). Örneğin, klinik gözlemler, laboratuvar raporları ve görüntüleme testleri, hastanın durumu hakkında bilgilendirici veriler, derin öğrenme algoritmaları tarafından analiz edilebilmektedir (Rajkomar et al., 2018; Solares et al., 2020). Bu bağlamda, sağlık bilişiminde yapay zekayı uygulamak daha kolay olmakla kalmaz, aynı zamanda kanıta dayalı önerilerle klinik karar verme süreci de kolaylaştırmaktadır (Giordano et al., 2021; Secinaro et al., 2021).

Derin öğrenmenin sağlıkta en umut verici uygulama alanlarından biri tıbbi görüntüleme alanıdır (Chen et al., 2024; Khalifa & Albadawy, 2024). Derin öğrenmenin görüntü işleme kısmında CNN'ler kullanılmaktadır. Konvolüsyonel sinir ağları (CNN'ler) röntgen, MRI ve BT taramaları gibi tıbbi görüntülerin işlenmesinde son derece etkilidir (Sarvamangala & Kulkarni, 2022; Upreti et al., 2021). Modeller anormallikleri büyük bir doğrulukla tespit edebilir (Eisemann et al., 2025). Örneğin, derin öğrenme diyabetik retinopati, erken evre Alzheimer hastalığı (Wang et al., 2024) ve meme kanseri gibi hastalıkları tespit etmek için kullanılmıştır (Chen et al., 2024; Khalifa & Albadawy, 2024). Derin öğrenme, tıbbi görüntüleri otomatik olarak işleyerek radyologların (Eisemann et al., 2025) ve patoloğların yükünü azaltmakta, daha karmaşık vakalara odaklanmalarını sağlamakta ve genel olarak teşhis verimliliğini artırmaktadır (Montagnon et al., 2020).



Şekil 3. Sağlıkta Derin Öğrenmenin Yöntem ve Uygulama Örnekleri (Helaly et al., 2024)

Derin öğrenme modelleri, geçmişteki hasta geçmişlerini öğrenerek hastalığın gelişimini ve hasta sonuçlarını tahmin edebilir ve bu da önleme ile sonuç-

lanabilir. Örneğin, YZ, öngörücü modeller aracılığıyla diyabet ve kardiyovasküler hastalık gibi kronik hastalıklar geliştirme riski taşıyan duyarlı hastaları belirleyebilir ve klinisyenlere önleyici müdahalelerin nasıl uygulanacağı konusunda tavsiyelerde bulunabilir (Grout et al., 2024; Wang et al., 2024). Derin öğrenme, her hastanın benzersiz gereksinimlerine göre tedaviyi kişiselleştirmek amacıyla genetik verileri deşifre etmek için de kullanılmaktadır. Bu uyarlanmış süreç, tedavinin etkisini optimize etmenin yanı sıra yan etkileri de en aza indirir (Taherdoost & Ghofrani, 2024; Unger & Kather, 2024).

Günümüz sağlık hizmetlerinde hataları, kusurları, eksiklikleri düzeltmek için derin öğrenmenin maksimum yeteneklerinden yararlanmak için sağlık uygulayıcıları ve araştırmacılar arasında daha fazla işbirliğine ihtiyaç vardır. Çünkü yapay zekayı sağlık hizmetlerine entegre etmek, hastalık teşhisini, tedavi seçimini ve klinik laboratuvar testlerini iyileştirmek için mükemmel bir potansiyele sahiptir (Alowais et al., 2023). Sağlık bilişiminde ve YZ'da derin öğrenmenin kullanılması, sağlık hizmetleri sunumunda bir devrim niteliğindedir. Derin sinir ağlarının gücünden yararlanma kapasitesiyle, sağlık kuruluşları teşhis hassasiyetini optimize edebilir, operasyonları geliştirebilir ve hasta merkezli bakım sağlayabilir. Derin öğrenme teknolojilerindeki son teknolojik ilerlemeyle birlikte, bu tür kullanımlar artacak ve hastalarda daha iyi sonuçlar elde edilmesini sağlamada sağlık hizmetleri üzerinde önemli bir etkiye sahip olacaktır.

2.2. Sağlık Yönetimi ve Yapay Zekâ İlişkisi

Sağlık yönetimi, sağlık hizmetlerinin planlanması, organize edilmesi, yönetilmesi ve değerlendirilmesi süreçlerini kapsayan bir disiplindir. Temel amacı sağlık hizmetlerinin kalitesini artırırken maliyetleri optimize etmek ve hasta sonuçlarını iyileştirmektir. Sağlık hizmetlerinde verimlilik ve etkin maliyet yönetimi, YZ teknolojilerinin entegrasyonu ile önemli ölçüde iyileştirilebilir. YZ, klinik süreçlerden operasyonel verimliliğe kadar geniş bir yelpazede sağlık hizmetlerini dönüştürme potansiyeline sahiptir.

Günümüzde sağlık yönetimi, teknolojik yeniliklerle önemli bir dönüşüm geçirmektedir. Bu dönüşümün yaşanmasında etkili olan bazı sebepler vardır. Bunlardan biri sağlık bilgi sistemlerinde elde edilen veriler ve bu verilerin her an ve her yerde kayıt altına alınmasından kaynaklanmaktadır. Özellikle sağlık kurumları mevcut teknolojik sistem ve imkanlar açısından birer veri deposu görevi gördüğü söylenebilir.

Verinin önemini ifade etmek için *“veri bu çağın yeni petrolüdür”* (Humbly, 2006) tanımları yapılmaktadır. Bu noktadan hareketle sağlık hizmetlerinin daha etkin planlanması, daha hızlı organize edilmesi, verimli ve etkin yönetilmesi için sağlık kurumlarında ve sağlık sistemlerinde tutulan verilerden anlamlı ve tutarlı sonuçlar ortaya koymak YZ teknolojisinin yeni ve ekili analiz

teknik yöntemleri ile mümkün olabilmektedir. Çünkü yapay zekâ teknolojisi veri odaklı bir teknolojidir. YZ'nin, teşhis veya klinik karar vermeyi desteklemek için büyük miktarda veriyi dönüştürerek sağlık hizmetlerini yeniden düşünme yeteneği göz önüne alındığında, gelecekteki sağlık sistemlerini etkilemesi kaçınılmazdır (Kastrup et al., 2024). Şekil 4'te yukarıda ifade edilen bağlamdan hareketle Sağlık Yönetimi ve YZ etkileşiminin yoğunlaştığı alanlar ve araştırmanının teorik arka planı gösterilmeye çalışılmıştır.



Şekil 4. Sağlık Yönetimi ve Yapay Zekâ

Sağlık yönetimin önemli bir hedefi olan kaliteli sağlık hizmeti amacına ulaşılması YZ ile daha hızlı ve daha doğru bir şekilde mümkün olabilir. Çünkü sağlık hizmetlerinde kalitesizliğe sebep olan nedenler YZ teknolojisiyle çözümü mümkündür. Örneğin hastane hasta akışı YZ ile optimize edilebilir. Bu şekilde hastaların ve sağlık çalışanlarının zaman ve bekleme süreleri daha optimum seviyelerde tutulabilir. Diğer taraftan, hatalı tanı, teşhis ve tedavi süreçlerine YZ algoritmalarını entegrasyonu umut vaden sonuçlar sunmaktadır. Bölüm üçte bunun detayları mevcuttur.

Sağlık hizmetlerinin hizmet akışında Klinik Karar Destek Sistemleri önemli bir yer tutmaktadır. YZ algoritmalarının KKDS'lere entegrasyonu ile

hasta verileri daha kolay analiz edilebilir ve tedavi kararlarında hekimlere yardımcı asistan işlevinde kullanılabilir. Bu ifadeleri destekleyecek kanıt niteliğinde bir çalışma 2024 yılında yapılmış bir sistematik literatür YZ-KK-DS'e entegrasyonu, klinisyenlere modern tıbbın karmaşıklıklarında gezinmede yardımcı olan bilişsel bir yardımcı görevi görebileceği sonucu bulunmuştur. Ayrıca aynı çalışmada; Makine öğrenimi, doğal dil işleme (NLP) ve derin öğrenme dahil olmak üzere yapay zeka teknolojileri, KKDS'lerin yeteneklerinde önemli bir katkı yaparak büyük miktarda sağlık verisini benzeri görülmemiş bir hız ve doğrulukla işlemesini ve yorumlamasını sağladığı sonucuna ulaşılmıştır (Elhaddad & Hamam, 2024).

Sağlık hizmetlerinde giderek önemi artan kişiselleştirilmiş tıp yaklaşımı YZ'a teknolojinin sunduğu imkanlarla hastaların genetik yapısı, yaşam tarzı ve tıbbi geçmişi gibi faktörleri analiz ederek kişiye özel tedavi planları oluşturmaya katkı sağlayabilmektedir. Özellikle, Üretken YZ'a ile üretilen yüksek kaliteli sentetik veriler, tanısal doğruluğu artırarak ve kişiselleştirilmiş tedavi planlarının geliştirilmesini kolaylaştırarak kişiselleştirilmiş sağlık hizmetlerinin geliştirilmesine katkıda bulunabilmektedir (Ghebrehiwet et al., 2024). Üretken YZ, eğitilmiş parametrelerden yeni içerik oluşturmak için tasarlanmıştır (Raza et al., 2024). Bu konuda yapılan bir detaylı araştırmada, klinik ortamda kullanılan Üretken YZ modelleri için değerlendirme kontrol listesi bile hazırlanmıştır (Wornow et al., 2023).

YZ'nin sağlık hizmeti sunumunu optimize etme yeteneği dikkat çekicidir. YZ güdümlü tahmine dayalı analitik, hastane iş akışlarını iyileştirebilir, hasta kabul oranlarını doğru bir şekilde tahmin edebilir ve kaynak tahsisini optimize edebilir (Davenport & Kalakota, 2019). Radyolojik görüntülerde (MR, BT, röntgen) anormallikleri tespit etme konusunda YZ algoritmaları giderek daha başarılı olmaktadır. Maliyet tahminleri, sigorta süreçleri ve kaynak dağılımı kararlarında YZ destekli sistemler kullanılmaktadır.

YZ teknolojileri sağlık yönetiminde büyük potansiyel sunsa da veri gizliliği, algoritmaların şeffaflığı, etik kaygılar ve insan gözetiminin önemi gibi konular dikkate alınmalıdır. Gelecekte sağlık yönetimi, insan uzmanlığı ile YZ teknolojilerinin entegre olduğu bir model etrafında şekillenebileceğini ifade etmek yerinde bir tespit olacaktır.

2.2.1. Sağlık Kurumlarında Yapay Zekanın Gelişen Rolü

YZ, sağlık sektöründe giderek daha önemli bir rol üstlenerek, hastalara daha kişiselleştirilmiş ve verimli bakım sunulmasına yardımcı olabilmektedir. Doktorların ve sağlık çalışanlarının karar alma süreçlerini destekleyen bu teknoloji, aynı zamanda hastane yönetimi gibi idari işleri de kolaylaştırmaktadır. YZ, insan uzmanlığının yerini almak yerine onu güçlendirdiğini; tıpkı bir asistan gibi çalışarak sağlık profesyonellerine daha fazla zaman ve doğru bilgi sağ-

layacağı öngörüsü yapılabilir. Gelecekte, bu iş birliği daha da derinleşeceğini ve hasta bakımında yeni bir dönemin olacağını öngörmek ve etkileşimin daha fazla olacağını söylemek ideal bir yaklaşım olacaktır.

Dünya çapında birçok sağlık kurumu, hasta bakımını geliştirmek için yapay zekayı benimsemiştir. Örneğin, Mayo Clinic, ciddi komplikasyon riski taşıyan hastaları belirlemek için tahmine dayalı analitik için yapay zekayı kullanmaktadır. Cleveland Clinic, hasta katılımını ve iletişimini geliştirmek için YZ odaklı sohbet robotları uygulamaktadır. Bu vakalar, yapay zekanın teknoloji şirketleriyle sınırlı olmadığını, verimliliği, hasta sonuçlarını ve genel sağlık hizmeti sunumunu iyileştirmek isteyen sağlık hizmeti sağlayıcılarının stratejilerine entegre edildiğini göstermektedir (Faiyazuddin et al., 2025)

2.3. Sağlıkta Yapay Zekâ ve Tartışmalı Alanları

Sağlık hizmetlerinde makine öğrenme veya derin öğrenme ile büyük verileri işlemenin büyük avantajları vardır (Ngiam & Khor, 2019; Wainberg et al., 2018). Geleneksel biyoistatistiksel yöntemlere kıyasla daha uyarlanabilir ve ölçeklenebilir olduklarından risk tabakalandırma, teşhis, prognoz ve tedavi planlaması gibi çeşitli görevler için kullanılabilirler. ML ve DL, demografik veriler, laboratuvar sonuçları, görüntüleme verileri ve serbest metin klinik notları gibi farklı veri biçimlerini analiz ederek hastalık riski değerlendirmesi, teşhis ve tedavi protokollerine yardımcı olma potansiyeline sahiptir. Ancak bu teknolojiler sağlık sektöründe kullanıldığında sorunludur. Veri ön işleme, model eğitimi ve klinik sorunlarla ilgili sistemler oluşturma gibi teknik konuların yanı sıra, alınması gereken pragmatik ve etik kaygılar da vardır. Bunların başında veri gizliliği ve korunması, doktorların bu tür teknolojileri tanınması ve kullanması ve adli kullanımları etkileme kapasiteleri gibi konular gelmektedir. Bu nedenle, makine öğrenimi ve DL'nin sağlık alanında etkili bir şekilde kullanılmasını kolaylaştırmak için ihtiyatlı ve hem teknik hem de etik bir yaklaşım gerekmektedir (A. Ahmed et al., 2023; Amal et al., 2022; Chen et al., 2017).

YZ şemsiyesi altına giren gelişmiş analitik teknikler sağlık hizmetlerini iyileştirebilse de sağlıkta YZ kullanımı güvenlik ve etik endişeleri doğurmaktadır. Şu anda sağlık hizmetlerinde YZ teknolojilerinin geliştirilmesi ve kullanılması için uluslararası olarak tanınan yönetim mekanizmaları (politikalar, etik standartlar, değerlendirme ve düzenlemeler) çoğunlukla çerçeve niteliğindedir. Uluslararası fikir birliğinin eksikliği, sağlık YZ kullanımına teknik ve sosyal engeller yaratırken potansiyel olarak pazar rekabetini de engellemektedir (Morley et al., 2022).

YZ teknolojilerinin sağlık hizmetlerinde kullanımı konusunda hastalar arasında büyük bir heyecan bulunsa da bu teknolojilere yönelik endişeler de devam etmektedir. 15 odak grubuyla yapılan bir araştırmada (Richardson et al., 2021) hastaların YZ'nin güvenliği, hasta seçimine etkileri, maliyet artışları,

veri önyargısı ve güvenliği gibi konularda kaygı taşıdığını ortaya koymuştur. Bu endişeleri gidermek ve YZ'nin sağlık hizmetlerinde başarılı bir şekilde kullanılmasını sağlamak için etik yaklaşımlar geliştirmek önemlidir.

Sağlık hizmetlerinde YZ kullanımı esnasında karşılaşılan engeller üzerine yapılmış bir sistematik çalışmada sağlık hizmetlerinde yapay zekanın uygulanmasına engel teşkil eden önemli etik endişeler olduğu ve incelenen 39 çalışma bu etik engellere atıfta bulunmuş ve tema içinde en belirgin olanlar gizlilik, güven, onay ve çıkar çatışmaları öne çıktığı vurgusu yapılmıştır (M. I. Ahmed et al., 2023).

Sağlık sektörü giderek daha fazla veri odaklı bir hale geldikçe, sağlık bilişimini çevreleyen etik hususlar ön plana çıkmaktadır (Robert, 2024). Sorumlu YZ uygulaması için veri kalitesi, yorumlanabilirlik, önyargı ve düzenleyici çerçeveler gibi zorlukların ele alınması gerekmektedir. Öneriler, YZ'nin sağlık hizmetlerinde etik ve etkili entegrasyonunu sağlamak için sağlam etik ve yasal çerçevelere, insan-YZ iş birliğine, güvenlik, doğrulamaya, eğitime ve kapsamlı düzenlemeye olan ihtiyacı vurgulamaktadır (Olawade et al., 2024).

Çok modlu sağlık verilerinin analizi, özellikle önyargı ve ayrımcılıkla ilgili olarak etik kaygıları gündeme getirmektedir. Önyargılar, dengesiz veriler, belirli veri kategorilerinin yetersiz temsil edilmesi ve veri toplama ve etiketleme işlemleri sırasında ortaya çıkan önyargılar nedeniyle ortaya çıkabilmektedir. Sonuç olarak, araştırmacıların bu etik kaygıları proaktif olarak ele almaları ve çok modlu sağlık hizmetleri analitiğindeki önyargıları tespit edip azaltabilecek araçlar geliştirmeleri ve böylece adil ve eşitlikçi sonuçları teşvik etmeleri çok önemlidir.

Çok modlu sağlık hizmeti veri analizinin bütünlüğünü ve adaletini sağlamak için araştırmacılar birkaç kilit alana odaklanmalıdır. İlk olarak, verilerde bulunan önyargıları belirlemek, veri toplama sürecini eleştirel bir şekilde değerlendirmek ve önyargıları ele almak ve azaltmak için uygun önlemleri uygulamak için sağlam metodolojiler kullanmak esastır. Ek olarak, araştırmacılar analizlerinde şeffaflık ve açıklanabilirlik için çaba göstermeleri, veri kaynaklarını, ön işleme tekniklerini ve modelleme kararlarını belgelemeli ve algoritmaların çıktıları için net açıklamalar sağlamalıdır. Araştırmacılar, etik hususlara öncelik vererek ve önyargı tespit ve azaltma tekniklerini kullanarak, tarafsız çok modlu sağlık hizmetleri analitiğinin geliştirilmesine katkıda bulunabilir, güveni teşvik edebilir ve ilgili tüm bireyler için adil sonuçları teşvik edebilir (A. Ahmed et al., 2023).

BÖLÜM III:

SAĞLIK HİZMETLERİNDE BİR KLİNİK KARAR DESTEK UYGULAMASI: BEYİN TÜMÖRÜ TEŞHİS ÖRNEĞİ

3.1. Sağlık Hizmetlerinde Beyin Tümörlerinin Tespiti: MR ve Yapay Zekâ Destekli Görüntüleme Tekniklerinin Rolü

İnsan hayatı için ciddi tehlike oluşturan hastalıklar vardır. Kanser bunların arasında önemli hastalıklardan biridir. Kanser genellikle vücudun belirli bir bölümündeki hücrelerin kontrolsüz bir şekilde çoğaldığında ve genişlediğinde ortaya çıkmaktadır. Uluslararası Kanser Araştırma Ajansı (IARC), GLOBOCAN 2022 verilerini kullanarak, beyin ve MSS tümörlerinin önemli bir küresel yükünü tahmin etmiştir. 2022 yılında, dünya genelinde yaklaşık 322.000 yeni vaka teşhis edilmiştir. İleriye dönük olarak, projeksiyonlar yeni vaka sayısının mutlak sayısında endişe verici bir gidişata işaret etmektedir. Mevcut insidans oranları sabit kalırsa, yeni teşhislerin toplam sayısının 2045 yılına kadar 474.000'e ulaşması beklenmektedir; bu, 2022 rakamlarına göre önemli bir %47'lik artış temsil etmektedir (Adalberto Filho et al., 2025).


2024 yılında Amerika Birleşik Devletleri'nde yaklaşık 2.001.140 yeni kanser vakası ve kanserle ilişkili 611.720 ölüm olacağı tahmin edilmektedir (Siegel et al., 2024). Beyin tümörleri, beyindeki kötü huylu büyümeleri nedeniyle kötü huylu olarak kategorize edilen çeşitli kanser türleri arasında yer almaktadır (Herholz et al., 2012). Bu, kötü huylu olmayan ve genellikle daha yavaş bir hızda büyüyen iyi huylu beyin tümörlerinden farklıdır (Bondy et al., 2008). Bir beyin tümörünün büyüme hızı, türü, ilerleme aşaması ve yeri, kötü huylu mu yoksa iyi huylu mu olduğunu belirleyen özellikler arasındadır (Lamba et al., 2021; Roth et al., 2015). 700.000 Amerikalının halihazırda birincil beyin tümörüne sahip olduğu ve 2023 yılında 94.390 Amerikalıya daha ana beyin tümörü teşhisi konulacağı tahmin edilmektedir (Siegel et al., 2023).

2020 yılına ait ulusal verilere göre, Türkiye'de beyin, meninksler ve merkezi sinir sistemi kanserleri (C70-C72) için yaşa standardize edilmiş insidans oranı erkeklerde 100.000'de 6,2, kadınlarda ise 100.000'de 4,4 olarak kaydedilmiştir (Genel, 2023). Bu oranlar, Dünya Standart Nüfusu'na göre standardize edilmiştir. Ege Üniversitesi Hastanesi'nin 1992-2017 yılları arasındaki verileri, MSS tümörlerinin tüm kanser vakalarının %5'ini oluşturduğunu ve hastane

sisteminde dokuzuncu en sık görülen tümör grubu olduğunu göstermektedir (Özgiray et al., 2019). Bu MSS vakalarının %66,7'sini ise beyin tümörleri oluşturmaktadır.

