


Kanser Teşhisinde Görüntü Tabanlı Makine Öğrenmesi ve Derin Öğrenme Uygulamaları



Düvar Kitapevi

Dr. Öğr. Üyesi Muhammet ÇAKMAK





Kanser Teşhisinde Görüntü Tabanlı Makine Öğrenmesi ve Derin Öğrenme Uygulamaları
Muhammet ÇAKMAK

Genel Yayın Yönetmeni: Berkan Balpetek

Kapak ve Sayfa Tasarımı: Duvar Design

Baskı : Aralık 2024

Yayıncı Sertifika No: 49837

ISBN: 978-625-5530-28-8

© Duvar Yayınları

853 Sokak No:13 P.10 Kemeraltı-Konak/Izmir/ Turkey

Telefon: 0 232 484 88 68

www.duvar yayinlari.com

duvarkitabevi@gmail.com

Önsöz

Kanser, günümüzün en ciddi sağlık sorunlarından biri olarak dünya genelinde milyonlarca insanı etkilemektedir. Erken teşhis ve doğru sınıflandırma, kanserle mücadelede hayati bir öneme sahiptir. Teknolojideki hızlı ilerlemeler sayesinde, bilgisayarla görü ve yapay zekâ tabanlı makine öğrenmesi ile derin öğrenme modelleri, kanser teşhisinde yeni ufuklar açmaktadır. Bu kitap, beyin tümörü, meme kanseri, akciğer kanseri, deri kanseri ve kan kanseri gibi yaygın kanser türlerinin teşhisinde kullanılan makine öğrenmesi ve derin öğrenme yöntemlerini kapsamlı bir şekilde ele almaktadır.

Kitabımızda, farklı kanser türlerine yönelik bilgisayarla görü ve yapay zekâ uygulamaları detaylı bir şekilde açıklanmış, her bir kanser türü için en etkili modeller sunulmuştur. Bu çalışmada, makine öğrenmesi ve derin öğrenme modellerinin performans değerlendirmeleri, klinik uygulamalardaki faydaları ve gelecekteki potansiyelleri üzerinde durulmuştur. Ayrıca, kanser teşhisinde karşılaşılan etik ve teknik sorunlara da yer verilerek okuyuculara geniş bir perspektif sunulması amaçlanmıştır.

Bu kitap, kanser teşhisinde teknoloji tabanlı çözümlere ilgi duyan araştırmacılar, mühendisler, doktorlar ve öğrenciler için bir kaynak niteliğindedir. Bilimsel veriye dayalı modellerin geliştirilmesi ve sağlık sektöründe uygulanabilir hale getirilmesi, insan hayatını kurtarmak adına büyük bir adımdır. Bu çalışmanın, kanserle mücadelede hem akademik hem de klinik çalışmalara katkıda bulunmasını diliyoruz.

Teşekkür

Bu kitabın hazırlanmasında katkı sunan herkese en içten teşekkürlerimi sunarım.