İnsan beynindeki tümörler için hem invaziv (cerrahi işlem yapılarak) hem de invaziv olmayan çeşitli tanı teknikleri kullanılarak tanı ve teşhis yapılmaktadır (Herholz et al., 2012; Siegel et al., 2024). Örneğin, biyopsi, cerrahi bir kesi yoluyla bir örnek çıkarmayı ve kötü huylu tümör (malign tümör) tanımlamak için mikroskop altında incelemeyi içeren invaziv bir işlemdir. Öte yandan, beyin tümörü biyopsileri, vücudun diğer bölümlerindeki kötü huylu tümörlerin aksine, kesin beyin ameliyatından önce genellikle yapılmaz (Bondy et al., 2008). Beyin tümörlerini teşhis etmek için bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi invaziv olmayan görüntüleme yöntemlerinin daha hızlı ve daha güvenli olduğu düşünülmektedir. MR'ın beyin tümörünün yeri, gelişimi, şekli ve boyutu hakkında hem 2D hem de 3D formatlarda yüksek çözünürlükte kapsamlı bilgi sunma kapasitesi, onu tartışılan tüm invaziv olmayan görüntüleme yöntemleri arasında tercih edilen yöntem haline getirmektedir (Charles et al., 2011; Villanueva-Meyer et al., 2017). Yüksek hasta hacmi nedeniyle, MR görüntülerinin manuel yorumlanması tıp uzmanları için zaman alıcıdır ve hatalara açıktır.

Tümörün evreleri için örnek bir görsel Şekil 5'te verilmiştir. Çeşitli tıbbi durumları temsil etmek için sıklıkla kullanılan bir MRI görüntüsü (A) sağ alt köşede şüpheli bir düzensizlik göstermektedir. Öte yandan (B, C), tümörün daha fazla yer kapladığı kötü huylu bir durumu göstermektedir. Daha erken evrelerin aksine, (D) tümör büyümesini ve yakındaki hücrelerin yok edilmesini göstermektedir (Liu et al., 2023).



Şekil 6. Bir Beyin Tümörünün İlk Durumundan En Kötü Duruma Kadar Büyümesinin Seyri

Kanserle mücadele de hem hastalığın erken evre tespiti hem de çeşitli önleyici tedbirlerin uygulanması için erken teşhis yöntemlerinden yararlanmak hayati önem taşımaktadır. Bu bağlamda erken tümör tespiti için en popüler tekniklerden biri MR teknolojisidir (Villanueva-Meyer et al., 2017). Radyologlar, deneyimlerine dayanarak beyin kanserlerini erken tespit etmek için rutin olarak bu tekniği kullanmaktadırlar. Tıbbi görüntüleme alanında karar alma süreçlerini hızlandırabilecek ve geliştirebilecek yeni yöntemlere açık bir ihtiyaç vardır (Pacal, 2024c). Tıbbi alan, hızlı işlem yapma ve hastalık teşhisinde yüksek doğruluk oranlarına ulaşma kabiliyetleri nedeniyle YZ ve ML'nin giderek daha fazla tercih edilmesiyle birlikte yeni teknolojileri kapsamlı bir şekilde kullanmaktadır (Farooq et al., 2023; Kurtulus et al., 2024).

3.1.1. Sağlıkta Beyin Tümörü Teşhisi: Derin Öğrenme Etkisi

Çok sayıda bilimsel çalışma beyin tümörü teşhisine odaklanarak, derin öğrenmenin bu alanda önemli ilerlemelere yol açtığını ortaya koymaktadır (Ali et al., 2022; Bhagyalaxmi et al., 2024; Chahal et al., 2020; Jyothi & Singh, 2023; Liu et al., 2023; Nazir et al., 2021; Younis et al., 2022). Derin öğrenme, karmaşıklıkları nedeniyle beyin tümörlerini doğru bir şekilde teşhis etmek için önemli faydalar sunan çığır açıcı bir yöntem haline gelmiştir. Bu model-

ler, MR taramaları gibi büyük tıbbi veri kümelerinden karmaşık desenleri ve özellikleri otonom olarak çıkararak hassas tümör segmentasyonu ve sınıflandırmasına olanak tanımaktadır (Farajzadeh et al., 2023; Jyothi & Singh, 2023; Nazir et al., 2021).

Çeşitli bilimsel araştırmalar inceledikten sonra, derin öğrenmenin beyin tümörü teşhisinde çok sayıda önemli keşfe yol açtığı bu araştırma sürecinde görülmüştür. Araştırmalar, derin öğrenmenin bu alanda yenilikçi ve etkili bir yaklaşıma dönüştüğünü göstermektedir. Bhagyalaxmi ve arkadaşları (Bhagyalaxmi et al., 2024) derin öğrenmenin, özellikle CNN'lerin, beyin tümörü tespiti için umut verici olduğunu bulmuşlardır. Araştırmaları mevcut teknikleri ana hatlarıyla belirtirken, gelecekteki araştırmaların etkinliği en üst düzeye çıkarmak için derin öğrenmeyi diğer metodolojilerle birleştiren hibrit modelleri keşfedilmesi gerektiğini önermektedirler. Awuah ve arkadaşları (Awuah et al., 2024) yapay zekanın nöroşirurjide hasta sonuçlarını iyileştirme potansiyelini, nöroşirurji uzmanlarına tanı, prognoz ve cerrahi karar alma konusunda yardımcı olabileceğini vurgulamaktadırlar.

Makine öğrenimi ve derin öğrenme de dahil olmak üzere YZ, komplikasyonları azaltarak, cerrahi planlamayı iyileştirerek ve genel olarak nöroşirurjide hasta bakımına fayda sağlayarak önemli ölçüde ilerleme kaydedilmiştir. Levy ve diğerleri (Levy et al., 2024) nöroşirurjide makine öğrenimi ile ilgili önemli makaleleri vurgulamaktadır. Bunlar, özellikle sonuç tahmini, hasta seçimi ve cerrahi karar almada hasta bakımını iyileştirmek için makine öğreniminin çeşitli alt uzmanlık alanlarındaki uygulamasını vurgulamaktadır.

3.1.2 Sağlık Hizmetlerinde Bilgisayar Destekli Teşhis, Derin Öğrenme ile Beyin Tümörü Tespiti

Derin öğrenme, karmaşık beyin tümörlerini doğru bir şekilde teşhis etmek için çığır açan bir yöntemdir. Bu modeller, büyük MR veri kümelerinden desenleri otonom bir şekilde çıkararak hassas tümör segmentasyonu ve sınıflandırması sağlamaktadır. Derin öğrenmenin büyük hacimli verileri hızlı ve hassas bir şekilde işleme kapasitesi, teşhis etkinliğini artırır, tedavi kararlarını hızlandırır ve hasta sonuçlarını iyileştirmektedir. Ancak, klinik uygulamaya başarılı bir şekilde entegre etmek, güven, yorumlanabilirlik ve derin öğrenmenin tıbbi uzmanlığın yerini almak yerine destekleyici bir araç olarak kullanılmasını sağlamak için YZ uzmanları ve tıp uzmanları arasında yakın bir iş birliği gerektirmektedir. Beyin tümörleri alanında, çok sayıda derin öğrenme tabanlı CADx (bilgisayar destekli teşhis) yöntemi geliştirilmiştir. Bu çalışmalardan bazıları aşağıda verilmiştir.

Ullah ve arkadaşları üç ardışık dilim ve çok ölçekli öğrenmeyi kullanarak beyin tümörü segmentasyonu için Çok Ölçekli Kalan Dikkat-UNet'i (MRA-UNet) tanıtmıştır (Ullah et al., 2022). Son işlem teknikleri segmentasyon doğru-

luğunu artırarak, tüm tümör, tümör çekirdeği ve geliştirilmiş tümör bölgeleri için sırasıyla %90,18, %87,22 ve %86,74 ortalama zar puanlarıyla BraTS2017, BraTS2019 ve BraTS2020 veri kümelerinde en son sonuçları üretmiştir. Celik ve Inik özellik çıkarma için yeni bir CNN modeli ile sınıflandırma için ML algoritmalarını birleştiren beyin tümörü sınıflandırması için hibrit bir yöntem önermektedir (Celik & Inik, 2024). Dokuz en son model ve optimize edilmiş ML algoritması hiperparametrelerini kullanarak CNN performansını Bayes optimizasyonu ile karşılaştırmışlardır. Sonuçlar, hibrit modelin %97,15 ortalama sınıflandırma doğruluğunun yanı sıra %97 geri çağırma, hassasiyet ve F1 puanı değerlerine ulaştığını göstermektedir. Anantharajan ve diğerleri (Anantharajan et al., 2024) DL ve ML kullanarak MR beyin tümörü tespiti için yeni bir yöntem önermektedir. MR görüntülerini Uyarlamalı Kontrast Geliştirme Algoritması (ACEA) ve medyan filtresiyle ön işleme tabi tutarlar, ardından bunları bulanık c-ortalamalarla bölerler. Enerji, ortalama, entropi ve kontrast gibi özellikler Gri Seviye Eş Oluşum Matrisi (GLCM) kullanılarak çıkarılır. Anormal dokular, Topluluk Derin Sinir Destek Vektör Makinesi (EDN-SVM) sınıflandırıcısı kullanılarak sınıflandırılır.

Pacal (Pacal, 2024c) Swin Transformatörüne dayalı gelişmiş bir derin öğrenme yöntemi sunmuştur. Doğruluğu artırmak, bellek kullanımını azaltmak ve eğitim karmaşıklığını basitleştirmek için Hibrit Kaydırılmış Pencere Çok Başlı Kendi Kendine Dikkat modülü (HSW-MSA) ve yeniden ölçeklenmiş bir model içerir. Geleneksel MLP'yi Kalan Tabanlı MLP (ResMLP) ile değiştirerek, Swin Transformatörü iyileştirilmiş doğruluk, eğitim hızı ve parametre verimliliği elde eder. Kamuya açık bir beyin MRI veri seti üzerinde yapılan değerlendirme, verimli ve sağlam eğitim için transfer öğrenme ve veri artırma teknikleri aracılığıyla gelişmiş performansı göstermektedir.

Remzan ve arkadaşları derin öğrenme algoritmaları kullanarak beyin tümörü sınıflandırmasını ele alarak radyolojide tanısal hassasiyeti artırmışlardır. RadImageNet'i önerdiler ve sınırlı ve çeşitli olmayan tıbbi görüntü veri kümeleriyle ilgili zorlukların üstesinden gelmek için transfer öğrenimini kullanmışlardır (Remzan et al., 2024). Topluluk öğrenme stratejileri, ResNet-50 ve DenseNet121 özellikleriyle sırasıyla %97,71 ve %97,40 doğruluğa ulaşarak önemli doğruluk iyileştirmeleri elde etmişlerdir. Ullah ve arkadaşları, beyin tümörü segmentasyonu için yeni bir tam otomatik yöntem olan MRA-UNet'i önermişlerdir (Ullah, Usman, Latif, et al., 2023). Üç ardışık dilimden çok ölçekli öğrenme ve sıralı bilgileri kullanır. MRA-UNet, uyarlanabilir ilgi alanı şeması kullanarak geliştirilmiş ve çekirdek tümör bölgelerini doğru bir şekilde segmentlere ayırır. Koşullu rastgele alan ve test süresi artırma gibi son işlem teknikleri performansını daha da artırır (Ullah et al., 2022). İzole edilmiş ve geliştirilmiş bir transfer derin öğrenme modeline dayanarak, Alanazi ve arkadaşları (Alanazi et al., 2022) MR kullanan bir beyin tümörü/

kitle sınıflandırma çerçevesi sunmuşlardır. Yayımlanmamış bir beyin MRI veri seti için, model %96,89'luk yüksek bir doğruluk elde etmişlerdir.

Younis ve arkadaşları 155'inin tümöre işaret ettiği 253 MR beyin görüntüsünden oluşan bir veri seti üzerinde beyin tümörü tanısını değerlendirmişlerdir (Younis et al., 2022). Algoritma, beyin tümörlerini tespit etmede mevcut geleneksel yaklaşımlardan daha iyi performans göstererek sırasıyla %96, %98,15 ve %98,41'lik hassasiyet oranları ve %91,78, %92,6 ve %91,29'luk F1 puanları elde etmiştir. Pedada ve arkadaşları (Pedada et al., 2023) araştırmalarında derin öğrenmeyi bilgisayar destekli tümör tespit yöntemleriyle birleştirerek makine öğrenimini büyük ölçüde geliştirmişlerdir. Beyin tümörü segmentasyonu (BraTS) Challenge 2017 ve 2018 veri setleri için önerilen U-Net modelini kullanarak sırasıyla %93,40 ve %92,20'lik segmentasyon doğruluğu elde etmişler. Habibe ve arkadaşları özellik çıkarıcı olarak "EfficientNet" ve sınıflandırıcı olarak Deep CNN kullanarak önerilen modelin beyin MRI görüntülerinden Alzheimer'ı tespit etmek için %97'lik genel bir sınıflandırma doğruluğu elde ettiğini ve diğer tüm son teknoloji modellerini geride bıraktığını göstermektedir (Umme Habiba et al., 2023). Çalışmalarda sunulduğu gibi, derin öğrenme tabanlı CNN mimarileri beyin tümörü teşhisinde yaygın olarak kullanılmaktadır. Bu çalışmanın temel amacı, hastaların durumlarıyla ilgili hızlı, etkili ve doğru karar vermeyi sağlayan beyin tümörlerini tespit etmek için MRI taramalarını kullanan yararlı bir strateji oluşturmaktır.

Zebari ve arkadaşları (Zebari et al., 2024) büyük eğitim veri kümelerine olan gereksinimi aşmak için veri artırma tekniklerini kullanarak beyin tümörü sınıflandırması için derin öğrenme birleştirme modeli tasarlamışlardır. Sınıflandırıcı olarak Softmax ile VGG16, ResNet50 ve evrişimli derin inanç ağlarını kullanarak MR görüntülerinden derin özellikler çıkarmışlardır. İki DL modelinden özellikleri birleştiren birleştirme modeli, sınıflandırma doğruluğunu önemli ölçüde artırdığını bulmuşlardır. Azhagiri ve Rajesh (Azhagiri & Rajesh, 2024) MR görüntülerindeki tümörleri tanımlamak için derin bir CNN modeli olan AlexNet'i kullanmıştır. AlexNet'i katmanlar ekleyerek geliştirmiş ve doğruluğu artırmak için veri artırma tekniklerini kullanmışlardır. Geliştirilmiş AlexNet (EAN) modelleri, geleneksel modelleri geride bırakarak MR görüntülerinden beyin tümörlerini sınıflandırmada dikkate değer bir %99,32 doğruluk elde edilmiştir. Mandle ve arkadaşları (Mandle et al., 2024) ön işleme, segmentasyon ve sınıflandırma aşamalarını içeren beyin tümörü tespiti için gelişmiş bir derin öğrenme modeli geliştirmiştir. Bileşik bir filtre kullanarak görüntü kalitesini iyileştirerek ve tümörleri morfolojik ve eşik tabanlı teknikler kullanarak segmentlere ayırmışlardır. Model, gri seviye eşoluşum matrisi (GLCM) ile özellik çıkarma ve Balina Sosyal Örümcek Tabanlı Optimizasyon Algoritması (WSSOA) ile optimize edilmiş özellik seçimi ve ardından DCNN kullanılarak sınıflandırma yoluyla doğru tespit elde edilmiştir.

Özetle, bu çalışmalar toplu olarak beyin tümörü tanısında CNN ve görüntü dönüştürücü modellerinin kapsamlı uygulamasının altını çizerek, beyin tümörlerinin tespiti için MRI taramalarını kullanan kapsamlı bir strateji sunmaktadır. Bu yaklaşım, hastaların durumlarıyla ilgili hızlı, etkili ve doğru karar vermeyi mümkün kılarak, derin öğrenme tekniklerinin tıbbi görüntüleme ve tanı alanında önemli ilerleme sağladığı gösterilmektedir.

BÖLÜM IV:

ARAŞTIRMADA KULLANILAN YÖNTEM


Bu çalışmada, manyetik rezonans görüntüleme (MR) tabanlı beyin tümörü teşhisi için derin öğrenme destekli bir klinik karar destek sistemi geliştirilmiştir. Buradaki teşhis, beyin tümörünün daha sık görülen üç türünün (glioma, menenjima, hipofiz) ile tümör yok sınıfının tespit edilmesine odaklanmaktadır. Yani çalışmada geliştirilen model doğrudan beyin tümörü sınıflandırması yapmak içindir. Bu bağlamda seçilen veri seti, dengesiz dağılıma sahip dört farklı tümör sınıfını (Glioma, Menenjiyom, Hipofiz) ve tümör olmayan kategoriye (No-tümör) içermektedir (Nickparvar, 2021). Önerilen model beyin tümörü hastalığının sınıflandırılması için güçlü bir yapı ve birkaç temel bileşenden oluşan sağlam bir çerçeve sunmaktadır. Araştırma kullanılan veri seti Google geliştirdiği Kaggle platformundan alınmıştır (Kaggle, 2024).

Kaggle, Google LLC bünyesinde faaliyet gösteren, veri bilimcileri ve makine öğrenimi uygulayıcıları için önde gelen bir çevrimiçi topluluk ve platform olarak geniş çapta tanınmaktadır (Banachewicz & Massaron, 2022). Nisan 2010'da Anthony Goldbloom tarafından kurulan bu platform, o zamandan beri kapsamlı bir ekosisteme dönüşmüştür (Banachewicz & Massaron, 2022). Temel amacı, kullanıcıların veri kümeleri bulmasını ve yayınlamasını, web tabanlı bir ortamda modeller oluşturup keşfetmesini, akranlarıyla işbirliği yapmasını ve karmaşık veri bilimi sorunlarını çözmek için yarışmalara katılmasını sağlamaktır (Chow, 2019; Hayashi et al., 2021). Küresel çapta 25 milyondan fazla makine öğrenimi uzmanını bir araya getiren Kaggle, kendisini en büyük yapay zeka (YZ) ve makine öğrenimi (ML) topluluğu olarak konumlandırmıştır (Banachewicz & Massaron, 2022).

Modelde sunulan aşamaların açıklaması ise şu şekildedir: Veri seti aşamasında beyin MR görüntüsü seçerek süreç başlatılmıştır. Veri kümesi aşamasında (Kaggle, 2024) çeşitli kamuya açık veri setleri arasından seçilmiş (veri seti başlığı altında detayları mevcuttur) ve ön işleme aşamasında işlenmiştir.

Görüntüler yeniden boyutlandırılmış, bölümlere ayrılmış ve temel veri artırma teknikleri uygulanarak eğitim performansı iyileştirilmiş ve sınıf dengesizlikleri giderilmiştir. Derin öğrenme yöntemleri için veri seti üç alt kümeye ayrılmıştır. Sınırlı çeşitliliğe sahip küçük ölçekli veri setleri için, çevirme, döndürme ve ölçeklendirme gibi veri artırma teknikleri kullanılarak eğitim verisinin çeşitliliği artırılmıştır. Model eğitimi aşamasında, derin öğrenme yaklaşımları kullanılmış; özellikle ImageNet ağırlıklarına sahip son teknoloji modeller ve önerilen model değerlendirilmiştir.

Bu yaklaşım, küçük ölçekli veri setlerinde hızlı yakınsama ve gelişmiş performans sağlamıştır. Modeller, doğrulama sürecinden geçirilmiş ve sınıflandırma için 20'den fazla derin öğrenme mimarisi ile toplam 45 derin öğrenme modeli karşılaştırma-
lı olarak test edilmiştir. Son olarak, değerlendirme aşamasında modeller, test verisi üzerinde denenmiş; performansları ölçülmüş ve Grad-CAM ısı haritaları ile görsel olarak analiz edilmiştir (M. A. Lubbad et al., 2024). Araştırmanın yöntem bölümün daha iyi anlaşılması için Şekil 5'te genel hatlarıyla gösterilmeye çalışılmıştır.




Şekil 7. Beyin Tümörü Tanımlama ve Açıklanabilirliği İçin Önerilen Yaklaşım (Pacal et al., 2024)

4.1. Veri Seti

Bu çalışmada, derin öğrenme modellerinin etkili bir şekilde eğitilebilmesi için Kaggle'daki (Kaggle, 2024) kamuya açık veri setlerinden hem sağlıklı hem de hastalıklı örneklerini içeren toplam 7.023 MRI görüntüsünden oluşan geniş bir veri seti seçilmiştir. Nickparvar tarafından bu veri seti üç farklı Figshare, SARTAJ ve Br35H veri seti birleştirilerek Kaggle platformunda paylaşılmıştır (Nickparvar, 2021). Figshare veri seti, 2005-2010 yılları arasında Çin'deki General Hospital, Tianjin Medical University ve Nanfang Hospital tarafından toplanmıştır (Khan et al., 2022). Figshare'den alınan veri seti herkese açıktır (Swati et al., 2019b) ve sınıflandırma algoritmalarını değerlendirmek için yaygın olarak kullanılmaktadır (Deepak & Ameer, 2019). İçerik olarak üç beyin tümöründen biri olan menenjioma, glioma ve hipofiz tümörleri teşhisi konmuş 233 hastaya ait 3064 beyin MRI görüntüsünden oluşan bir koleksiyondur (Deepak & Ameer, 2019). SARTAJ veri seti ise ilk olarak 2017 yılında Jun Cheng tarafından çevrimiçi olarak yayınlanmış ve 2020 yılında Sartaj Bhuvaji tarafından güncellenmiştir (Bhuvaji et al., 2020). Br35H, 1500'ü beyin tümörü, geri kalanı ise normal beyin MR görüntüleri olmak üzere 3000 beyin MR görüntüsü içeren ikili bir sınıflandırma veri kümesidir (Mondal & Shrivastava, 2022). Ayrıca, birçok farklı araştırmacı ve programcı bu veri setini kullanmakta ve bu veri setinin Kaggle'da 10 üzerinden 8,75 kullanılabilirlik puanı (Hamada, 2020) olmakla birlikte beyin tümörü tespiti ve sınıflandırması için oldukça güvenilir ve makul bir veri seti olduğunu göstermektedir.

Veri seti, dengesiz dağılıma sahip dört farklı sınıftan oluşmaktadır: Glioma-tümör (1.621 örnek), Meningioma-tümör (1.645 örnek), Hipofiz-tümör (1.757 örnek) ve Tümör olmayan (2.000 örnek). Şekil 7'de kullanılan veri setindeki sınıflardan rastgele seçilmiş örnek gösterilmiştir.



Şekil 8. Beyin Tümörü ve Sağlıklı Sınıflara Ait MR Görüntüleri

Gliyomlar, merkezi sinir sisteminin bir bölümünde ortaya çıkan malign (kötü huylu) tümörlerdir. Bu tümörler, beyin dokusundan veya beyin omurilik sıvısından kaynaklanabilir. Beyin kanserine bağlı ölümlerin büyük çoğunluğu, en agresif ve ölümcül beyin tümörü türü olan gliomalardan kaynaklanmaktadır (Ostrom & Barnholtz-Sloan, 2011). Gliyomlar aynı zamanda en yaygın görülen birincil beyin tümörlerinden biridir ve tedavileri halen oldukça zorlu bir süreçtir (Tummala et al., 2022). Meningiomlar ise beynin ve omuriliğin dış zarını oluşturan hücrelerden gelişir (Alruwaili & De Jesus, 2023).

Hipofiz tümörleri, bir çalışmaya göre (Herholz et al., 2012), hipofiz bezindeki anormal hücre gelişimi sonucu oluşan tümörlerdir. Bu tümörlerin çoğu benign (iyi huylu) olsa da nadiren malign (kötü huylu) forma dönüşebilirler. Boyutlarına, konumlarına ve hormon salgılama durumlarına bağlı olarak hipofiz tümörleri çeşitli semptomlar ve bulgularla kendini gösterebilir. Hipofiz tümörlerinin kesin nedenleri henüz tam olarak anlaşılamamış olmakla birlikte, bazı faktörlerin tümör oluşum riskini artırabileceği düşünülmektedir.

Tümör olmayan (No-tümör) durumu ise, beyin görüntülerinde herhangi bir anormal büyüme veya tümör bulunmadığını ifade eder. Bu durumlarda, beyin sağlıklı ve normal kabul edilir; kanser veya anormal hücre çoğalmasına dair hiçbir belirti yoktur.

4.2. Ön İşleme

Ön işleme aşaması, derin öğrenme algoritmalarının etkili şekilde eğitilmesi ve değerlendirilmesi için bir dizi kritik adımdan oluşmaktadır (Goodfellow et al., 2016). İşlemler, $512 \times 512 \times 3$ piksel boyutundaki ham MR görüntülerinin öncelikle $224 \times 224 \times 3$ piksel boyutuna indirgenmesiyle başlamaktadır (Zhang et al., 2023). Bu boyut küçültme işlemi; hesaplama karmaşıklığını azaltmak, işlem süresini optimize etmek ve hesaplama kaynaklarını verimli kullanmak amacıyla gerçekleştirilir (Simonyan & Zisserman, 2014). Görüntülerin biküçük interpolasyon (Triwijoyo & Adil, 2021) yöntemiyle yeniden boyutlandırılması, en yakın komşu ve çift doğrusal interpolasyon yöntemlerine kıyasla daha yumuşak sonuçlar verdiği için tercih edilir (Ullah et al., 2025). Bu yöntem, yeniden boyutlandırma sürecinde görüntü kalitesini korumak için en yakındaki 16 pikseli (4×4 'lük alan) dikkate alarak yeni piksel değerlerini hesaplar (Dubois et al., 2024). Tıbbi görüntü işlemede doğru tümör tespiti ve sınıflandırma için görüntü kalitesinin korunması hayati önem taşıdığından bu seçim özellikle önemlidir (Shen et al., 2017). Boyut küçültme işlemi aynı zamanda görüntüdeki piksel sayısını azaltarak hesaplama yükünü hafifletir ve daha hızlı sonuçlar alınmasını sağlamaktadır (Krizhevsky et al., 2012). Sonraki aşamada, modelin eğitim sırasında veri setinin belirli bir alt kümesine odaklanmasını engellemek ve tüm veri setinden daha temsili bir şekilde yararlanılmasını sağlamak amacıyla görüntü verileri karıştırılır (LeCun et al., 2015). Bu işlem, modelin genelleme yeteneğini artırarak ezberleme (overfitting) eğilimini azaltır ve daha güvenilir sonuçlar elde edilmesine olanak tanımaktadır (Goodfellow et al., 2016).

Veri seti, çeşitli beyin tümörü türlerine karşılık gelen dört sınıfa ayrılmıştır: Glioma, menenjiyom, hipofiz ve tümör olmayan. Her sınıf farklı sayıda örnek içermekte olup, "Tümör olmayan" sınıfı 2.000 örnekle en fazla veriye sahiptir. Veri seti, Tablo 6'da görüldüğü üzere eğitim, doğrulama ve test amaçlarıyla üç alt kümeye bölünmüştür (Pacal et al., 2024).

Tablo 6. Kamuya Açık Veri Setindeki Eğitim, Doğrulama ve Test Kümelerindeki Görüntü Sayıları

Sınıf Adı (Beyin tümörü)	Eğitim	Doğrulama	Test	Toplam
Glioma-tümör	1.122	199	300	1.621
Menenjiyom-tümör	1.138	201	306	1.645
Hipofiz tümörü	1.237	220	300	1.757
Tümör olmayan	1.355	240	405	2.000
Toplam	4.852	860	1.311	7.023

Veri setinin eğitim, doğrulama ve test kümelerine titizlikle ayrılması, yöntemimizin güvenilirliğini ve genellenebilirliğini temel alan kritik bir adımdır (Chan et al., 2020). Bu stratejik bölümlenme, modelimizin tümör tiplerinin ve

evrelerinin geniş bir yelpazesini kapsayan çeşitli ve temsili MR taramaları üzerinde eğitilmesini sağlamaktadır. Modelin bağımsız veri kümeleri üzerinde doğrulanması ve test edilmesi, genelleme kabiliyetinin titizlikle değerlendirilmesine olanak tanımaktadır (Chan et al., 2020). Bu yaklaşım, modelin yeni ve eğitim verisi olarak kullanılmamış hasta verilerini doğru şekilde sınıflandırma becerisinin hayati önem taşıdığı tıbbi tanı alanında özellikle kritiktir. Bu kapsamlı değerlendirme çerçevesi, yalnızca modelin sağlamlığını vurgulamakla kalmaz, aynı zamanda klinik ortamlarda kullanıma uygun alabileceği düşünülmektedir. Bu sayede model, beyin tümörlerinin zamanında ve doğru teşhisine yardımcı olarak hasta sonuçlarını iyileştirme potansiyeli taşımaktadır (Chan et al., 2020).

Derin öğrenme modeli, her bir tümör sınıfına özgü desen ve özellikleri belirlemek üzere 4.852 örnekten oluşan eğitim setindeki etiketli verilerle eğilirken, 860 örneklik doğrulama seti modelin hiperparametre optimizasyonu ve genellebilirlik performansının değerlendirilmesinde kullanılmıştır. Modelin klinik uygulanabilirliğini nesnel olarak test etmek amacıyla, eğitim sürecinde kullanılmamış 1.311 MR görüntüsünden oluşan bağımsız bir test seti kullanılmış olup, toplamda 7.023 örnek içeren bu veri seti sayesinde geliştirilen güvenilir sınıflandırma modelinin, beyin tümörü teşhis doğruluğunu artırarak klinisyenlerin tanı sürecini destekleme potansiyeli bulunmaktadır.

Son olarak, modelin aşırı uyum (overfitting) sorununu önlemek ve sistemin genel dayanıklılığını artırmak amacıyla veri çoğaltma teknikleri uygulanmıştır. Görüntü çoğaltma işlemleri kapsamında, orijinal MR görüntülerine döndürme, yansıtma ve ters çevirme gibi çeşitli dönüşümler uygulanarak veri çeşitliliği artırılmıştır. Bu yaklaşım, modelin daha farklı senaryolarda çalışabilmesini sağlamakta ve veriye daha geniş bir perspektiften bakmasına olanak tanımaktadır. Görüntü çoğaltma teknikleri, modelin aşırı öğrenme eğilimini azaltmak ve genelleme yeteneğini güçlendirmek amacıyla sıklıkla kullanılan etkili bir yöntemdir. Tüm bu adımların birleştirilmesiyle, görüntü verilerinin etkin bir şekilde ön işleme tabi tutulması sağlanmış ve önerilen mimari için hazır hale getirilmiştir (Pacal, 2024b).

4.3. Model Eğitimi Ve En Güncel Modeller

Bilgisayarlı görü alanında, derin öğrenme modelleri beyin tümörlerinin sınıflandırılması ve tespitinde önemli potansiyel gösteren çığır açıcı bir yenilik olarak karşımıza çıkmaktadır (Nazir et al., 2021). Yapılan kapsamlı literatür taraması sonucunda, bu araştırmada uygulanmak üzere beyin tümörü teşhisinde en güncel ve etkili derin öğrenme yapılarını temsil eden, alanda kabul görmüş ve son teknoloji derin öğrenme mimarileri dikkatlice seçilmiştir. Bu kapsamda, söz konusu mimarilere ait hemen hemen tüm modeller seçilmiş ve model boyutunun performans üzerindeki etkisi de detaylı şekilde incelenmiş-

tir. Örneğin, yalnızca ResNet50 değil, ResNet18'den ResNet101'e kadar tüm modeller değerlendirmeye alınmıştır. Bu yaklaşım sayesinde her mimari için en başarılı modellerin belirlenmesi mümkün olmuştur.

Bu çalışmada Transfer Öğrenme yöntemi de kullanılmıştır (Deepak & Ameer, 2019). Çünkü büyük veri kümelerinde daha önce eğitilmiş modellerde öğrenilen bilgileri kullanarak küçük veri kümeleriyle yeni görevlerde modellerin performansını iyileştirmeye ve yeni özelliklerle karşılaşıldığında model oluşturmayı hızlandırmaya ve performansı artırmaya olanak tanımaktadır (Deepak & Ameer, 2019). Bu yöntem, duygu analizi, doğal dil işleme ve bilgisayarlı görü dahil olmak üzere birçok disiplinde sıklıkla kullanılmaktadır. ImageNet veri kümesi üzerinde eğitilmiş modeller ise bu alanda en sık başvurulan modeller arasında yer almaktadır (Kaya, 2024).

DenseNet, derin öğrenmede karşılaşılan kaybolan gradyan problemini çözmek üzere geliştirilmiş özgün bir evrişimli sinir ağı (CNN) mimarisidir (Huang et al., 2017). Bu mimaride, “yoğun blok” adı verilen yapılar içinde her katman, sonraki tüm katmanlara doğrudan bağlantılar içererek geleneksel CNN mimarilerinden farklılaşır. Bu radikal bağlantı şeması sayesinde, özelliklerin ağ boyunca daha etkin şekilde yayılması sağlanırken, model parametrelerinde önemli ölçüde verimlilik elde edilir. Katmanlar arasındaki bu yoğun bağlantı yapısı, özellik yeniden kullanımını maksimize ederek hem model kompaktlığını artırır hem de aşırı öğrenme riskini azaltır. Bilgisayarlı görü alanında yaygın kabul gören bu mimari, özellikle tıbbi görüntü analizi de dahil olmak üzere çeşitli görüntü sınıflandırma problemlerinde üstün performans göstermiştir (Ali et al., 2022).

“Kalan Ağ” veya “Artıklı Ağ” anlamına gelen ResNet kaybolan gradyan sorununu aşmak için atlama bağlantıları kullanan bir evrişimli sinir ağı tasarımıdır (He et al., 2016). Bu bağlantılar, ağıın artık fonksiyonları öğrenmesine olanak tanır ve gradyan akışını daha verimli hale getirir. ResNet, görüntü sınıflandırma görevlerinde daha iyi sonuçlar elde etmiş ve bilgisayarlı görü alanında yaygın şekilde benimsenmiştir.

EfficientNet, Google tarafından geliştirilen ve görüntü sınıflandırma performansını önemli ölçüde artıran bir derin öğrenme mimarisidir. “Bileşik Ölçeklendirme” (Compound Scaling) adı verilen bir teknik kullanarak birden fazla hiperparametreyi aynı anda optimize eder ve daha az parametreyle yüksek doğruluk oranları elde eder. Bu özellikleriyle EfficientNet, özellikle kaynak kısıtı olan cihazlarda görüntü sınıflandırma uygulamaları için son derece uygundur (Tan & Le, 2019).

VGG, Oxford Üniversitesi'ndeki Görsel Geometri Grubu tarafından geliştirilen bir evrişimli sinir ağı (CNN) modelidir (Levy et al., 2024). Evrişimsel katmanlar, maksimum havuzlama ve tam bağlı katmanlar düzenli yapısını

oluşturur. VGG, ImageNet (Y. Liu et al., 2021) gibi görüntü sınıflandırma kıyaslamalarındaki dikkate değer performansı nedeniyle sıklıkla alternatif CNN modelleri oluşturmak için bir başlangıç noktası olarak kullanılır.

Inception-v4 (Szegedy et al., 2017) orijinal Inception mimarisini daha gelişmiş bir evrişimli sinir ağı (CNN) tasarımıyla genişletmektedir. Paralel evrişimli katmanlara sahip Inception blokları, faktörleştirilmiş indirgeme ve başlangıç özelliği çıkarma ve çok ölçekli özellik gösterimi için kök blokları dahil edilmiştir. Model, kalıntı bağlantılara sahip Inception bloklarının birleştirilmesini araştırır ve daha iyi eğitim için yardımcı sınıflandırıcıları dahil eder.

MobileNetv3 Howard ve diğerleri (Howard et al., 2019) tarafından mobil telefonlar gibi düşük güç tüketimli cihazlar için özel olarak tasarlanmış bir evrişimli sinir ağı (CNN) mimarisidir. Bu mimari, hesaplama maliyetlerini azaltmak için özellik çıkarımı sırasında düşük boyutlu filtreler kullanır ve bu özelliğiyle gerçek zamanlı mobil uygulamalar için ideal bir seçim oluşturur. MobileNet, nesne tanıma, yüz tanıma ve görüntü sınıflandırma gibi görevlerde oldukça başarılı performans sergilemektedir.

Xception, Inception modeline dayalı bir CNN mimarisidir (Chollet, 2017). Bu mimari, derinlikwise ayrılabilir evrişimler (depthwise separable convolutions) ve noktasal evrişimler (pointwise convolutions) kullanarak parametre ve hesaplama gereksinimlerini azaltırken sınıflandırma doğruluğunu artırmayı başarmıştır. Bilgisayarlı görü uygulamalarında yaygın olarak kullanılan Xception, görüntü sınıflandırma görevlerinde üstün performans sergilemiştir (Ullah et al., 2022).

MobileViTv2 (Mehta & Rastegari, 2022) mobil cihazlarda etkili görüntü sınıflandırma ve nesne tespiti için özel olarak tasarlanmış ileri düzey bir görüntü dönüştürücü (vision transformer) modelidir. Benzersiz nitelikleri arasında, ayrılabilir öz-dikkat gibi karmaşık unsurların entegrasyonu yer almaktadır ve geleneksel öz-dikkat mekanizmasına daha hesaplama açısından verimli bir alternatif sunarak doğruluğu artırmaktadır. Ek olarak, model, bellek kullanımını azaltmak için her katmanın daha küçük kanal gruplarına bölünmesini içeren katman bazlı kanal bölümlendirmesi yoluyla kaynak verimliliği artırmaktadır.

InceptionNext (Yu et al., 2024) hem Inception hem de ConvNeXt mimarilerinin güçlü yönlerini kusursuz bir şekilde entegre eden bir CNN mimarisini temsil eder. InceptionNext'in dikkate değer özellikleri arasında, hesaplama açısından pahalı büyük çekirdekli derinlik bazlı evrişimleri ayrıştırmak için Inception tarzı modüllerin stratejik kullanımı yer alır. Bu ayrıştırma, yüksek doğruluk standartlarını korurken işleme verimliliğini artırır. Model ayrıca, özellik çıkarma yeteneklerinden ödün vermeden hesaplama karmaşıklığını etkili bir şekilde azaltarak derinlik bazlı evrişimleri kullanmaktadır.

MaxViT (Tu et al., 2022) Google YZ araştırmacıları tarafından 2022’de tanıtılan yenilikçi bir görüntü dönüştürücü (vision transformer) modelidir ve görüntü sınıflandırma ile nesne tespiti alanında fark yaratan çok eksenli bir dikkat mekanizmasına sahiptir. Bu mekanizma, birden fazla uzamsal boyutta çalışarak MaxViT’nin görüntüler içindeki kapsamlı global ve bağlamsal bilgileri yakalamasını sağlamaktadır.

Son teknoloji bir görüntü dönüştürücü olan Swin Transformer (Z. Liu et al., 2021) çeşitli bilgisayarlı görüntü görevleri için genel amaçlı bir omurga olarak öne çıkmaktadır ve görüntü sınıflandırması ve yoğun tahminde dikkate değer bir performans sergilemektedir. Bu modelin temel özellikleri şunlardır: (1) yerel (lokal) ve global bilgilerin etkin şekilde yakalanmasını sağlayan hiyerarşik özellik haritaları oluşturma, (2) öz- dikkat hesaplamalarında verimliliği artırmak için kaydırılmış pencereler kullanma ve (3) yüksek çözünürlüklü görüntülerde ölçeklenebilirliğe olanak tanıyan doğrusal hesaplama karmaşıklığıdır.

DeiT III (Touvron, Cord, & Jégou, 2022) Facebook Research tarafından 2023 yılında büyük veri kümelerinde verimli görüntü sınıflandırma için geliştirilmiş en son teknoloji bir görüntü dönüştürücü (vision transformer) modelidir. Önceki versiyonlara kıyasla, DeiT III daha basitleştirilmiş bir eğitim yöntemi sunmaktadır. ResNet-50 temelli bu yeni yaklaşım model karmaşıklığını azaltırken, geliştirilmiş veri çoğaltma teknikleri sayesinde genelleme yeteneğini artırmaktadır. Model ayrıca, bellek tüketimini optimize etmek için katman bazında kanal bölümlenme yöntemini kullanmakta ve özellik toplamayı geliştiren çapraz aşamalı kısmi bağlantılar ile üstün performans sağlamaktadır.

ResMLP (Touvron, Bojanowski, et al., 2022) görüntü sınıflandırma için tamamen çok katmanlı algılayıcılara (MLP) dayanan yenilikçi bir mimaridir. Bu model, iki temel bileşeni birleştiren artık bağlantılı (residual) bir MLP yapısı kullanır: (1) bağımsız yama (patch) etkileşimleri için doğrusal katmanlar ve (2) yama içi kanal etkileşimleri için iki katmanlı ileri beslemeli ağlar. ResMLP’nin öne çıkan özelliği, standart öz-dikkatin mekanizmasının hesaplama karmaşıklığına sahip olmadan uzun menzilli bağımlılıkları yakalayabilen verimli bir “çapraz token dikkati” (cross-token attention) mekanizması içermesidir. Bu yaklaşım, MLP tabanlı modellerin görüntü anlama yeteneklerini önemli ölçüde geliştirirken hesaplama verimliliğini de korumaktadır.

GhostNet (Han et al., 2020) verimli görüntü sınıflandırması için tasarlanmış yüksek performanslı bir CNN mimarisidir. Temel yeniliği olan Ghost modülü, doğrusal dönüşümler ve düşük maliyetli aktivasyon fonksiyonları gibi hesaplama açısından verimli işlemler kullanarak özellik üretimini geliştirirken hesaplama verimliliğini de korumaktadır. GhostNetV2 (Tang et al., 2022). GhostNet mimarisinin gelişmiş bir versiyonudur ve uzun menzilli dikkat

mekanizmalarıyla desteklenen geliştirilmiş düşük maliyetli işlemler sayesinde daha üstün doğruluk ve verimlilik elde etmeyi hedefler. RepGhostNet, ise CNN mimarisinde kritik bir bileşen olan Ghost modülüne yeni ve donanım dostu bir alternatif olarak ortaya çıkmaktadır. RepGhostNet GhostNet'in performans seviyesini korurken, RepGhost hesaplama karmaşıklığında ve bellek kullanımında önemli ölçüde azalma sağlamaktadır.

Apple tarafından 2023 yılında tanıtılan FastViT (Vasu et al., 2023) verimli görüntü sınıflandırması ve nesne tespiti için tasarlanmış çığır açıcı bir CNN-Transformer hibrit mimarisidir. Yapısal yeniden parametrelendirmeyi kullanarak, Transformer öz-dikkatini daha hesaplama açısından verimli bir evrimsel biçime dönüştürür ve doğruluğu korurken karmaşıklığı önemli ölçüde azaltmaktadır. FastViT, erken özellik çıkarma için CNN'leri ve global bağlam toplama için Transformatörleri kullanarak hibrit bir yaklaşım benimsemektedir.


CaFormer (Yu et al., 2023) Weihao Yu ve diğerleri tarafından 2023'te sunulan "Vision için MetaFormer Temel Modelleri"nin bir alt modelidir ve görüntü sınıflandırma ile nesne tespiti görevleri için özelleştirilmiş hafif ve verimli transformatör mimarileri sunar. Bu modeller, standart öz-dikkat mekanizmalarına kıyasla hesaplama karmaşıklığını azaltan IdentityFormer, RandFormer ve ConvFormer gibi verimli token karıştırıcıların kullanımını içerir. Bellek tüketimini optimize etmek için, MetaFormer Temel Modelleri her katmanı daha küçük kanal gruplarına bölen katman bazında kanal bölümlleme tekniğini kullanmaktadır.

4.4. Önerilen Model

Derin öğrenmedeki son gelişmeler, otomatik beyin MR görüntü tanı alanını yeni bir seviyeye taşımaktadır. Özellikle, CNN'ler ve görüntü dönüştürücü (vision transformer) modellerine dikkat mekanizmalarının entegre edilmesi, beyin rahatsızlıklarının teşhisinde performans ve verimliliği belirgin şekilde artırmıştır. EfficientNetv2 mimarisinin modelimizin temeli olarak seçilmesi stratejik bir tercihtir; bu seçim, çeşitli görüntü sınıflandırma görevlerinde kanıtlanmış verimliliği ve ölçeklenebilirliğinden kaynaklanmaktadır. Bununla birlikte, MR tabanlı beyin tümörü sınıflandırmasının kendine özgü zorlukları -özellikle tümör görünümündeki yüksek çeşitlilik ve erken evre belirtilerinin belirsizliği- bu temel mimarinin geliştirilmesini gerektirmektedir. Bu amaçla, EfficientNetv2'ye GAM ve ECA mekanizmalarını entegre ederek modelin karmaşık MR görüntülerindeki önemli özellikleri ayırt etme ve önceliklendirme yeteneği güçlendirilmiştir. Bu iyileştirme, yalnızca bir artırım değil, aynı zamanda modelin kritik ancak belirsiz tümör özelliklerine olan duyarlılığını artırmak için tasarlanmış hedefli bir modifikasyondur ve sınıflandırma görevlerinde önemli bir doğruluk artışı sağlamaktadır.

EfficientNetv2 modelinin çekirdek yapısı MBConv ve Fused-MBConv katmanlarını içermektedir. Kullanılan yöntem, bu mimariyi SE bloğunu GAM ve ECA bloklarıyla değiştirerek ve stratejik yeniden ölçeklendirme uygulayarak zenginleştirmektedir. Bu iyileştirme, beyin tümörlerini daha yüksek hassasiyetle tespit edebilen bir model oluşturmayı hedeflemektedir. GAM ve ECA, bu büyütecin daha etkili çalışmasını sağlamaktadır.

Şekil 8’de model mimarisini ve beyin tümörü tanıma için özel olarak tasarlanmış GAM ile geliştirilmiş Fused-MBConv ile ECA ile güçlendirilmiş MBConv katmanlarını göstermektedir. Bu yenilikçi strateji, geleneksel EfficientNetv2 modeline kıyasla daha az parametre sayısı ile üstün sınıflandırma doğruluğu sağlamaktadır. Yaklaşımımızın kapsamlı bir şekilde anlaşılması için çalışma, önce EfficientNetv2 mimarisinin temel bir özetiyle başlamakta, ardından dikkat mekanizmalarının detaylarını incelemekte ve son olarak mimarinin ölçeklendirilmiş modifikasyonlarını araştırmaktadır.



Şekil 9. GAM ve ECA Blokları ile Önerilen Model

Bu mimaride, ağ boyunca farklı boyut ve konfigürasyonlarda bulunan MBConv modülleri, ağır öğrenme yeteneğini güçlendiren gelişmiş evrimsel katmanlar olarak işlev görür. Özellikle görsel işleme görevleri için kritik olan karmaşık desenleri tanımada ağa esneklik sağlarlar. FusedMBConv ise standart MBConv modülünün evrimleşmiş bir formudur ve ağ genişlemesi yoluyla daha derin özelliklerin çıkarılmasına yardımcı olur. Bu ayarlama, hesaplama gereksinimlerini en aza indirerek hem verimli hem de hızlı modellerin geliştirilmesine olanak tanımaktadır.

Araştırmamızda, ECA modülü SE modülünün yerine MBConv modülüne entegre edilmiştir. Bu iyileştirme, modelin özellik çıkarım yeteneğini güçlendirirken öğrenme kapasitesini genişletir ve derinlik-yönlü uzamsal özelliklerin etkileşimini iyileştirir. FusedMBConv modülü içinde ise SE modülünün

yerini GAM almıştır. GAM, kanal-uzamsal etkileşimleri teşvik ederek değerli bilgileri korur ve daha az parametreyle daha verimli özellik çıkarımı sağlar. Sonuç olarak, bu yaklaşım modelin genel verimliliğini artırırken hesaplama gereksinimlerini de önemli ölçüde azaltmaktadır.

EfficientNetv2 mimarileri, ölçeklenebilir ve yüksek verimli modeller oluşturmayı sağlayan sağlam yapılarıyla bilinir. Bu mimarinin ölçeklenebilirliği, ağın genişliğini, derinliğini ve çözünürlüğünü aynı anda ölçeklendiren benzersiz bir yaklaşımdan kaynaklanır. Bu yöntem, EfficientNetv2'nin model karmaşıklığı ile hesaplama gereksinimleri arasında denge kurmasını sağlayarak hem geniş hem de küçük ölçekli veri kümelerine uyum sağlamasına olanak tanımaktadır. Bu çalışmada, küçük ölçekli beyin MR veri kümelerinin ihtiyaçlarına daha iyi uyum sağlamak için EfficientNetv2'nin en küçük varyantı olan EfficientNetv2-Small ölçeklendirilmiştir. Bu versiyon, her ağ bölümündeki blok tekrarlarının sıklığını gösteren özgün bir katman tekrar düzenine sahiptir. Orijinal katman tekrar dizisi olan 2, 4, 4, 6, 9, 15 yerine özelleştirilmiş bir dizi olan 2, 3, 3, 4, 6, 12 kullanılarak model beyin MR verileri için dikkatle uyarlanmış ve model boyutu ile doğruluk arasında denge sağlanmıştır. Bu tür modifikasyonlar, model karmaşıklığını ve toplam parametre sayısını azaltırken etkinliğini korumasını sağlar. GAM ile geliştirilmiş FusedMBConv ve ECA ile güçlendirilmiş MBConv bloklarının kullanımı sayesinde model, doğruluk üzerinde minimum etki ile yüksek verimliğini sürdürebilmektedir.

4.4.1 EfficientNetv2 Mimarisi

Derin öğrenme modellerinin görüntü işleme kısmında CNN mimarisi yoğun bir şekilde kullanılmaktadır (LeCun et al., 2015). Tan ve Le tarafından 2021 yılında geliştirilen öncü bir CNN tabanlı mimari olan EfficientNetv2, alanda önemli bir ilerlemeyi temsil etmekte ve özellikle EfficientNetv1'de belirlenen eksiklikleri ele alarak verimli özellik çıkarma için özel olarak tasarlanmıştır (Tan & Le, 2021). Başlangıçta optimize edilmiş ikili işlemler ve parametre verimliliği için uyarlanan EfficientNetv2, doğruluk ve hesaplama yükü arasında daha iyi bir denge sağlayan bir başlangıç mimarisi keşfetmek için Sinirsel Mimari Arama (NAS) kullanmaktadır (Tan & Le, 2021). Ardından, model, belirli bir ölçeklendirme katsayıları setiyle ağın sonraki katmanlarına kademeli olarak daha fazla katman ekleyen düzensiz bir ölçeklendirme stratejisi uygulamaktadır. Son olarak, görüntü boyutundaki artışla uyumlu bir şekilde veri düzenleme ve artırma tekniklerini sistematik olarak artıran kademeli öğrenme yöntemleriyle model performansını ve verimliliğini geliştirmektedir. Önceki sürümünün aksine, EfficientNetv2, ilk katmanlarda MBConv ve Fused-MBConv'u yoğun şekilde kullanmakta ve bellek erişim yükünü hafifletmek için daha düşük bir MBConv genişleme oranını tercih etmektedir. Fused-MBConv işleminin entegrasyonu ve titiz optimizasyon çabaları, Effi-

cientNetv2'yi evrişimli sınıflandırma ağları alanında önemli bir çözüm konumuna getirmektedir (Tan & Le, 2021).

4.4.2. EfficientNetv2 Modelleri İçin Dikkat Mekanizması

Dikkat mekanizması, sinir ağlarının bir girdinin önemli bileşenlerine odaklanmasını sağlayan bir yöntemdir (Vaswani et al., 2017). Özellikle bilgisayarlı görü uygulamalarında, ağın arka plan gürültüsüyle ilgi çeken nesneleri ayırt etmesine yardımcı olmaktadır (Wang et al., 2017). Son yıllarda giderek popüler hale gelen bu mekanizma, CNN modellerinin doğruluğunu artırmak için yaygın şekilde kullanılmaktadır (Hu et al., 2018). Dikkat mekanizması, sert (hard) ve yumuşak (soft) dikkat olmak üzere iki ana kategoriye ayrılmaktadır (Xu et al., 2015). Yumuşak dikkat süreci altında ise uzamsal dikkat (spatial attention) (Jaderberg et al., 2015), kanal dikkati (channel attention) (Hu et al., 2018) ve karma (mixed) (Woo et al., 2018) dikkat olarak üç temel tür tanımlanmıştır.


Ağ, uzamsal dikkat kullanarak girdi verisindeki belirli bölgelere seçici şekilde odaklanabilir ve böylece uzamsal ilişkileri ve yapıları daha iyi kavrayabilir. Öte yandan, kanal dikkati, ağın farklı kanallar arasında özellik yanıtlarını ayarlamasını sağlar, böylece ilgili özelliklerin çıkarılmasını kolaylaştırırken gürültüyü bastırır (Pacal et al., 2024). Karma dikkat ise kanal ve uzamsal dikkati birleştirerek, ağa hem kanal hem de uzamsal bilgiyi aynı anda yakalayan kapsamlı bir mekanizma sunar ve bu sayede zorlu görsel tanıma görevlerinde genel performansı artırabilmektedir.

CNN modellerine kanal dikkatini uygulayan ilk önemli girişimlerden biri Squeeze and Excitation Block (SE) olmuştur. CNN alanında, dikkat mekanizmaları derin öğrenme modellerinin geliştirilmesinde temel taş haline gelmiştir. Bu teknikler, ağın hedefli bir şekilde önemli özellikleri vurgulamasını sağlayarak performansını ve ayırt edici yeteneğini artırır. Özellik yanıtlarını yeniden kalibre etmek ve ağın farklı kanallar arasındaki karmaşık bağımlılıkları yakalamasına olanak tanımak için Convolutional Block Attention Module (CBAM), BAM, ECA modülü ve GAM gibi çeşitli dikkat teknikleri geliştirilmiştir.

ECA-Net, Wang ve arkadaşları tarafından 2020 yılında önerilen (Wang et al., 2020) derin CNN'ler için verimli bir kanal dikkat mekanizmasıdır. Görüntüdeki hangi renk veya özellik kanallarının daha önemli olduğunu belirler. Örneğin, bir beyin MR görüntüsünde tümörün olduğu bölgenin rengi veya dokusu daha önemli olabilir. Geleneksel tam bağlı katmanlar yerine, adaptif çekirdek boyutuna sahip 1D evrişim kullanarak yerel kanallar arası etkileşimleri yakalar. Süreç, global ortalama havuzlama (GAP), ardından 1D evrişim ve sigmoid aktivasyonu içerir; bu da girdi öznitelik haritasını modüle eder. Kayda değer performans iyileştirmelerine rağmen, ECA-Net hafif ve verimli yapısını korur, model karmaşıklığını ve hesaplama yükünü en aza indirir.

CBAM (Convolutional Block Attention Module), 2018 yılında Sanghyun Woo ve arkadaşları tarafından önerilen, CNN'ler için hafif ve çok yönlü bir dikkat modülüdür. (Woo et al., 2018). Öznitelik haritalarını iyileştirmek için kanal ve uzamsal boyutlara sırasıyla odaklanır. Kanal dikkat mekanizması, global ortalama havuzlama ve tam bağlı katmanlar aracılığıyla önemli kanalları vurgularken; uzamsal dikkat mekanizması global maksimum havuzlama ve benzer katmanlar kullanarak önemli bölgeleri öne çıkarır. İki dikkat haritasının eleman bazında çarpımıyla elde edilen rafine öznitelik haritası, sonraki CNN katmanlarına aktarılır.

GAM ve CBAM temelde aynı yapıya sahiptir, ancak kanal ve uzamsal dikkat modülleri için farklı matematiksel operatörler kullanırlar. Şekil 9, GAM ve CBAM modüllerinin temel yapısını göstermektedir.



Şekil 10. CBAM ve GAM Mimarileri İçin Temel Yapı

Şekil 9'da gösterildiği gibi, CBAM, Channel Attention Module (CAM) ve Spatial Attention Module (SAM) adlı iki ardışık alt modülün stratejik uygulanmasıyla CNN'lerin performansını önemli ölçüde artırır. CBAM, iki tür dikkat haritası oluşturarak modelin ilgili özelliklere odaklanmasını güçlendirir: $C \times 1 \times 1$ boyutlarında tek boyutlu bir kanal dikkat haritası (M_c) ve $1 \times H \times W$ boyutlarında iki boyutlu bir uzamsal dikkat haritası (M_s). CBAM, beyin tümörü sınıflandırmasında modelin en önemli özelliklere odaklanmasını sağlayarak doğruluğu artırır. Kanal Dikkat Modülü (CAM), MR görüntüsündeki farklı özellik haritaları arasında tümörle ilgili olanları güçlendirirken, gereksiz bilgileri baskılar. Örneğin, bir kanal tümörün kenarlarını belirginleştiriyorsa, model bu kanala daha fazla dikkat eder. Uzamsal Dikkat Modülü (SAM) ise tümörün bulunduğu bölgeyi vurgulayarak gereksiz alanları göz ardı eder, böylece model tümürlü ve tümörsüz alanları daha doğru ayırt eder. Bu iki mekanizma birlikte çalışarak modelin tümörün varlığını ve türünü yüksek doğrulukla belirlemesini sağlar, böylece YZ destekli teşhis sistemleri daha güvenilir hale gelir. Özellikle M_c , tüm öznitelik haritası üzerinde her kanalın


önemini vurgulamak üzere yapılandırılmıştır. Buna karşılık M_s , görüntü içindeki ilgili uzamsal özellikleri öne çıkarır. Bu çift odaklı mekanizma, modelin hem kanal bazında hem de uzamsal bilgiyi önceliklendirerek öznitelik temsillerini uyarlamalı olarak iyileştirmesine olanak tanır, böylece modelin veri içindeki önemli kalıpları ayırt etme yeteneği gelişir. $C \times H \times W$ boyutlarında bir ara öznitelik haritası (F) girdi olarak verildiğinde, CBAM sırasıyla $C \times 1 \times 1$ boyutlarında 1D kanal dikkat haritası (M_c) ve $1 \times H \times W$ boyutlarında 2D uzamsal dikkat haritası (M_s) çıkarır (Şekil 9'da gösterildiği gibi). Genel dikkat süreci, Denklem 1 ve Denklem 2'de formüle edilebilir.

$$F' = M_c(F) \otimes F_1 \quad (1)$$

$$F'' = M_s(F') \otimes F' \quad (2)$$

Burada $\otimes$ sembolü eleman bazında çarpımı temsil eder. Çarpım işlemi sırasında dikkat değerleri uygun şekilde kopyalanır: kanal dikkat değerleri uzamsal boyut boyunca, uzamsal dikkat değerleri ise kanal boyunca çoğaltılır. F'' elde edilen rafine çıktıyı gösterir.

ECA, CBAM ve GAM gibi dikkat mekanizmalarını kullanan CNN'lerde, F_1 , F' ve F'' özellik haritalarının işlenmesindeki farklı aşamaları belirtir. F_1 başlangıçtaki evrimsel katmanlardan türetilir ve çıkarılan özellik kümesini temsil eder. Dikkat mekanizmalarıyla iyileştirmeden geçtikten sonra, bu özellikler şu şekilde temsil edilir: F' Beyin tümörlerinin tespiti gibi görevler için kritik öneme sahip belirli unsurların, önemlerinin dinamik olarak ayarlanmasıyla vurgulandığı bir uygulamadır. F'' daha da rafine edilmiş halini temsil eder F' 'ek işleme veya özellikleri birleştirme yoluyla, böylece modelin kesinliği ve netliği artırılır. Bu, modelin verilerdeki en alakalı bilgileri hassas bir şekilde hedeflemesini ve vurgulamasını sağlar. CBAM mimarisinin, iki ana bileşeni olan CAM ve SAM modüllerinden oluşan temel yapısı Şekil 10'da gösterilmiştir.



Şekil 11. CBAM Ağının Blokları

CBAM çerçevesinin CAM (Kanal Dikkat Modülü) bileşeninde, kanal özellikleri arasındaki ilişkilerden yararlanılarak kanallara odaklanan bir dikkat haritası oluşturulur. Bu modül, girdideki temel unsurları belirlemeye öncelik verir. Bunu başarmak için öncelikle, özellik haritalarının uzamsal yönlerine ortalama ve maksimum havuzlama uygulanarak ve elde edilir. Bu değerler, havuzlar üzerinden ortalaması alınan ve maksimum değeri hesaplanan özellikleri temsil eder. Daha sonra, bu türetilmiş değerler, boyutu $C \times 1 \times 1$ olan ve bir gizli katman içeren özel bir sinir ağı katmanına M_c iletilir. Burada C , kanal sayısını ifade eder. Kanallara ayrılan dikkatin hesaplanma yöntemi denklem 3 ve denklem 4 ile belirlenmiştir.

$$M_c(\mathbf{F}) = \sigma(MLP(AvgPool(\mathbf{F})) + MLP(MaxPool(\mathbf{F}))) \quad (3)$$

$$M_c(\mathbf{F}) = \sigma(W_1(W_0(\mathbf{F}_{avg}^c)) + W_1(W_0(\mathbf{F}_{max}^c))), \quad (4)$$

Bu bağlamda, σ sigmoid aktivasyon fonksiyonunu, W_0 ve W_1 ise ağırlık katsayılarını, MLP ise çok katmanlı algılayıcı ağını ifade etmektedir.

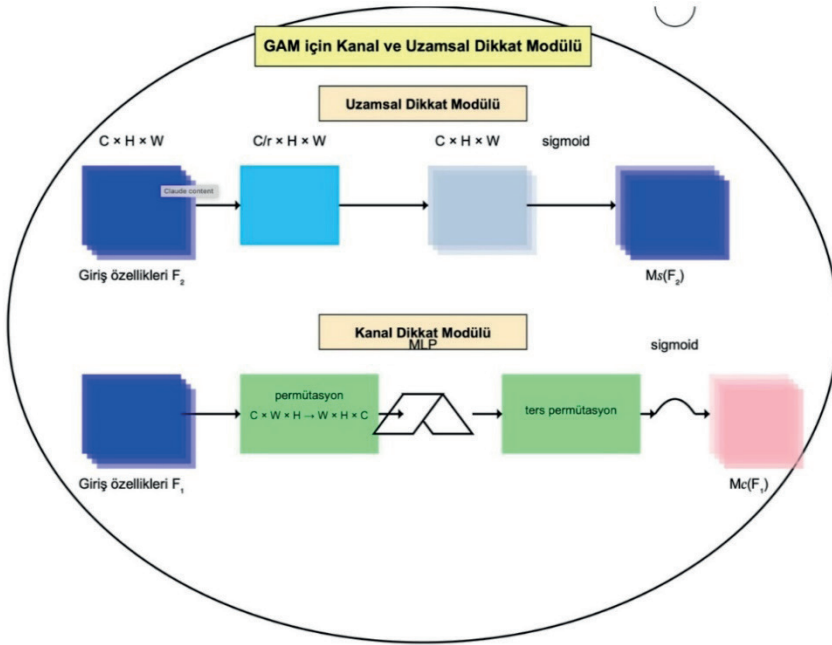
Öte yandan, SAM, uzamsal özellik korelasyonlarını analiz ederek kritik

uzamsal bölgeleri işaretleyen bir harita oluşturur. Kanal önemine odaklanan karıştırdan farklı olarak, SAM, girdi içindeki ilgili bilgilerin yoğunlaştığı belirli konumları belirler. Bu uzamsal dikkat haritalarının oluşturulması için, kanal boyutu üzerinde ortalama ve maksimum havuzlama işlemleri gerçekleştirilir. Bu işlemler, ortalama havuzlanmış uzamsal özellikler için ve maksimum havuzlanmış uzamsal özellikler için edilmesini sağlar. Bu çıktılar daha sonra birleştirilir ve bir evrişim katmanından geçirilerek şeklinde temsil edilen uzamsal dikkat haritası oluşturulur. Bu özel yaklaşım, uzamsal dikkatin belirlenmesini kolaylaştırır. Uzamsal dikkatin hesaplanması, aşağıdaki Denklem 5 ve Denklem 6'da gösterildiği gibi gerçekleşir:

Bu açıklamada σ sigmoid aktivasyon fonksiyonunu $f^{7 \times 7}$ ise 7×7 boyutlarındaki bir filtre kullanılarak yapılan bir evrişimsel işlemi ifade etmektedir.

Öte yandan, beyin tümörü tespiti alanında, veri kümesinin karmaşıklığına yönelik gezinme sürecinde, kritik özellikleri vurgularken ilgisiz bilgileri filtrelemek için sağlam bir mekanizmaya ihtiyaç duyulur. GAM, gereksiz verileri en aza indirme ve global-boyutsal etkileşimleri vurgulama konusundaki etkinliğiyle öne çıkar (Y. Liu et al., 2021). Görüntüdeki hangi bölgelerin (piksel gruplarının) daha önemli olduğunu belirler. Örneğin, tümörün bulunduğu bölge, görüntünün diğer kısımlarından daha önemlidir. GAM'ın bu üstünlüğü, öncelikle veri setinin karmaşık varyasyonları arasında bilgiyi koruma konusundaki gelişmiş kapasitesi nedeniyle, diğer dikkat mekanizmalarıyla yan yana getirildiğinde belirgindir.

GAM, CBAM tarafından oluşturulan temel üzerine inşa edilmiş olup kanal ve uzamsal dikkat sıralamasını korurken, geliştirilmiş alt modüllerle işlem kapasitesini artırır. Kanal dikkat alt modülünde, tüm boyutlarda kapsamlı bilgi koruması sağlamak için 3D permütasyon tekniği kullanır. Bunu takiben, kanal ve uzamsal öğeler arasındaki etkileşimi güçlendiren iki katmanlı bir MLP (Çok Katmanlı Algılayıcı) uygulanarak bağımlılıkların geniş ölçekte yakalanması sağlanır. Uzamsal dikkat bileşeni ise, uzamsal bilgiyi daha tutarlı şekilde birleştirmek üzere özel tasarlanmış iki evrişimsel katman entegre ederek bu yaklaşımı pekiştirir (Şekil 11'de gösterildiği gibi).



Şekil 12. GAM Ağının Blokları

Giriş özelliği eşlemesinde işlem yapılıyor F_1 , ara durum F_2 ve son çıktı F_3 denklem 7 ve denklem 8’lerde gösterildiği gibi bu mekanizma global özellik entegrasyonu ile ağ içindeki bilgi kaybını azaltma arasında bir denge kurmayı amaçlamaktadır.

$$F_2 = M_c(F_1) \otimes F_1 \quad (7)$$

$$F_3 = M_s(F_2) \otimes F_2 \quad (8)$$

GAM’in operasyonel dinamikleri, girdi özellik haritalarını iyileştirmeye yönelik yapılandırılmış yaklaşımını vurgulayan denklemler ve görsel temsillerle gösterilmektedir. Başlangıçta, kanal dikkat haritası M_c , girdi özellik haritası F_1 üzerine uygulanarak bir ara durum F_2 elde edilir. Daha sonra bu ara durum, uzamsal dikkat haritası M_s tarafından daha da iyileştirilir ve nihai çıktı F_3 elde edilir. Bu prosedürel akış, görüntülerdeki önemli özelliklerin kapsamlı bir şekilde geliştirilmesini sağlar ve GAM’i tıbbi görüntü analizi ve beyin tümörü tespiti gibi incelikli alanlarda vazgeçilmez bir araç haline getirir.

4.5 Değerlendirme Ölçütleri

Makine öğreniminde, özellikle beyin tümörü sınıflandırma ve tespitinde, geliştirilen modellerin etkinliğini değerlendirmek için çeşitli performans metrikleri kullanılır. Bu metrikler şunları içerir:

- Doğruluk (Accuracy): Modelin genel tahmin doğruluğunu ölçer
- Kesinlik (Precision): Pozitif tahminlerin doğruluk oranını gösterir
- Duyarlılık (Recall/Sensitivity): Modelin gerçek pozitifleri doğru tanıma yeteneğini ölçer (yanlış negatifleri minimize etmeye odaklanır)
- Özgüllük (Specificity): Negatif tahminlerin doğruluğunu değerlendirir
- F1-Skoru: Kesinlik ve duyarlılığın harmonik ortalamasıdır, dengeli bir ölçüm sunar

Metrik	Formül
Doğruluk (Accuracy)	$\text{Doğruluk} = \frac{\text{Doğru Tahmin Sayısı}}{\text{Toplam Tahmin Sayısı}}$
Kesinlik (Precision)	$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}}$
Duyarlılık (Recall) / Hassasiyet (Sensitivity)	$\text{Duyarlılık} = \text{Hassasiyet} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}}$
F1 Skoru (F1 Score)	$\text{F1 Skoru} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{(\text{Kesinlik} + \text{Duyarlılık})}$

Araştırmacılar, bu metrikleri ve oluşturulan hata matrisini (confusion matrix) inceleyerek modelin beyin tümörü vakalarını doğru sınıflandırma yeteneği hakkında kapsamlı bilgi edinebilirler.

4.6 DeneySEL Tasarım

Deneylerde kullanılan bilgisayarın donanım konfigürasyonu şu şekildedir: Ubuntu 21.04 adlı Linux tabanlı bir işletim sistemi kullanılmıştır. GPU donanımı olarak 11 GB GDDR6 RAM ve 4352 CUDA çekirdeğine sahip NVIDIA RTX 2080TI ekran kartı kullanılmıştır. İşlemci olarak 10 çekirdekli, 3,50 GHz ve 19,25 MB Intel® Smart Cache'e sahip Intel Core i9 9900X ve 32 GB DDR4 RAM kullanılmıştır. Programlama dili olarak Python, PyTorch derin öğrenme kütüphanesi kullanılmıştır.

BÖLÜM V:

ARAŞTIRMANIN BULGULARI VE TARTIŞMA

Bu bölümde çalışmanın bulguları ve tartışma kısmı birlikte verilmiştir. Model kıyaslamaları yapıldığı için tartışma bölümünün de burada verilmesi daha uygun olacağı düşünülmüştür. Aynı zamanda, beyin tümörü tanısı bağlamında gelişmiş derin öğrenme modellerinin kapsamlı bir değerlendirmesini yapılmaktadır. Önerilen tanı modeliyle ilişkili karışıklık matrisinde tasvir edilen performans ölçütlerini ve sonuçları tartışılmıştır. Tablo 7’de sunulan bulgular, VGG19 hariç tüm derin öğrenme modellerinin beyin tümörlerini doğru bir şekilde tanımlamada %99’u aşan doğruluk oranlarına ulaştığını göstermektedir. Bu sonuçlar, radyoloji uzmanlarının beyin tümörlerini doğru bir şekilde tanı koymalarında yardımcı olmakta derin öğrenme metodolojilerinin etkinliğini ve güvenilirliğini vurgulayabilmektedir. Bu modellerin radyoloji alanında tanı doğruluğunu ve hasta sonuçlarını önemli ölçüde iyileştirme potansiyeli olabilmektedir.

Tablo7’debeyintümörütanımlamasıiçinMRgörüntülerinisınıflandırmada çeşitli derin öğrenme mimarilerinin performansını karşılaştırır. Doğruluk, kesinlik, duyarlılık ve F1 puanı gibi önemli performans ölçütlerine göre VGG, ResNet, DenseNet, Inception, MobileNet, MobileViTv2, FastViT, GhostNet, RepGhostNet, MaxViT, Swin, DeiT3, ResMLP ve Caformer gibi popüler modelleri değerlendirir.


Tablo 7. Derin Öğrenme Modellerinin Sonuçları

Model	Doğruluk	Kesinlik	Geri Çağırma	F1- Skoru
VGG-13	0.9924	0.9918	0.9917	0.9917
VGG-16	0.9908	0.9901	0.9901	0.9901
VGG-19	0.9855	0.9844	0.9853	0.9848
ResNet-18	0.9931	0.9929	0.9925	0.9927
ResNet-34	0.9931	0.9928	0.9925	0.9926
ResNet-50	0.9923	0.9921	0.9917	0.9919
ResNet-101	0.9924	0.9919	0.9917	0.9918
DenseNet-121	0.9947	0.9942	0.9942	0.9942
DenseNet-169	0.9931	0.9928	0.9925	0.9926

DenseNet-201	0.9946	0.9945	0.9942	0.9943
Xception	0.9924	0.9920	0.9917	0.9918
Inceptionv3	0.9947	0.9945	0.9942	0.9943
Inceptionv4	0.9939	0.9940	0.9934	0.9937
InceptionNexT-base	0.9947	0.9944	0.9942	0.9943
MobileNetv3-small	0.9947	0.9946	0.9942	0.9944
MobileNetv3-large	0.9916	0.9914	0.9909	0.9911
MobileViTv2-100	0.9939	0.9936	0.9934	0.9935
FastViT-t12	0.9931	0.9928	0.9926	0.9927
FastViT-s12	0.9954	0.9953	0.9950	0.9952
FastViT-sa36	0.9947	0.9945	0.9942	0.9943
GhostNet-100	0.9947	0.9945	0.9942	0.9943
GhostNetv2-100	0.9931	0.9928	0.9926	0.9927
RepGhostNet-100	0.9939	0.9938	0.9934	0.9936
RepGhostNet-200	0.9954	0.9953	0.9950	0.9952
MaxViT-base	0.9954	0.9950	0.9950	0.9950
Swin-base	0.9947	0.9943	0.9942	0.9942
DeiT3-base	0.9931	0.9926	0.9930	0.9928
ResMLP-24	0.9939	0.9936	0.9934	0.9935
Caformer-s18	0.9924	0.9918	0.9917	0.9917
Caformer-s36	0.9954	0.9953	0.9950	0.9951
Önerilen Model	0.9977	0.9976	0.9975	0.9975

Önemli bir bulgu, Önerilen Modelin %99,77 doğruluk, %99,76 hassasiyet, %99,75 duyarlılık ve %99,75 F1 puanı ile en yüksek performansı göstermesidir. Bu, Önerilen Modelin beyin tümörü sınıflandırması için incelenen diğer tüm derin öğrenme modellerine göre önemli bir üstünlüğe sahip olduğunu gösterir ve özellikle beyin tümörlerini tespit etmek için kullanılan özel dikkat mekanizmaları ve model optimizasyonları sayesinde daha hassas ve etkili sınıflandırma yapma yeteneğini vurgular. Ayrıca, DenseNet-121 ve Inceptionv3 gibi mimariler de %99,47 civarında doğruluk oranlarıyla dikkat çekici bir performans sergilerken, VGG-19 modeli %98,55'lik nispeten daha düşük bir performans göstermektedir. Performanstaki bu farklılık, modelin mimarisinin ve kullanılan özellik çıkarma tekniklerinin sonuçları nasıl önemli ölçüde etkileyebileceğini göstermektedir. Özellikle, %99,54'lük yüksek doğruluk oranları gösteren FastViT-s12 ve RepGhostNet-200 gibi modeller, görsel sınıflandırma görevlerinde transformatör tabanlı ve hafif modellerin potansiyelini vurgulamaktadır. Bu sonuçlar, çeşitli derin öğrenme mimarilerinin beyin tümörü tanısı gibi belirli tıbbi görüntüleme görevlerinde nasıl farklı performans gösterebileceğini ve en uygun modeli seçmenin önemini göstermektedir.

Benzer şekilde, MaxViT-base, Swin-base, DeiT3-base ve ResMLP-24 gibi dikkat çekici mimariler beyin tümörü tanımlama görevlerinde etkileyici performans göstermiştir. Özellikle MaxViT-base ve Swin-base sırasıyla %99,54 ve %99,47 doğruluk oranlarıyla öne çıkarak karmaşık görsel özellikleri etkili bir şekilde işleme kabiliyetlerini ve tıbbi görüntüleme için derin öğrenme uygulamalarındaki önemli potansiyellerini sergilemektedir. DeiT3-base, %99,31 doğrulukla transformatör mimarilerinin gücünü vurgularken, ResMLP-24, %99,39 doğrulukla bu alanda MLP mimarilerinin etkinliğini doğrulamaktadır. Sonuç olarak, bu bulgular derin öğrenme yaklaşımlarının tıbbi görüntülemede, özellikle MR kullanılarak beyin tümörlerinin teşhisinde etkinliğini ve potansiyelini aydınlatmaktadır. Şekil 12'de belirtilen tüm modeller için bir çubuk grafiği göstermektedir.




Şekil 13. Önerilen Model ve Derin Öğrenme Modellerinin Sonuçları İçin Çubuk Grafik

Şekil 12'de, Önerilen Model olarak adlandırılan en iyi performans gösteren model kırmızıyla ayırt edilirken, sonraki ilk dört model, yani Caformer-s36, MaxViT-base, RepGhostNet-200 ve FastViT-s12, yeşille gösterilmiştir. Geriye kalan modeller, karşılaştırmalı olarak daha düşük performanslarını belirtmek için griyle gölgelendirilmiştir. Ayrıca, Tablo 8, beyin MR veri kümelerini kullanarak EfficientNetv1 ve EfficientNetv2 çerçeveleri içindeki model performanslarının bir karşılaştırmasını sunmaktadır. Ayrıca, Önerilen Model tarafından elde edilen sonuçlarla birlikte, EfficientNetv2-small modelinin uygulanmasıyla birlikte CNN tabanlı mimariler için farklı dikkat mekanizmalarının kullanılmasının etkisini vurgulamaktadır.

Tablo 8. Önerilen Modelin Yanı Sıra Farklı Dikkatlere Sahip Tüm EfficientNet Modellerinin Sonuçları

Model	Doğruluk	Kesinlik	Geri Çağırma	F1-Skoru	Params (M)
EfficientNet-B0	0.9931	0.9929	0.9925	0.9927	4.02
EfficientNet-B1	0.9947	0.9945	0.9942	0.9943	6.52
EfficientNet-B2	0.9954	0.9953	0.9950	0.9952	7.71
EfficientNet-B3	0.9954	0.9953	0.9950	0.9951	10.71
EfficientNet-B4	0.9954	0.9953	0.9950	0.9952	17.56
EfficientNet-B5	0.9954	0.9953	0.9950	0.9951	28.35
EfficientNet-B6	0.9947	0.9947	0.9942	0.9944	40.75
EfficientNet-B7	0.9947	0.9944	0.9942	0.9943	63.79
EfficientNetv2-small	0.9954	0.9953	0.9950	0.9951	20.19
EfficientNetv2-medium	0.9954	0.9952	0.9950	0.9951	52.87
EfficientNetv2-large	0.9954	0.9953	0.9950	0.9952	117.24
EfficientNetv2-small + CBAM	0.9954	0.9951	0.9950	0.9951	22.52
EfficientNetv2-small + ECA	0.9962	0.9961	0.9959	0.9960	17.76
EfficientNetv2-small + GAM	0.9969	0.9967	0.9967	0.9967	88.67
Proposed Model (GAM + ECA)	0.9977	0.9976	0.9975	0.9975	14.41

Tablo 8, beyin tümörlerini tespit etmek için kullanılan çeşitli EfficientNet modelleri ile önerilen bir model arasında kapsamlı bir karşılaştırma sunmaktadır. Bu karşılaştırma, doğruluk, kesinlik, geri çağırma ve F1 puanı gibi performans ölçütleri açısından ayrıntılı bir analiz sunarken, aynı zamanda dikkat mekanizmalarının etkisini derinlemesine araştırmayı amaçlamaktadır. Bu bölüm, önerilen model (GAM+ECA) ile birlikte hem EfficientNet hem de EfficientNetv2 serilerinin performansına ilişkin analizleri ve dikkat mekanizmalarının beyin tümörü tespiti üzerindeki etkilerini sunmaktadır. EfficientNet ve EfficientNetv2 serileri arasındaki kapsamlı bir karşılaştırma, her iki serinin de Şekil 13'da gösterildiği gibi çeşitli yapılandırmalarda mükemmel performans ölçütleri sağladığını göstermektedir.



Şekil 14. Önerilen Model ve Dikkat Mekanizmasına Sahip EfficientNet Tabanlı Modellerin Sonuçları İçin Çubuk Grafik

Şekil 13, EfficientNet modelleri ve ek dikkat mekanizmalarına sahip EfficientNet modelleri tarafından elde edilen doğruluk metriği üzerindeki başarıları göstermektedir. Önerilen model en yüksek başarıyı göstermektedir (kırmızıyla vurgulanmıştır), en yakın 4 model de yeşille vurgulanmıştır ve diğer EfficientNet mimarilerine ait modeller ve optimizasyonlar griyle gösterilmiştir.

Özellikle, EfficientNetv2 serisi ve dikkat mekanizmasıyla geliştirilmiş varyantları, model karmaşıklığını artırmadan performansı önemli ölçüde iyileştirmeleri nedeniyle öne çıkmaktadır. Önerilen modelin etkinliği, farklı dikkat mekanizmalarının EfficientNetv2-Small modeline entegre edilmesiyle somutlaştırılıyor. FusedMBConv bloklarındaki SE modüllerini GAM ile ve MBConv bloklarındaki SE modüllerini ECA mekanizmalarıyla değiştiren bu entegrasyon, hibrit bir yaklaşımı temsil ediyor. Bu strateji, modelin toplam parametre sayısını 14,41 milyona düşürürken doğruluğu %99,77'ye, hassasiyeti %99,76'ya, geri çağırma %99,75'e ve F1 puanını %99,75'e yükseltiyor. Bu, modelin hafif yapısını ve hesaplama kaynaklarını ve eğitim süresi gereksinimlerini azaltırken üstün performans ölçütlerine ulaşma yeteneğini vurguluyor. Özellikle, bu optimizasyon GPU kullanımında ve FLOP'larda da önemli azalmalara yol açmaktadır.

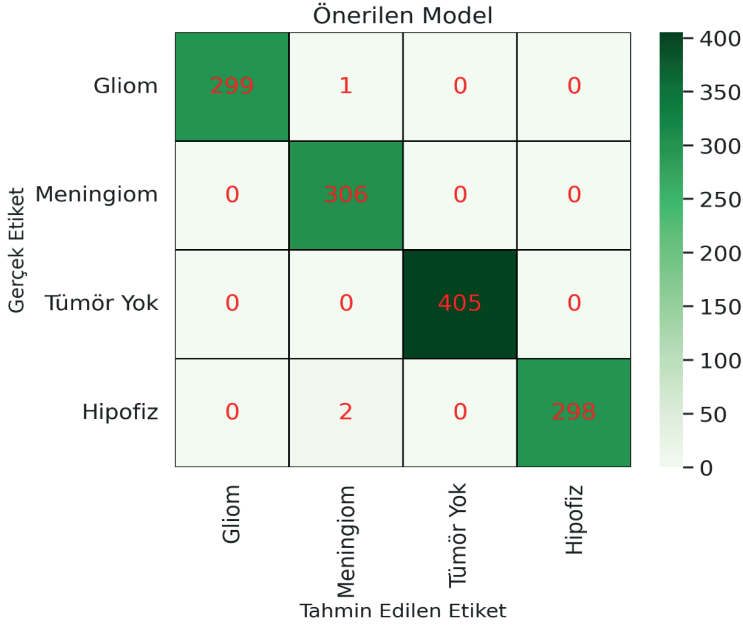
Önerilen modelin verimliliği, azaltılmış parametre sayısında ve hesaplama ayak izinde belirgindir. Özellikle, model derinlik bazında ayrılabilir evrimlerden ve modelin genişliğini, derinliğini ve çözünürlüğünü bileşik bir şekilde ayarlayan ölçeklenebilir bir mimariden yararlanır, performanstan ödün ver-

meden hız ve bellek kullanımını optimize eder. VGG ve ResNet gibi geleneksel CNN mimarileriyle karşılaştırıldığında, önerilen model hesaplama hızı ve bellek verimliliğinde önemli iyileştirmeler göstermektedir. Örneğin, VGG-16 138 milyondan fazla parametre gerektirebilirken, önerilen EfficientNetv2 tabanlı model, eklenen dikkat mekanizmalarıyla bile, önemli ölçüde daha düşük bir parametre sayısını koruyarak daha hızlı eğitim sürelerine ve azaltılmış bellek gereksinimlerine katkıda bulunur. Çıkarım hızı açısından, önerilen model VGG-16 ve ResNet-50 gibi klasik modellere göre belirgin bir iyileştirme sergilemektedir. Aynı donanımda kıyaslandığında önerilen model, VGG-16'dan 2 kata kadar, ResNet-50'den ise 1,5 kata kadar daha hızlı çıkarım sürelerine ulaşarak, MR görüntülerinin gerçek zamanlı analizini ve sınıflandırılmasını kolaylaştırıyor.

Parametre sayısı ve hesaplama maliyeti (FLOP, GPU kullanımı) ile ilgili analiz, daha yüksek parametre sayısının veya hesaplama yoğunluğunun mutlaka daha iyi performansla ilişkili olmadığını ortaya koymaktadır. Sırasıyla 5,3 ve 7,8 milyon parametreye sahip EfficientNet-B0 ve EfficientNet-B1 modelleri %99,31 ve %99,47 doğruluk oranları sunmaktadır. Buna karşılık, sırasıyla 12 ve 19 milyon parametreye sahip EfficientNet-B3 ve EfficientNet-B4 modelleri, karşılaştırılabilir yüksek hassasiyet, geri çağırma ve F1 puanlarıyla birlikte %99,54'lük benzer yüksek bir doğruluk seviyesini korumaktadır. EfficientNetv2 serisindeki en büyük model olan EfficientNetv2-Large, 48 milyon parametreye sahip olmasına rağmen %99,54 doğruluk, %99,53 hassasiyet, %99,50 geri çağırma ve %99,52 F1 puanı ile etkileyici performans ölçümleri sergilemektedir.

Dikkat mekanizmalarının etkisine ilişkin araştırmalar, ECA'nın EfficientNetv2-Small modeline entegre edilmesinin parametre sayısını 20,19 milyondan 17,76 milyona düşürdüğünü, doğrulukta (%99,62), kesinlikte (%99,61), geri çağırmada (%99,59) ve F1 puanında (%99,60) önemli iyileştirmeler sağladığını göstermektedir. Parametre sayısını 88,67 milyona çıkararak GAM kullanımı, doğruluğu %99,54'ten %99,69'a çıkararak genel performansı önemli ölçüde artırmış ve diğer metriklerde olumlu sonuçlar sağlamıştır. Ancak CBAM'ın entegre edilmesi, diğer metriklerde önemli iyileştirmeler sağlamadan parametre sayısını 22,52 milyona çıkarmıştır. Önerilen model (GAM + ECA), yalnızca parametre sayısında ve hesaplama maliyetinde bir azalma değil, aynı zamanda mevcut modellerle karşılaştırıldığında doğruluk, kesinlik, geri çağırma ve F1 puanı gibi kritik performans metriklerinde de önemli iyileştirmeler göstermektedir. Bu, beyin tümörlerinin derin öğrenmeye dayalı tespitinde önemli bir ilerleme olduğunu kanıtlamakta ve modelin performans ile verimlilik arasında etkili bir denge kurma yeteneğini ortaya koyabilmektedir. Önerilen modelin başarısı, derin öğrenme modelleri geliştirmede dikkat mekanizmalarının stratejik entegrasyonunun önemini vurguluyor. Bu bulgu-

lar, gelecekteki araştırmalar için bir temel oluşturarak daha verimli ve etkili derin öğrenme modellerinin geliştirilmesini teşvik etmektedir. Şekil 14'te önerilen modelin sınıf performansını gösteren karışıklık matrisini gösteriyor.




Şekil 15. Önerilen Modelin Sınıf Bazında Performansı

Şekil 14'ü inceledikten sonra, karışıklık matrisinin ayrıntılı değerlendirmesi, sınıflandırma modelinin dört kategoriye ayırt etmede üstün performansını doğrulamaktadır. Bunlar gliom, menenjiom, hipofiz ve tümörsüzdür. Model, 299 doğru tahminle gliomu ve 298 doğru tahminle hipofiz tümörlerini tanımlamada daha iyi bir hassasiyet sergileyebilmekte ve daha iyi bir doğruluğa ulaşabilmektedir. Benzer şekilde, sırasıyla 306 ve 405 doğru tahminle menenjiom ve tümörsüz vakaları tanımlamada daha iyi bir hassasiyet elde edebilmektedir. Tutarlılıklar, glioma olarak yanlış sınıflandırılan bir menenjiom vakası ve modelin hipofiz tümörlerini yanlış bir şekilde menenjiom olarak etiketlediği iki durum dahil olmak üzere asgari düzeydedir. Bu sonuçlar, modelin her kategori için hassasiyet, geri çağırma ve F1 puanlarında yüksek metrikler elde ettiğini, belirli durumları ve genel tümör dışı durumları ayırt etme konusunda dengeli ve sağlam bir kapasiteyi yansıttığını göstermektedir. Modelin yanlış sınıflandırma yapması oldukça nadirdir; bu da farklı beyin tümörü tiplerini ayırt etmedeki başarısını ve tümör olmayan vakaları doğru şekilde tanıma yeteneğini gösterir. Bu durum, modelin yüksek doğruluk oranını ve farklı tümör sınıfları arasında güçlü bir genelleme kapasitesine sahip olduğunu ortaya koymaktadır.

5.1. Grad-CAM Kullanılarak Görselleştirme Analizi


Gradient-weighted Class Activation Mapping (Grad-CAM), CNN'lerin kararları nasıl aldığını yorumlamak ve görselleştirmek için kullanılan etkili bir tekniktir. Ana amacı, bir giriş görüntüsünde ağırlıklı belirli bir sınıf için tahminlerini büyük ölçüde etkileyen önemli bölgeleri belirlemektir. Beyin tümörü sınıflandırması alanında Grad-CAM, CNN tabanlı modellerin önceliklendirdiği belirli özellikleri görsel olarak gösteren temel bir araç görevi görür. Bu açıklama, modelin sınıflandırma kararlarının ardındaki gerekçeye dair paha biçilmez içgörüler sunarak, teşhis yeteneklerine ilişkin anlayışımızı güçlendirir. Tıbbi görüntüleme bağlamlarında kesin beyin tümörü tanımlama ve sınıflandırma için çok önemli olan bu analiz sayesinde, modelin güvenilirliği önemli ölçüde artırılır. Ampirik kanıtlar, Önerilen Modelin beyin tümörlerini doğru bir şekilde sınıflandırmada mükemmel olduğunu doğrulayarak, diğer modellere kıyasla üstünlüğünü vurgular. Grad-CAM'in modelimize entegre edilmesi, yapay zeka destekli tıbbi teşhislerde yorumlanabilirliğe yönelik kritik bir ihtiyacı ele alır. Bu teknik, sınıflandırma kararlarını etkileyen MR taramalarındaki belirli bölgeleri vurgulayarak modelin karar alma sürecini aydınlatır. Bir modelin tahmininin temelini anlaşılmasının tahminin doğruluğu kadar hayati önem taşıdığı beyin tümörü tanısı bağlamında, Grad-CAM paha biçilmez bir araç görevi görür. Sadece radyologların ve klinisyenlerin YZ'nın bulgularını doğrulamalarına yardımcı olmakla kalmaz, aynı zamanda teknolojiye daha derin bir güven de sağlar. Grad-CAM, modelin operasyonel mantığına dair şeffaf ve yorumlanabilir içgörüler sağlayarak YZ modelleri ve tıp uzmanları arasındaki iş birliği potansiyelini artırır ve daha bilgili ve etkili tedavi planlamasının önünü açar. Şekil 15, Grad-CAM'in Önerilen Model ile entegrasyonunun beyin tümörü bölgelerindeki belirli konumlara nasıl odaklandığını göstermektedir.



Şekil 16. Önerilen Model İçin Grad-CAM Görselleştirmeleri (Uzman Bir Nörolog Tarafından İşaretlenen Temel Gerçek Bölgeleri Gösteren Kırmızı “+” İşaretleriyle)

Şekil 15'te görüldüğü gibi, görünen iki satır yapay zekanın yorumlanabilirliği ve beyin tümörlerini tespit etmede modelin doğruluğu hakkında önemli ayrıntılar sunmaktadır. İlk satırdaki radyolog tarafından işaretlenen beyin tümörü lokasyonları manuel olarak konumlandırılmış referans noktaları olarak hizmet eder. Önerilen Modelin Grad-CAM ile entegrasyonu, ikinci satırda modelin kategorizasyon seçimlerinin altında yatan nedenleri ortaya çıkaran ısı haritası görselleştirmeleri üretmektedir.

Ek olarak, modelin ortaya koyduğu sonuçlar yorumlanabilir. Bu da radyologlar ve uzmanlar arasında güveni artırabilir. Bu bağlamda Grad-CAM, önerilen modelin işleyişini görsel olarak yorumlayan ve tümör bölgelerini belirleyen önemli bir araç olarak ortaya konulabilir. Beyin tümörlerinin sınıflandırılması gibi kritik alanlarda yapay zekanın yorumlanabilirliğini destekleyebilir. Önerilen modelin Grad-CAM görselleştirmeleri, bazı hatalı bölge ve yanlış sınıflandırmalar içermektedir ve Şekil 16'da gösterilmiştir.



Şekil 17. Önerilen Model İçin Yanlış Bölgeler ve Yanlış Sınıflandırmalar İçeren Grad-CAM Görselleştirmeleri (Uzman Bir Nörolog Tarafından İşaretlenen Temel Gerçek Bölgeleri Gösteren Kırmızı “+” İşaretleriyle)

Şekil 16'ta Önerilen Modelin Grad-CAM analiz sonuçları bazı yanlış sınıflandırmalar ve yanlış odak alanları içermektedir. İnceleme üzerine, Önerilen Modelin Grad-CAM ile entegrasyonunun yanlış sınıflandırılmış beyin tümörlerini tam olarak karakterize edemediğini ve yanlış bölgelere odaklandığını gözlemleyebiliriz. Hem Önerilen Modelin hatalı tespitleri hem de Grad-CAM'in yanlış sınıflandırılmış tümör bölgeleri dışındaki alanlara odaklanması, her iki yöntemin uyumluluğunu ve etkinliğini göstererek Grad-CAM'in CNN tabanlı derin öğrenme tekniklerindeki başarılı sonuçlarını sergilemektedir.

Tümörsüz görüntüler söz konusu olduğunda, Grad-CAM tekniğini kullanan modeller odaklarını farklı alanlara kaydırmaktadır. Yüksek doğruluk elde edilmesine rağmen, Grad-CAM'in her zaman kesin yerleştirme sağlamadığı

söylenebilir. Bu, Grad-CAM'in sınırlamalarının ötesinde yorumlanabilirliği artırmak için yapay zeka ve tıbbi görüntü işlemede daha sağlam ve gelişmiş teknikler geliştirme ihtiyacını vurgulamaktadır.

Şekil 9 ve Şekil 10'da görüldüğü gibi, Grad-CAM, CNN modellerinin “kara kutu” doğasının bir kısmının üstesinden gelmeye ve karar mekanizmalarını daha yorumlanabilir hale getirmeye yardımcı olabilir. Önerilen Model tarafından gösterildiği gibi, bu yöntem modelin tıbbi teşhislerine olan güveni artırabilir ve doktorların modelin teşhislerinin doğrulanması ve yorumlanmasına daha fazla dahil olmasını sağlayabilir. Ancak, tam yorumlanabilirlik sağladığı iddia edilemez. Yine de bu konudaki zorlukları ele alan gelişmiş teknikler geliştirerek, yapay zeka tıbbi alanda daha yüksek bir yorumlanabilirlik düzeyine ulaşabilir.

Bir radyoloğun bir beyin MRG'sini yorumlamak için harcadığı ortalama süreye ilişkin doğrudan çalışmalar, deneyimli radyologların (uzmanlar) beyin MRG'lerini bağımsız olarak okumak için ortalama 11 dakika harcadığını göstermektedir. Eğitimdeki asistan ve uzmanlık öğrencileri ise bağımsız okuma yaparken sırasıyla ortalama 18 dakika ve 16 dakika gibi daha uzun süreler harcamaktadır. Görüntü incelemeye ayrılan süre, uzmanlar için 4.07 ila 5.33 dakika arasında değişirken, asistanlar ve uzmanlık öğrencileri için daha uzundur (asistanlar için 7.14 dakika, uzmanlık öğrencileri için 8.06 dakika) (Al Yassin et al., 2018).

Araştırma materyalinde belirtildiği üzere, manuel MRI yorumlamasının tıp uzmanları için zaman alıcı ve hataya açık olması, yapay zeka destekli çözümlerin sunduğu hızın değerini ortaya koymaktadır. Modelin VGG-16'dan 2 kat ve ResNet-50'den 1.5 kat daha hızlı çıkarım süreleri sunması, bu hızlanmanın somut bir göstergesidir. Örneğin, bir radyoloğun karmaşık bir MRI taramasını başlangıçta yorumlamak için 15-20 dakika harcadığı bir senaryoda, yapay zeka modelinin kritik alanları önceden işlemesi veya yüksek güvenle sınıflandırma sağlaması, radyoloğun inceleme süresini %20-30 oranında azaltabilir. Bu, tarama başına 3 ila 6 dakika arasında bir tasarruf anlamına gelir. Günde 50 ila 100 beyin MRI taraması işleyen bir hastane için bu, kümülatif olarak günlük 150 ila 600 dakika (2.5 ila 10 saat) tanı süresi tasarrufu sağlayabilir. Modelin %99.76'lık yüksek doğruluğu ve Grad-CAM ile sağlanan yorumlanabilirliği, yeniden değerlendirme, ikinci görüş veya hata düzeltme ihtiyacını azaltarak zaman alıcı faaliyetleri de minimize etmektedir. Bu, sadece tanı hızını değil, aynı zamanda tüm hasta bakım yolunu iyileştirerek daha iyi sağlık ve ekonomik sonuçlara yol açan önemli bir verimlilik artışıdır.

Bu çalışmada önerilen modelin üstünlüğünü doğrulamak için kapsamlı deneyler yürütülmüş ve modelin performansı kapsamlı bir dizi derin öğrenme modeli ile kıyaslanmıştır. Bu karşılaştırmalı analiz, modelin MR tabanlı beyin

tümörü sınıflandırma teknolojilerinin mevcut manzarası içinde konumlandırıldığı, etkinliğini ve verimliliğini gösterdiği için çok önemlidir. Tablo 9, önerilen modelin diğer derin öğrenme yöntemlerine göre performansı göstermektedir.

Tablo 9. Önerilen Model ve Son Teknoloji Yöntemler (Kaggle Veri Seti figshare, SARTAJ Veri Seti ve Br35H'den Oluşur)

Yazarlar ve Yıl	Veriseti	Method	Doğruluk %
(Celik & Inik, 2024)	Kaggle	CNN + SVM	97.93
(Remzan et al., 2024)	Kaggle	Ensemble + CNN	97.40
(Anantharajan et al., 2024)	Kaggle	DNN + SVM	97.93
(Özkaraca et al., 2023)	Kaggle	CNN-based	96.00
(Rahman & Islam, 2023)	Kaggle	CNN-based	98.12
(Muezzinoglu et al., 2023)	Kaggle	CNN-based	98.10
(Zebari et al., 2024)	Figshare	DBN + CNN	98.98
(Tabatabaei et al., 2023)	Figshare	CNN + Attention	99.30
(Deepak & Ameer, 2023)	Figshare	CNN + SVM	95.60
(Zulfiqar et al., 2023)	Figshare	CNN-based	98.86
(Ghassemi et al., 2020)	Figshare	CNN + GAN	95.60
(Mehnatkesh et al., 2023)	Figshare	CNN-based	98.69
(Swati et al., 2019a)	Figshare	CNN-based	94.82
(Sajjad et al., 2019)	Figshare	CNN-based	90.67
(Rehman et al., 2020)	Figshare	CNN-based	98.69
(Mzoughi et al., 2020)	BraTS	CNN-based	96.49
(Sharif et al., 2021)	BraTS	CNN-based	98.80
Önerilen Model	Kaggle	GAM + ECA + EfficientNetv2	99.76

Tablo 9'da göz önünde bulundurarak, Önerilen Model MR tabanlı beyin tümörü sınıflandırmasında %99,76'lık bir doğruluk oranına ulaşarak önemli bir başarı elde etmiştir. Bu başarı, Celik ve Inik (Celik & Inik, 2024), Anantharajan ve ark (Anantharajan et al., 2024) ve Deepak ve Ameer (Deepak & Ameer, 2023) tarafından kullanılan ve %95,60 ile %97,93 arasında değişen doğruluk oranları sunan geleneksel CNN mimarilerine veya hibrit yaklaşımlara (CNN + SVM, DNN + SVM) göre dikkate değer bir üstünlüğü göstermektedir. Dikkat mekanizmalarının sınıflandırma hassasiyetini nasıl artırabileceğini gösteren modelimiz, bu oranları önemli ölçüde aşmaktadır.

Bu tezde, MRG'ye dayalı beyin tümörlerini sınıflandırmak için Global Dikkat Mekanizması (GAM) ve Verimli Kanal Dikkati (ECA) ile yeniden ölçeklendirilmiş EfficientNetv2 modelinin yeni bir uygulaması sunulmuştur. Kapsamlı deneysel analizden de anlaşılabacağı üzere, model %99,76 gibi etki-leyici bir test doğruluğuna ulaşarak literatürde iyi bir performans elde etmiş-

tir. Çalışmanın her aşamasında, diğer 45 derin öğrenme modeliyle yapılan karşılaştırma, burada önerilen yöntemin beyin tümörü teşhisinde daha etkili olduğunu kanıtlamaktadır. Dikkat mekanizmalarının kullanılması, tümör tiplerinin karakteristik özelliklerinin ayırt edilmesini kolaylaştırmak için MR görüntülerindeki önemli özelliklere odaklanılmasını sağlamıştır.

Grad-CAM görselleştirme tekniklerinin uygulanması, modelin karar verme sürecine yorumlanabilirlik katmış, bu da klinisyenlerin yapay zeka destekli sonuçlara olan güvenini pekiştirecektir. Bu nedenle, modelin şeffaflığı klinik karar destek sistemlerinin geliştirilmesi ve hasta bakımının basitleştirilmesi açısından önemlidir.

Ek olarak, Remzan ve ark (Remzan et al., 2024) ve Rahman ve İslam (Rahman & İslam, 2023) gibi topluluk yöntemleri ve gelişmiş CNN çerçeveleri kullanan çalışmalar, %98,20'nin altında doğruluk oranları göstermiştir. Bu yenilikçi yaklaşımlar, dikkat mekanizmalarıyla entegre edilmiş EfficientNetv2 tabanlı modelimizin verimliliği ve doğruluğu tarafından geride bırakılmıştır. Ek olarak, Tabatabaei ve ark (Tabatabaei et al., 2023) dikkat mekanizmalarını içeren bir model önermiş ve Figshare veri setinde %99,30 doğruluk elde etmiş olsa da, modelimiz bu doğruluğu daha da ilerletmiş ve özellikle GAM ve ECA gibi belirli dikkat mekanizmalarının etkinliğini vurgulamıştır.

Önerilen modelin üstünlüğü tek bir veri kümesinin ötesine uzanmaktadır, çünkü Zebari ve ark (Zebari et al., 2024), Muezzinoglu ve ark (Muezzinoglu et al., 2023) ve diğerlerinin farklı veri kümelerinde bildirdiği modellere kıyasla daha yüksek doğruluk oranları göstermektedir ve bu da önerilen modelin sağlamlığını ve genelleştirilebilirliğini kanıtlamaktadır. Önerilen modelin öne çıkan yönü, GAM ve ECA gibi dikkat mekanizmalarının EfficientNetv2 ile bütünleştirilmesinde yatmaktadır. Bu özel kombinasyon, modelin karmaşık MR görüntülerindeki önemli özellikleri doğru bir şekilde tespit etmesine olanak sağlamaktadır.

SONUÇ VE ÖNERİLER

Sağlık hizmetlerinin sunumu, yönetimi ve hasta deneyimi, YZ odaklı teknolojinin ilerlemesi ve mevcut sistemlere daha da entegre edilmesiyle giderek daha fazla dijitalleşmektedir (Bohr & Memarzadeh, 2020; Faiyazuddin et al., 2025; Kumar et al., 2023). Sağlık yönetimi perspektifinden bakıldığında, bu çalışma sağlık hizmetlerinin dijitalleştirilmesine ve verilerle karar verilmesine katkı sağlayabilir. Aynı zamanda yapay zekâ tabanlı tanı, teşhis araçlarının geliştirilmesi, radyoloji uzmanlarının iş yüklerini hafifletebilir ve klinik operasyonları daha etkili bir şekilde planlamasına olanak sunabilmektedir.

Modelin sağladığı teşhis hızı ve doğruluğu, hastaların bekleme sürelerini kısaltabilir. Bu da özellikle yoğun bakım üniteleri ve acil servisler gibi zaman ve kaynak açısından kısıtlı klinik ortamlarda operasyonel verimliliği artırır ve maliyet tasarrufu sağlayabilir. Aynı zamanda, radyologlar ve klinik ekipler, model tarafından sağlanan ayrıntılı tümör özellikleri sayesinde kişiselleştirilmiş ve etkili tedavi planları geliştirebilmektedir. Böylece hasta sonuçlarının ve yaşam kalitesinin iyileştirilmesi mümkün olabilmektedir.

Sağlık bilişiminde, önerilen yaklaşımın veri fonksiyonlarının entegre edilebilirliği ve yorumlanabilirliği, klinik iş akışlarının bilgisayarlaştırılmasında önemli bir kilometre taşı olarak görülebilir. Büyük tıbbi veri setlerinin analizi ve işlenmesi, veriye dayalı karar destek sistemlerini ve sağlık bilgi sistemlerinin etkinliğini geliştirmektedir. Modelin hesaplama açısından hafif çerçevesi, kaynakların kısıtlı olduğu ortamlarda bile uygulanabilirliğini kolaylaştırarak özellikle düşük ve orta gelirli ülkelerde sağlık eşitsizliklerinin azaltılmasına katkıda bulunabilir.

Sağlık bilişimi, YZ ve derin öğrenme gibi teknolojilerle büyük bir dönüşüm geçirmekte, karar alma süreçlerinde nesnellik ve doğruluk sağlamaktadır. Bu teknolojilerin klinik, yönetsel ve operasyonel süreçlerde daha etkin kullanımı, sağlık sistemlerinin verimliliğini ve hasta bakım kalitesini artırma potansiyeline sahiptir. Ancak bu dönüşüm sürecinde etik ilkeler, veri güvenliği ve insan denetimi gibi konuların da göz önünde bulundurulması elzemdir. Gelecekte sağlık sistemleri, insan uzmanlığı ile yapay zekânın entegre şekilde çalıştığı hibrit yapılara doğru evrilebileceğini söylemek yerinde bir tespit olacaktır.

Sağlık politikası yapıcıları için modelin sunduğu hızlı teşhis, sağlık hizmetlerinin görüntüleme alanında kaynak tahsisinde (radyoloji uzmanlarının zamanları) önemli avantajlar sunabilir. Hem gereksiz maliyetlerin önlenmesi hem de operasyonel verimliliğin artırılması klinik hizmetlerin kalitesini artı-

racak ve sağlık sistemlerinin sürdürülebilirliğini sağlayabilir. Modelin yaygın kullanımı konusunda dikkate alınması gereken bir dizi kısıtlama bulunmaktadır. Veri setinin boyutu ve çeşitliliği, modelin diğer hasta gruplarına genellenilebilirliğini sınırlandırabilir. Buna ek olarak, Grad-CAM'in sağladığı yorumlanabilirlik bazı klinisyenler tarafından karar verme sürecinin gizlenmesi olarak algılanabilir ve bu da teknolojinin klinik kabulünü olumsuz etkileyebilecek potansiyel bir risk olarak görülebilir.

Gelecekte, araştırma ve geliştirme sürecinde modelin bazı yönlerine odaklanılması önerilmektedir. Birincisi, farklı kaynaklardan elde edilen büyük ölçekli ve çeşitli veri setlerinin kullanılması, modelin önyargılarını azaltarak genelleme gücünü potansiyel olarak artırabilir. İkinci olarak, Grad-CAM'in üzerine modelin iç işleyişini daha fazla ortaya çıkarmaya devam edecek ve klinik yorumlanabilirliği geliştirecek yeni yöntemlerin eklenmesi, son kullanıcıların güvenini pekiştirecektir. Üçüncü olarak, hesaplama gereksinimlerinin basitleştirilmesi ve modelin mobil ve uç bilişim cihazları gibi çeşitli platformlara dağıtımının kolaylaştırılması, teknolojinin daha fazla kişi ve kuruma ulaştırılmasına imkan sağlayabilir.

Genel olarak bu tez, derin öğrenme ve yapay zekâ tabanlı beyin tümörü teşhis yöntemlerinin hastaların bakım kalitesini artırma, operasyonel etkinliği sağlama ve maliyet tasarrufu elde etme potansiyeline nasıl sahip olabileceğini örnek bir uygulama ile göstermektedir. Bu teknolojilerin sağlık hizmeti sunumunda ve sağlık bilgi sistemi tasarımında uygulanması, gelecekte tıp uygulamalarında büyük bir ilerleme potansiyeline sahip olduğu söylenebilir. Sağlık politikası yapımcıları için, sistem maliyetinin azaltılması, kaynak kullanımının en üst düzeye çıkarılması ve klinik süreçlerin bilgisayarlaştırılması gibi stratejik avantajlar, uzun vadede sürdürülebilir ve etkili sağlık sistemleri oluşturmaya merkezinde yer alacaktır.

Sonuç olarak, yeni yöntem sadece teknik bir yenilik değil, aynı zamanda sağlık bilişimi, sağlık hizmetleri ve sağlık politikası yapımcıları için stratejik öneme sahiptir. Sonraki çalışmalarda, modelin sınırlamalarının üstesinden gelinmesi ve büyük veri tabanlarıyla entegre edilmesi, bu yeni yöntemin tam potansiyeline ulaşılmasını sağlayacak ve böylece daha gelişmiş, uygun maliyetli ve kişiselleştirilmiş tıbbi teşhis ve tedavi planlamasına yol açacaktır.

KAYNAKÇA

- Abdelaziz, T., & Rosa, E. (2024). Electronic health records with decision support systems for sharper diagnoses: bibliometric analysis. *International Journal of Advances in Applied Sciences*, 13. <https://doi.org/10.11591/ijaas.v13.i2.pp411-418>.
- Adalberto Filho, M., Znaor, A., Sunguc, C., Zahwe, M., Marcos-Gragera, R., Figueroa, J. D., & Bray, F. (2025). Cancers of the brain and central nervous system: global patterns and trends in incidence. *Journal of neuro-oncology*, 172(3), 567-578.
- Adeniyi, A. O., Arowoogun, J. O., Chidi, R., Okolo, C. A., & Babawarun, O. (2024). The impact of electronic health records on patient care and outcomes: A comprehensive review. *World Journal of Advanced Research and Reviews*, 21(2), 1446-1455.
- Ahmad, H. F., Rafique, W., Rasool, R. U., Alhumam, A., Anwar, Z., & Qadir, J. (2023). Leveraging 6G, extended reality, and IoT big data analytics for healthcare: A review. *Computer Science Review*, 48, 100558.
- Ahmed, A., Xi, R., Hou, M., Shah, S. A., & Hameed, S. (2023). Harnessing big data analytics for healthcare: A comprehensive review of frameworks, implications, applications, and impacts. *IEEE Access*.
- Ahmed, M. I., Spooner, B., Isherwood, J., Lane, M., Orrock, E., & Dennison, A. (2023). A systematic review of the barriers to the implementation of artificial intelligence in healthcare. *Cureus*, 15(10).
- Al Kuwaiti, A., Nazer, K., Al-Reedy, A., Al-Shehri, S., Al-Muhanna, A., Subbarayalu, A. V., Al Muhanna, D., & Al-Muhanna, F. A. (2023). A review of the role of artificial intelligence in healthcare. *Journal of personalized medicine*, 13(6), 951.
- Al Yassin, A., Sadaghiani, M. S., Mohan, S., Bryan, R. N., & Nasrallah, I. (2018). It is About" Time": Academic Neuroradiologist Time Distribution for Interpreting Brain MRIs. *Academic Radiology*, 25(12), 1521-1525.
- Alanazi, M. F., Ali, M. U., Hussain, S. J., Zafar, A., Mohatram, M., Irfan, M., AlRuwaili, R., Alruwaili, M., Ali, N. H., & Albarrak, A. M. (2022). Brain tumor/mass classification framework using magnetic-resonance-imaging-based isolated and developed transfer deep-learning model. *Sensors*, 22(1), 372.
- Ali, S., Li, J., Pei, Y., Khurram, R., Rehman, K. U., & Mahmood, T. (2022). A comprehensive survey on brain tumor diagnosis using deep learning and emerging hybrid techniques with multi-modal MR image. *Archives of computational methods in engineering*, 29(7), 4871-4896.
- Alowais, S. A., Alghamdi, S. S., Alsuhebany, N., Alqahtani, T., Alshaya, A. I., Almohareb, S. N., Aldairem, A., Alrashed, M., Bin Saleh, K., & Badreldin, H. A. (2023). Revolutionizing healthcare: the role of artificial intelligence in clinical practice. *BMC medical education*, 23(1), 689.
- Alruwaili, A. A., & De Jesus, O. (2023). Meningioma. In *StatPearls [Internet]*. StatPearls Publishing.

- Amal, S., Safarnejad, L., Omiye, J. A., Ghanzouri, I., Cabot, J. H., & Ross, E. G. (2022). Use of multi-modal data and machine learning to improve cardiovascular disease care. *Frontiers in cardiovascular medicine*, 9, 840262.
- Anantharajan, S., Gunasekaran, S., Subramanian, T., & Venkatesh, R. (2024). MRI brain tumor detection using deep learning and machine learning approaches. *Measurement: Sensors*, 31, 101026.
- Annarumma, M., Withey, S. J., Bakewell, R. J., Pesce, E., Goh, V., & Montana, G. (2019). Automated triaging of adult chest radiographs with deep artificial neural networks. *Radiology*, 291(1), 196-202.
- Arnott, D., Pervan, G., & Dodson, G. (2004). Decision Support Systems Research 1990 to 2003: A Descriptive Analysis.
- Atun, R., Aydın, S., Chakraborty, S., Sümer, S., Aran, M., Gürol, I., Nazlıoğlu, S., Özgülcü, Ş., Aydoğan, Ü., & Ayar, B. (2013). Universal health coverage in Turkey: enhancement of equity. *The Lancet*, 382(9886), 65-99.
- Awuah, W. A., Adebuseye, F. T., Wellington, J., David, L., Salam, A., Yee, A. L. W., Lansiaux, E., Yarlagadda, R., Garg, T., & Abdul-Rahman, T. (2024). Recent outcomes and challenges of artificial intelligence, machine learning and deep learning applications in neurosurgery—Review applications of artificial intelligence in neurosurgery. *World Neurosurgery*: X, 100301.
- Azhagiri, M., & Rajesh, P. (2024). EAN: enhanced AlexNet deep learning model to detect brain tumor using magnetic resonance images. *Multimedia Tools and Applications*, 1-17.
- Bajwa, J., Munir, U., Nori, A., & Williams, B. (2021). Artificial intelligence in healthcare: transforming the practice of medicine. *Future healthcare journal*, 8(2), e188-e194.
- Banachewicz, K., & Massaron, L. (2022). *The Kaggle Book: Data analysis and machine learning for competitive data science*. Packt Publishing Ltd.
- Bhagyalaxmi, K., Dwarakanath, B., & Reddy, P. V. P. (2024). Deep learning for multi-grade brain tumor detection and classification: a prospective survey. *Multimedia Tools and Applications*, 1-23.
- Bhuvaji, S., Kadam, A., Bhumkar, P., Dedge, S., & Kanchan, S. (2020). Brain tumor classification (MRI). *Kaggle*, 10.
- Bohr, A., & Memarzadeh, K. (2020). *Artificial intelligence in healthcare*. Academic Press.
- Bondy, M. L., Scheurer, M. E., Malmer, B., Barnholtz-Sloan, J. S., Davis, F. G., Il'Yasova, D., Kruchko, C., McCarthy, B. J., Rajaraman, P., & Schwartzbaum, J. A. (2008). Brain tumor epidemiology: consensus from the Brain Tumor Epidemiology Consortium. *Cancer*, 113(S7), 1953-1968.
- Celard, P., Iglesias, E. L., Sorribes-Fdez, J. M., Romero, R., Vieira, A. S., & Borrajo, L. (2023). A survey on deep learning applied to medical images: from simple artificial neural networks to generative models. *Neural Computing and Applications*, 35(3), 2291-2323.

- Celik, M., & Inik, O. (2024). Development of hybrid models based on deep learning and optimized machine learning algorithms for brain tumor Multi-Classification. *Expert Systems with Applications*, 238, 122159.
- Chahal, P. K., Pandey, S., & Goel, S. (2020). A survey on brain tumor detection techniques for MR images. *Multimedia Tools and Applications*, 79(29), 21771-21814.
- Chan, H.-P., Samala, R. K., Hadjiiski, L. M., & Zhou, C. (2020). Deep learning in medical image analysis. *Deep learning in medical image analysis: challenges and applications*, 3-21.
- Charles, N. A., Holland, E. C., Gilbertson, R., Glass, R., & Kettenmann, H. (2011). The brain tumor microenvironment. *Glia*, 59(8), 1169-1180.
- Chen, M., Hao, Y., Hwang, K., Wang, L., & Wang, L. (2017). Disease prediction by machine learning over big data from healthcare communities. *Ieee Access*, 5, 8869-8879.
- Chen, M., Wang, Y., Wang, Q., Shi, J., Wang, H., Ye, Z., Xue, P., & Qiao, Y. (2024). Impact of human and artificial intelligence collaboration on workload reduction in medical image interpretation. *NPJ digital medicine*, 7(1), 349.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Chow, W. (2019). A pedagogy that uses a kaggle competition for teaching machine learning: an experience sharing. 2019 ieee international conference on engineering, technology and education (tale),
- Coiera, E. (2015). *Guide to health informatics*. CRC press.
- Collen, M. F., & Shortliffe, E. H. (2015). The creation of a new discipline. *The History of Medical Informatics in the United States*, 75-120.
- Cresswell, K., Rigby, M., Magrabi, F., Scott, P., Brender, J., Craven, C. K., Wong, Z. S.-Y., Kukhareva, P., Ammenwerth, E., & Georgiou, A. (2023). The need to strengthen the evaluation of the impact of Artificial Intelligence-based decision support systems on healthcare provision. *Health policy*, 136, 104889.
- Davenport, T., & Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future healthcare journal*, 6(2), 94-98.
- Deepak, S., & Ameer, P. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, 111, 103345.
- Deepak, S., & Ameer, P. (2023). Brain tumor categorization from imbalanced MRI dataset using weighted loss and deep feature fusion. *Neurocomputing*, 520, 94-102.
- Dehe, B., & Bamford, D. (2017). Quality Function Deployment and operational design decisions—a healthcare infrastructure development case study. *Production Planning & Control*, 28(14), 1177-1192.

- Demirhan, A., & Güler, İ. (2011). Bilişim ve sağlık. *Bilişim Teknolojileri Dergisi*, 4(3), 13-20.
- Deo, R. C. (2015). Machine learning in medicine. *Circulation*, 132(20), 1920-1930.
- Dicuonzo, G., Donofrio, F., Fusco, A., & Shini, M. (2023). Healthcare system: Moving forward with artificial intelligence. *Technovation*, 120, 102510.
- Dubois, C., Eigen, D., Delmas, E., Einfalt, M., Lemaçon, C., Berteloot, L., Bossuyt, P. M., Drummond, D., Scherdel, P., & Simon, F. (2024). Deep learning in medical image analysis: introduction to underlying principles and reviewer guide using diagnostic case studies in paediatrics. *bmj*, 387.
- Eisemann, N., Bunk, S., Mukama, T., Baltus, H., Elsner, S. A., Gomille, T., Hecht, G., Heywang-Köbrunner, S., Rathmann, R., & Siegmann-Luz, K. (2025). Nationwide real-world implementation of AI for cancer detection in population-based mammography screening. *Nature medicine*, 1-8.
- Elhaddad, M., & Hamam, S. (2024). AI-driven clinical decision support systems: an ongoing pursuit of potential. *Cureus*, 16(4).
- 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.
- Faggella, D. (2018). Where healthcare's big data actually comes from. *Tech Emerg*, 11.
- Faiyazuddin, M., Rahman, S. J. Q., Anand, G., Siddiqui, R. K., Mehta, R., Khatib, M. N., Gaidhane, S., Zahiruddin, Q. S., Hussain, A., & Sah, R. (2025). The Impact of Artificial Intelligence on Healthcare: A Comprehensive Review of Advancements in Diagnostics, Treatment, and Operational Efficiency. *Health Science Reports*, 8(1), e70312.
- Fang, R., Pouyanfar, S., Yang, Y., Chen, S.-C., & Iyengar, S. (2016). Computational health informatics in the big data age: a survey. *ACM Computing Surveys (CSUR)*, 49(1), 1-36.
- Farajzadeh, N., Sadeghzadeh, N., & Hashemzadeh, M. (2023). Brain tumor segmentation and classification on MRI via deep hybrid representation learning. *Expert Systems with Applications*, 224, 119963.
- Farooq, M. U., Ullah, Z., Khan, A., & Gwak, J. (2023). DC-AAE: dual channel adversarial autoencoder with multitask learning for KL-grade classification in knee radiographs. *Computers in Biology and Medicine*, 167, 107570.
- Gartner, I. (2014). Glossary: big data. *Gartner Inc. Available (accessed on 13.7. 2017): <https://research.gartner.com/definition-what-is-bigdata>*, 1-8163325102.
- Genel, T. S. B. H. S. (2023). Müdürlüğü Türkiye Kanser İstatistikleri. In.
- Ghassemi, N., Shoeibi, A., & Rouhani, M. (2020). Deep neural network with generative adversarial networks pre-training for brain tumor classification based on MR images. *Biomedical Signal Processing and Control*, 57, 101678.

- Ghebrehiwet, I., Zaki, N., Damseh, R., & Mohamad, M. S. (2024). Revolutionizing personalized medicine with generative AI: a systematic review. *Artificial intelligence review*, 57(5), 128.
- Giordano, C., Brennan, M., Mohamed, B., Rashidi, P., Modave, F., & Tighe, P. (2021). Accessing artificial intelligence for clinical decision-making. *Frontiers in digital health*, 3, 645232.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1). MIT press Cambridge.
- Grout, R., Gupta, R., Bryant, R., Elmahgoub, M. A., Li, Y., Irfanullah, K., Patel, R. F., Fawkes, J., & Inness, C. (2024). Predicting disease onset from electronic health records for population health management: a scalable and explainable Deep Learning approach. *Frontiers in Artificial Intelligence*, 6, 1287541.
- Hamada, A. (2020). Br35h:: Brain tumor detection 2020. *Version 5*.
- Han, K., Wang, Y., Tian, Q., Guo, J., Xu, C., & Xu, C. (2020). Ghostnet: More features from cheap operations. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition,
- Hardy, L. R. (2023). *Health Informatics: An Interprofessional Approach*. Elsevier. <https://books.google.com/books?id=2cQazwEACAAJ>
- Hayashi, T., Shimizu, T., & Fukami, Y. (2021). Collaborative Problem Solving on a Data Platform Kaggle. *arXiv preprint arXiv:2107.11929*.
- Hayat, Y., Tariq, M., Hussain, A., Tariq, A., & Rasool, S. (2024). A Review of Biosensors and Artificial Intelligence in Healthcare and Their Clinical Significance. *International Research Journal of Economics and Management Studies IRJEMS*, 3(1).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Helaly, H. A., Badawy, M., & Haikal, A. Y. (2024). A review of deep learning approaches in clinical and healthcare systems based on medical image analysis. *Multi-media Tools and Applications*, 83(12), 36039-36080.
- Herholz, K., Langen, K.-J., Schiepers, C., & Mountz, J. M. (2012). Brain tumors. Seminars in nuclear medicine,
- Hersh, W. (2022). Health Informatics.
- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., & Vasudevan, V. (2019). Searching for mobilenetv3. Proceedings of the IEEE/CVF international conference on computer vision,
- Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. Proceedings of the IEEE conference on computer vision and pattern recognition,

- Humby, C. (2006). Data is the New Oil. ANA Senior marketer's summit. Kellogg School. In.
- Işık, O., & Akbolat, M. (2010). Bilgi teknolojileri ve hastane bilgi sistemleri kullanımı: Sağlık çalışanları üzerine bir araştırma. *Bilgi Dünyası*, 11(2), 365-389.
- Jaderberg, M., Simonyan, K., & Zisserman, A. (2015). Spatial transformer networks. *Advances in Neural Information Processing Systems*, 28.
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., & Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and vascular neurology*, 2(4).
- Johnson, A. E., Pollard, T. J., Shen, L., Lehman, L.-w. H., Feng, M., Ghassemi, M., Moody, B., Szolovits, P., Anthony Celi, L., & Mark, R. G. (2016). MIMIC-III, a freely accessible critical care database. *Scientific data*, 3(1), 1-9.
- Johnson, K. B., Wei, W. Q., Weeraratne, D., Frisse, M. E., Misulis, K., Rhee, K., Zhao, J., & Snowdon, J. L. (2021). Precision medicine, AI, and the future of personalized health care. *Clinical and translational science*, 14(1), 86-93.
- Jyothi, P., & Singh, A. R. (2023). Deep learning models and traditional automated techniques for brain tumor segmentation in MRI: a review. *Artificial intelligence review*, 56(4), 2923-2969.
- Kaggle. (2024).
- Karaman, A., Karaboga, D., Pacal, I., Akay, B., Basturk, A., Nalbantoglu, U., Coskun, S., & Sahin, O. (2023). Hyper-parameter optimization of deep learning architectures using artificial bee colony (ABC) algorithm for high performance real-time automatic colorectal cancer (CRC) polyp detection. *Applied Intelligence*, 53(12), 15603-15620.
- Karaman, A., Pacal, I., Basturk, A., Akay, B., Nalbantoglu, U., Coskun, S., Sahin, O., & Karaboga, D. (2023). Robust real-time polyp detection system design based on YOLO algorithms by optimizing activation functions and hyper-parameters with artificial bee colony (ABC). *Expert Systems with Applications*, 221, 119741.
- Kastrup, N., Holst-Kristensen, A. W., & Valentin, J. B. (2024). Landscape and challenges in economic evaluations of artificial intelligence in healthcare: A systematic review of methodology. *BMC Digital Health*, 2(1), 1-12.
- Kaya, Z. (2024). Dört sınıflı veri seti kullanarak beyin tümörlerinin sınıflandırılması. *Anadolu Bil Meslek Yüksekokulu Dergisi*, 19(69), 67-74.
- Khalifa, M., & Albadawy, M. (2024). AI in diagnostic imaging: Revolutionising accuracy and efficiency. *Computer Methods and Programs in Biomedicine Update*, 100146.
- Khan, M. S. I., Rahman, A., Debnath, T., Karim, M. R., Nasir, M. K., Band, S. S., Mosa-vi, A., & Dehzangi, I. (2022). Accurate brain tumor detection using deep convolutional neural network. *Computational and structural biotechnology journal*, 20, 4733-4745.

- Kim, J. T. (2018). Application of machine and deep learning algorithms in intelligent clinical decision support systems in healthcare. *J Health Med Inform*, 9, 321.
- Koh, D.-M., Papanikolaou, N., Bick, U., Illing, R., Kahn Jr, C. E., Kalpathi-Cramer, J., Matos, C., Martí-Bonmatí, L., Miles, A., & Mun, S. K. (2022). Artificial intelligence and machine learning in cancer imaging. *Communications Medicine*, 2(1), 133.
- Kolides, A., Nawaz, A., Rathor, A., Beeman, D., Hashmi, M., Fatima, S., Berdik, D., Al-Ayyoub, M., & Jararweh, Y. (2023). Artificial intelligence foundation and pre-trained models: Fundamentals, applications, opportunities, and social impacts. *Simulation Modelling Practice and Theory*, 126, 102754.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Kumar, Y., Koul, A., Singla, R., & Ijaz, M. F. (2023). Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda. *Journal of ambient intelligence and humanized computing*, 14(7), 8459-8486.
- Kunduracioglu, I., & Pacal, I. (2024). Advancements in deep learning for accurate classification of grape leaves and diagnosis of grape diseases. *Journal of Plant Diseases and Protection*, 131(3), 1061-1080.
- Kurtulus, I. L., Lubbad, M., Yilmaz, O. M. D., Kilic, K., Karaboga, D., Basturk, A., Akay, B., Nalbantoglu, U., Yilmaz, S., & Ayata, M. (2024). A robust deep learning model for the classification of dental implant brands. *Journal of Stomatology, Oral and Maxillofacial Surgery*, 101818.
- Küçük, F., & Çelik, Ö. (2023). *Sağlık kurumlarında bilgi sistemleri ve e-hizmetler* (Y. Demirhan & M. Korkutan, Eds.).
- Lamba, N., Wen, P. Y., & Aizer, A. A. (2021). Epidemiology of brain metastases and leptomeningeal disease. *Neuro-oncology*, 23(9), 1447-1456.
- Lau, A. Y., & Staccini, P. (2019). Artificial intelligence in health: new opportunities, challenges, and practical implications. *Yearbook of medical informatics*, 28(01), 174-178.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Levy, A. S., Bhatia, S., Merenzon, M. A., Andryski, A. L., Rivera, C. A., Daggubati, L. C., Di, L., Shah, A. H., Komotar, R. J., & Ivan, M. E. (2024). Exploring the landscape of machine learning applications in neurosurgery: a bibliometric analysis and narrative review of trends and future directions. *World neurosurgery*, 181, 108-115.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van Der Laak, J. A., Van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.

- Liu, Y., Shao, Z., & Hoffmann, N. (2021). Global attention mechanism: Retain information to enhance channel-spatial interactions. *arXiv preprint arXiv:2112.05561*.
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. Proceedings of the IEEE/CVF international conference on computer vision,
- Liu, Z., Tong, L., Chen, L., Jiang, Z., Zhou, F., Zhang, Q., Zhang, X., Jin, Y., & Zhou, H. (2023). Deep learning based brain tumor segmentation: a survey. *Complex & Intelligent Systems*, 9(1), 1001-1026.
- Lubbad, M., Karaboga, D., Basturk, A., Akay, B., Nalbantoglu, U., & Paçal, I. (2024). Machine learning applications in detection and diagnosis of urology cancers: a systematic literature review. *Neural Computing and Applications*, 36(12), 6355-6379.
- Lubbad, M. A., Kurtulus, I. L., Karaboga, D., Kilic, K., Basturk, A., Akay, B., Nalbantoglu, O. U., Yilmaz, O. M. D., Ayata, M., & Yilmaz, S. (2024). A comparative analysis of deep learning-based approaches for classifying dental implants decision support system. *Journal of Imaging Informatics in Medicine*, 1-22.
- Makond, B., Wang, K.-J., & Wang, K.-M. (2021). Benchmarking prognosis methods for survivability—A case study for patients with contingent primary cancers. *Computers in Biology and Medicine*, 138, 104888.
- Mandle, A. K., Sahu, S. P., & Gupta, G. P. (2024). WSSOA: whale social spider optimization algorithm for brain tumor classification using deep learning technique. *International Journal of Information Technology*, 1-17.
- McCorduck, P., & Cfe, C. (2004). *Machines who think: A personal inquiry into the history and prospects of artificial intelligence*. AK Peters/CRC Press.
- Mehnatkesh, H., Jalali, S. M. J., Khosravi, A., & Nahavandi, S. (2023). An intelligent driven deep residual learning framework for brain tumor classification using MRI images. *Expert Systems with Applications*, 213, 119087.
- Mehta, S., & Rastegari, M. (2022). Separable self-attention for mobile vision transformers. *arXiv preprint arXiv:2206.02680*.
- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in bioinformatics*, 19(6), 1236-1246.
- Mondal, A., & Shrivastava, V. K. (2022). A novel Parametric Flatten-p Mish activation function based deep CNN model for brain tumor classification. *Computers in Biology and Medicine*, 150, 106183.
- Montagnon, E., Cerny, M., Cadrin-Chênevert, A., Hamilton, V., Derennes, T., Ilinca, A., Vandenbroucke-Menu, F., Turcotte, S., Kadoury, S., & Tang, A. (2020). Deep learning workflow in radiology: a primer. *Insights into imaging*, 11, 1-15.
- Montani, S., & Striani, M. (2019). Artificial intelligence in clinical decision support: a focused literature survey. *Yearbook of medical informatics*, 28(01), 120-127.
- Morley, J., Murphy, L., Mishra, A., Joshi, I., & Karpathakis, K. (2022). Governing data

and artificial intelligence for health care: developing an international understanding. *JMIR formative research*, 6(1), e31623.

- Muezzinoglu, T., Baygin, N., Tuncer, I., Barua, P. D., Baygin, M., Dogan, S., Tuncer, T., Palmer, E. E., Cheong, K. H., & Acharya, U. R. (2023). PatchResNet: multiple patch division-based deep feature fusion framework for brain tumor classification using MRI images. *Journal of Digital Imaging*, 36(3), 973-987.
- Myers, D., Mohawesh, R., Chellaboina, V. I., Sathvik, A. L., Venkatesh, P., Ho, Y.-H., Henshaw, H., Alhawawreh, M., Berdik, D., & Jararweh, Y. (2024). Foundation and large language models: fundamentals, challenges, opportunities, and social impacts. *Cluster Computing*, 27(1), 1-26.
- Mzoughi, H., Njeh, I., Wali, A., Slima, M. B., BenHamida, A., Mhiri, C., & Mahfoudhe, K. B. (2020). Deep multi-scale 3D convolutional neural network (CNN) for MRI gliomas brain tumor classification. *Journal of Digital Imaging*, 33, 903-915.
- Najjar, R. (2023). Redefining radiology: a review of artificial intelligence integration in medical imaging. *Diagnostics*, 13(17), 2760.
- Nazir, M., Shakil, S., & Khurshid, K. (2021). Role of deep learning in brain tumor detection and classification (2015 to 2020): A review. *Computerized medical imaging and graphics*, 91, 101940.
- Ngiam, K. Y., & Khor, W. (2019). Big data and machine learning algorithms for health-care delivery. *The Lancet Oncology*, 20(5), e262-e273.
- Nickparvar, M. (2021). Brain tumor MRI dataset. *Kaggle*.
- Nielsen, M. A. (2015). *Neural networks and deep learning* (Vol. 25). Determination press San Francisco, CA, USA.
- Nuthakki, S., Neela, S., Gichoya, J. W., & Purkayastha, S. (2019). Natural language processing of MIMIC-III clinical notes for identifying diagnosis and procedures with neural networks. *arXiv preprint arXiv:1912.12397*.
- Olawade, D. B., David-Olawade, A. C., Wada, O. Z., Asaolu, A. J., Adereni, T., & Ling, J. (2024). Artificial intelligence in healthcare delivery: Prospects and pitfalls. *Journal of Medicine, Surgery, and Public Health*, 100108.
- Osheroff, J. A., Teich, J., Levick, D., Saldana, L., Velasco, F., Sittig, D., Rogers, K., & Jenders, R. (2012). *Improving outcomes with clinical decision support: an implementer's guide*. Himss Publishing.
- Ostrom, Q. T., & Barnholtz-Sloan, J. S. (2011). Current state of our knowledge on brain tumor epidemiology. *Current neurology and neuroscience reports*, 11, 329-335.
- Özgiray, E., Çalışkan, K. E., Çağlı, M. S., Yurtseven, T., Ertan, Y., Akalın, T., Şanlı, A. U., Kamer, S., Anacak, Y., & Haydaroğlu, A. (2019). Ege Üniversitesi Hastanesi merkezi sinir sistemi tümörlerinin epidemiyolojik ve genel sağ kalım özellikleri. *Ege Tıp Dergisi*, 58, 10-18.
- Özkaraca, O., Bağrıaçık, O. İ., Gürüler, H., Khan, F., Hussain, J., Khan, J., & Laila, U. e. (2023). Multiple brain tumor classification with dense CNN architecture using brain MRI images. *Life*, 13(2), 349.

- Pacal, I. (2024a). Enhancing crop productivity and sustainability through disease identification in maize leaves: Exploiting a large dataset with an advanced vision transformer model. *Expert Systems with Applications*, 238, 122099.
- Pacal, I. (2024b). MaxCerVixT: A novel lightweight vision transformer-based Approach for precise cervical cancer detection. *Knowledge-Based Systems*, 289, 111482.
- Pacal, I. (2024c). A novel Swin transformer approach utilizing residual multi-layer perceptron for diagnosing brain tumors in MRI images. *International Journal of Machine Learning and Cybernetics*, 1-19.
- Pacal, I., Celik, O., Bayram, B., & Cunha, A. (2024). Enhancing EfficientNetv2 with global and efficient channel attention mechanisms for accurate MRI-Based brain tumor classification. *Cluster Computing*, 27(8), 11187-11212.
- Pacal, I., & Karaboga, D. (2021). A robust real-time deep learning based automatic polyp detection system. *Computers in Biology and Medicine*, 134, 104519.
- Pacal, I., & Kılıcarslan, S. (2023). Deep learning-based approaches for robust classification of cervical cancer. *Neural Computing and Applications*, 35(25), 18813-18828.
- Panch, T., Szolovits, P., & Atun, R. (2018). Artificial intelligence, machine learning and health systems. *Journal of global health*, 8(2).
- Paul, D., Sanap, G., Shenoy, S., Kalyane, D., & Kalia, K. (2021). Te ade RK. *Artificial intelligence in drug discovery and development*. *Drug Discov Today*, 26(1), 80-93.
- Pedada, K. R., Rao, B., Patro, K. K., Allam, J. P., Jamjoom, M. M., & Samee, N. A. (2023). A novel approach for brain tumour detection using deep learning based technique. *Biomedical Signal Processing and Control*, 82, 104549.
- Rahman, T., & Islam, M. S. (2023). MRI brain tumor detection and classification using parallel deep convolutional neural networks. *Measurement: Sensors*, 26, 100694.
- Rajkomar, A., Oren, E., Chen, K., Dai, A. M., Hajaj, N., Hardt, M., Liu, P. J., Liu, X., Marcus, J., & Sun, M. (2018). Scalable and accurate deep learning with electronic health records. *NPJ digital medicine*, 1(1), 18.
- Raza, M. M., Venkatesh, K. P., & Kvedar, J. C. (2024). Generative AI and large language models in health care: pathways to implementation. *NPJ digital medicine*, 7(1), 62.
- Rehman, A., Naz, S., Razzak, M. I., Akram, F., & Imran, M. (2020). A deep learning-based framework for automatic brain tumors classification using transfer learning. *Circuits, Systems, and Signal Processing*, 39(2), 757-775.
- Remzan, N., Tahiry, K., & Farchi, A. (2024). Advancing brain tumor classification accuracy through deep learning: harnessing radimagenet pre-trained convolutional neural networks, ensemble learning, and machine learning classifiers on MRI brain images. *Multimedia Tools and Applications*, 1-29.
- Richardson, J. P., Smith, C., Curtis, S., Watson, S., Zhu, X., Barry, B., & Sharp, R. R. (2021). Patient apprehensions about the use of artificial intelligence in health-care. *NPJ digital medicine*, 4(1), 140.

- Robert, S. (2024). Ethical Considerations in Health Informatics: Privacy, Consent and Data Ownership. *J Health Med Informat.*
- Roth, H. R., Lu, L., Liu, J., Yao, J., Seff, A., Cherry, K., Kim, L., & Summers, R. M. (2015). Improving computer-aided detection using convolutional neural networks and random view aggregation. *IEEE transactions on medical imaging*, 35(5), 1170-1181.
- Russell, S. J., & Norvig, P. (2016). *Artificial intelligence: a modern approach*. pearson.
- Sajjad, M., Khan, S., Muhammad, K., Wu, W., Ullah, A., & Baik, S. W. (2019). Multi-grade brain tumor classification using deep CNN with extensive data augmentation. *Journal of computational science*, 30, 174-182.
- Sarvamangala, D., & Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: a survey. *Evolutionary intelligence*, 15(1), 1-22.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Scott, P. J., Brown, A. W., Adedeji, T., Wyatt, J. C., Georgiou, A., Eisenstein, E. L., & Friedman, C. P. (2019). A review of measurement practice in studies of clinical decision support systems 1998–2017. *Journal of the American Medical Informatics Association*, 26(10), 1120-1128.
- Secinaro, S., Calandra, D., Secinaro, A., Muthurangu, V., & Biancone, P. (2021). The role of artificial intelligence in healthcare: a structured literature review. *BMC medical informatics and decision making*, 21, 1-23.
- Shaban-Nejad, A., Michalowski, M., & Buckeridge, D. L. (2018). Health intelligence: how artificial intelligence transforms population and personalized health. *NPJ digital medicine*, 1(1), 53.
- Shahid, N., Rappon, T., & Berta, W. (2019). Applications of artificial neural networks in health care organizational decision-making: A scoping review. *PloS one*, 14(2), e0212356.
- Sharif, M. I., Khan, M. A., Alhussein, M., Aurangzeb, K., & Raza, M. (2021). A decision support system for multimodal brain tumor classification using deep learning. *Complex & Intelligent Systems*, 1-14.
- Shen, D., Wu, G., & Suk, H.-I. (2017). Deep learning in medical image analysis. *Annual review of biomedical engineering*, 19(1), 221-248.
- Siegel, R. L., Giaquinto, A. N., & Jemal, A. (2024). Cancer statistics, 2024. *CA: a cancer journal for clinicians*, 74(1).
- Siegel, R. L., Miller, K. D., Wagle, N. S., & Jemal, A. (2023). Cancer statistics, 2023. *CA: a cancer journal for clinicians*, 73(1).
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Solares, J. R. A., Raimondi, F. E. D., Zhu, Y., Rahimian, F., Canoy, D., Tran, J., Gomes, A. C. P., Payberah, A. H., Zottoli, M., & Nazarzadeh, M. (2020). Deep learning

- for electronic health records: A comparative review of multiple deep neural architectures. *Journal of biomedical informatics*, 101, 103337.
- Sukumar, S. R., Natarajan, R., & Ferrell, R. K. (2015). Quality of Big Data in health care. *International journal of health care quality assurance*, 28(6), 621-634.
- Swati, Z. N. K., Zhao, Q., Kabir, M., Ali, F., Ali, Z., Ahmed, S., & Lu, J. (2019a). Brain tumor classification for MR images using transfer learning and fine-tuning. *Computerized medical imaging and graphics*, 75, 34-46.
- Swati, Z. N. K., Zhao, Q., Kabir, M., Ali, F., Ali, Z., Ahmed, S., & Lu, J. (2019b). Content-based brain tumor retrieval for MR images using transfer learning. *Ieee Access*, 7, 17809-17822.
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. *Proceedings of the AAAI conference on artificial intelligence*,
- Tabatabaei, S., Rezaee, K., & Zhu, M. (2023). Attention transformer mechanism and fusion-based deep learning architecture for MRI brain tumor classification system. *Biomedical Signal Processing and Control*, 86, 105119.
- Taherdoost, H., & Ghofrani, A. (2024). AI and the Evolution of Personalized Medicine in Pharmacogenomics. *Intelligent Pharmacy*.
- Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *International conference on machine learning*,
- Tan, M., & Le, Q. (2021). Efficientnetv2: Smaller models and faster training. *International conference on machine learning*,
- Tang, Y., Han, K., Guo, J., Xu, C., Xu, C., & Wang, Y. (2022). GhostNetv2: Enhance cheap operation with long-range attention. *Advances in Neural Information Processing Systems*, 35, 9969-9982.
- Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature medicine*, 25(1), 44-56.
- Touvron, H., Bojanowski, P., Caron, M., Cord, M., El-Nouby, A., Grave, E., Izacard, G., Joulin, A., Synnaeve, G., & Verbeek, J. (2022). Resmlp: Feedforward networks for image classification with data-efficient training. *IEEE transactions on pattern analysis and machine intelligence*, 45(4), 5314-5321.
- Touvron, H., Cord, M., & Jégou, H. (2022). Deit iii: Revenge of the vit. *European conference on computer vision*,
- Triwijoyo, B. K., & Adil, A. (2021). Analysis of medical image resizing using bicubic interpolation algorithm. *J. Ilmu Komput*, 14(2), 20-29.
- Tu, Z., Talebi, H., Zhang, H., Yang, F., Milanfar, P., Bovik, A., & Li, Y. (2022). Maxvit: Multi-axis vision transformer. *European conference on computer vision*,
- Tummala, S., Kadry, S., Bukhari, S. A. C., & Rauf, H. T. (2022). Classification of brain tumor from magnetic resonance imaging using vision transformers ensembling. *Current Oncology*, 29(10), 7498-7511.

- Ullah, W., Ilyas, S., Naveed, H., & Ali, S. (2025). An integrated approach to image quality: comparative analysis of bilinear and nearest neighbor interpolation. *Big Data and Computing Visions*, 5(1), 24-36.
- Ullah, Z., Usman, M., Jeon, M., & Gwak, J. (2022). Cascade multiscale residual attention cnns with adaptive roi for automatic brain tumor segmentation. *Information sciences*, 608, 1541-1556.
- Ullah, Z., Usman, M., Latif, S., & Gwak, J. (2023). Densely attention mechanism based network for COVID-19 detection in chest X-rays. *Scientific Reports*, 13(1), 261.
- Ullah, Z., Usman, M., Latif, S., Khan, A., & Gwak, J. (2023). SSMD-UNet: semi-supervised multi-task decoders network for diabetic retinopathy segmentation. *Scientific Reports*, 13(1), 9087.
- Umme Habiba, S., Debnath, T., Islam, M. K., Nahar, L., Shahadat Hossain, M., Basnin, N., & Andersson, K. (2023). Transfer Learning-Assisted DementiaNet: A Four Layer Deep CNN for Accurate Alzheimer's Disease Detection from MRI Images. International Conference on Brain Informatics,
- Unger, M., & Kather, J. N. (2024). Deep learning in cancer genomics and histopathology. *Genome medicine*, 16(1), 44.
- Upreti, M., Pandey, C., Bist, A. S., Rawat, B., & Hardini, M. (2021). Convolutional neural networks in medical image understanding. *Aptisi Transactions on Technopreneurship*, 3(2), 120-126.
- Vasu, P. K. A., Gabriel, J., Zhu, J., Tuzel, O., & Ranjan, A. (2023). FastViT: A fast hybrid vision transformer using structural reparameterization. Proceedings of the IEEE/CVF International Conference on Computer Vision,
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.
- Ventola, C. L. (2014). Social media and health care professionals: benefits, risks, and best practices. *Pharmacy and therapeutics*, 39(7), 491.
- Villanueva-Meyer, J. E., Mabray, M. C., & Cha, S. (2017). Current clinical brain tumor imaging. *Neurosurgery*, 81(3), 397-415.
- Wainberg, M., Merico, D., Delong, A., & Frey, B. J. (2018). Deep learning in biomedicine. *Nature biotechnology*, 36(9), 829-838.
- Wang, F., Jiang, M., Qian, C., Yang, S., Li, C., Zhang, H., Wang, X., & Tang, X. (2017). Residual attention network for image classification. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Wang, J., Zhu, H., Wang, S.-H., & Zhang, Y.-D. (2021). A review of deep learning on medical image analysis. *Mobile Networks and Applications*, 26(1), 351-380.
- Wang, Q., Wu, B., Zhu, P., Li, P., Zuo, W., & Hu, Q. (2020). ECA-Net: Efficient channel attention for deep convolutional neural networks. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition,

- Wang, Y., Gao, R., Wei, T., Johnston, L., Yuan, X., Zhang, Y., Yu, Z., & Initiative, A. s. D. N. (2024). Predicting long-term progression of Alzheimer's disease using a multimodal deep learning model incorporating interaction effects. *Journal of translational medicine*, 22(1), 265.
- Woo, S., Park, J., Lee, J.-Y., & Kweon, I. S. (2018). Cbam: Convolutional block attention module. Proceedings of the European conference on computer vision (ECCV),
- Wornow, M., Xu, Y., Thapa, R., Patel, B., Steinberg, E., Fleming, S., Pfeffer, M. A., Fries, J., & Shah, N. H. (2023). The shaky foundations of large language models and foundation models for electronic health records. *NPJ digital medicine*, 6(1), 135.
- Xu, K., Ba, J., Kiros, R., Cho, K., Courville, A., Salakhudinov, R., Zemel, R., & Bengio, Y. (2015). Show, attend and tell: Neural image caption generation with visual attention. International conference on machine learning,
- Yang, H.-L., & Hsiao, S.-L. (2009). Mechanisms of developing innovative IT-enabled services: A case study of Taiwanese healthcare service. *Technovation*, 29(5), 327-337.
- Younis, A., Qiang, L., Nyatega, C. O., Adamu, M. J., & Kawuwa, H. B. (2022). Brain tumor analysis using deep learning and VGG-16 ensembling learning approaches. *Applied Sciences*, 12(14), 7282.
- Yu, W., Si, C., Zhou, P., Luo, M., Zhou, Y., Feng, J., Yan, S., & Wang, X. (2023). Meta-former baselines for vision. *IEEE transactions on pattern analysis and machine intelligence*.
- Yu, W., Zhou, P., Yan, S., & Wang, X. (2024). Inceptionnext: When inception meets convnext. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition,
- Zador, A. M. (2019). A critique of pure learning and what artificial neural networks can learn from animal brains. *Nature communications*, 10(1), 3770.
- Zebari, N. A., Mohammed, C. N., Zebari, D. A., Mohammed, M. A., Zeebaree, D. Q., Marhoon, H. A., Abdulkareem, K. H., Kadry, S., Viriyasitavat, W., & Nedoma, J. (2024). A deep learning fusion model for accurate classification of brain tumours in Magnetic Resonance images. *CAAI Transactions on Intelligence Technology*.
- Zhang, J., Tan, X., Chen, W., Du, G., Fu, Q., Zhang, H., & Jiang, H. (2023). EFF_D_SVM: a robust multi-type brain tumor classification system. *Frontiers in Neuroscience*, 17, 1269100.
- Zulfiqar, F., Bajwa, U. I., & Mehmood, Y. (2023). Multi-class classification of brain tumor types from MR images using EfficientNets. *Biomedical Signal Processing and Control*, 84, 104777.

Sağlık hizmetlerinde yapay zekâ uygulamaları, yalnızca teknolojik bir yenilik değil; tanı, tedavi ve klinik karar verme süreçlerini yeniden şekillendiren önemli bir dönüşümün parçasıdır. Özellikle tıbbi görüntüleme alanında geliştirilen derin öğrenme tabanlı sistemler, sağlık profesyonellerine daha hızlı, daha doğru ve daha güvenilir kararlar alma konusunda güçlü destek sunmaktadır.

Bu kitap, sağlık bilişimi, yapay zekâ ve klinik karar destek sistemlerini teorik temelleriyle ele almakta; ardından manyetik rezonans (MR) görüntülerinden beyin tümörlerinin otomatik sınıflandırılmasına yönelik özgün bir derin öğrenme modeli üzerinden bu teknolojilerin sağlık hizmetlerine nasıl uygulanabileceğini ayrıntılı biçimde ortaya koymaktadır.

Eserde; sağlık bilişiminin gelişimi, büyük veri, elektronik sağlık kayıtları, yapay zekâ ve derin öğrenme yaklaşımları, klinik karar destek sistemleri ile güncel literatür kapsamlı şekilde incelenmekte; geliştirilen hibrit modelin performansı bilimsel bulgular ışığında değerlendirilmektedir. Bunun yanında, açıklanabilir yapay zekâ yaklaşımları ve klinik uygulanabilirlik boyutları da ele alınarak araştırmacılar ve uygulayıcılar için bütüncül bir bakış açısı sunulmaktadır.

Akademisyenler, lisansüstü öğrenciler, sağlık yöneticileri, sağlık bilişimi araştırmacıları, bilgisayar mühendisleri ve yapay zekâ alanında çalışan tüm araştırmacılar için hazırlanmış bu eser; sağlık hizmetlerinde dijital dönüşümün geleceğini anlamak ve klinik yapay zekâ uygulamalarını bilimsel temelleriyle değerlendirmek isteyen okurlar için önemli bir başvuru kaynağıdır.