Dr. Öğr. Üyesi Muhammet Çakmak

17.12.2024

İçindekiler Tablosu

İçindekiler	4
Giriş	6
1. Kanser Teşhisinde Yapay Zekanın Rolü	6
2. Bilgisayarla Görme ve Makine Öğrenmesi ve Derin Öğrenmenin Temelleri	8
2.1 Makine Öğrenmesi	8
2.2 Makine Öğrenmesi Türleri	8
2.3 Denetimli Öğrenme (Supervised Learning)	9
2.4 Denetimsiz Öğrenme (Unsupervised Learning)	9
2.5 Pekiştirmeli Öğrenme (Reinforcement Learning)	9
2.6 Sınıflandırma (Classification)	9
2.7 Regresyon (Regression)	10
2.8 Kümeleme (Clustering)	10
2.9 Boyut Azaltma (Dimensionality Reduction)	10
2.10 Derin Öğrenme ve Sinir Ağlarının Yapısı	10
2.11 Yapay Sinir Ağları	10
2.12 Evrimsel Sinir Ağları (CNN)	11
2.13 Transfer Öğrenme	12
3. Tıbbi Görüntüleme ve Veri İşleme Teknikleri	12
3.1 Veri Ön İşleme	13
3.2 Veri Etiketleme	13
3.3 Makine Öğrenmesi ve Derin Öğrenmenin Kanser Teşhisindeki Rolü	13
3.4 Kanser Teşhisinde Tıbbi Görüntüleme Teknikleri	14
3.5 MRI, CT, PET ve Ultrason Görüntüleme Yöntemleri	14
3.6 Manyetik Rezonans Görüntüleme (MRI)	14
3.7 Bilgisayarlı Tomografi (CT)	15
3.8 Pozitron Emisyon Tomografisi (PET)	15
3.9 Ultrason	16
4. Yapay Zeka ile Kanser Teşhisinde Etik ve Veri Güvenliği	17
5. UYGULAMA ÇALIŞMALARI	19
5.1 Beyin Tümörü Teşhisi Uygulamaları	19
5.2 Beyin Tümörü Teşhisi Uygulamaları	21
5.3 Akciğer Kanseri Teşhisi Uygulaması	30
5.4 Meme Kanserinin Teşhisi için Uygulama	36

5.5	Deri Kanseri Teşhisi Uygulamaları	42
5.6	Kan Kanseri Teşhisi ve Uygulamaları.....	50
5.7	KAYNAKÇA.....	58

Giriş

Dünya Sağlık Örgütü'ne (WHO) göre, her yıl milyonlarca kişi kansere yakalanmakta ve bu hastalıkla mücadele etmektedir [1]. Kanserin erken teşhisi, yaşam süresini uzatmanın yanı sıra tedavi sürecinin etkinliğini de artırmaktadır. Geleneksel kanser teşhis yöntemleri, genellikle zaman alıcı, maliyetli ve insan faktörüne dayalı olarak hata payı yüksek olabilmektedir. Bu noktada, bilgisayarla görü ve yapay zekâ gibi teknolojiler, kanser teşhisinde önemli bir devrim yaratmıştır.

Bilgisayarla görü, bilgisayarların görsel verileri analiz ederek yorumlamasını sağlayan bir disiplindir. Yapay zekâ (AI) ise, insan zekâsını taklit eden algoritmalar ve modeller aracılığıyla problem çözme ve karar verme süreçlerini otomatikleştiren bir teknolojidir. Bilgisayarla görü ve yapay zekâ bir araya geldiğinde, tıbbi görüntülerin analiz edilmesinde oldukça başarılı sonuçlar elde edilebilmektedir.

Bu süreçte en yaygın kullanılan yöntemler şunlardır:

- Makine Öğrenmesi (ML): Verilerden öğrenerek karar veren algoritmaların kullanıldığı yöntemdir.
- Derin Öğrenme (DL): Çok katmanlı yapay sinir ağları kullanarak karmaşık verilerden anlam çıkaran yöntemdir. Derin öğrenme, özellikle görüntü sınıflandırma, segmentasyon ve nesne tespiti gibi konularda başarılı sonuçlar elde etmektedir.
- Transfer Öğrenme: Önceden eğitilmiş derin öğrenme modellerinin yeni veri setleri üzerinde yeniden eğitilmesidir. Bu yöntem, küçük veri setleriyle yüksek performans sağlar.

Bilgisayarla görü teknikleri ve yapay zekâ algoritmaları, tıbbi görüntüleri analiz ederek kanserli ve sağlıklı dokular arasındaki ince farkları hızlı ve doğru bir şekilde tespit edebilir [2]. Bu teknolojilerin kullanımı, özellikle tıbbi görüntüleme yöntemleri (MR, BT, PET, mamografi vb.) ile birleştirildiğinde, daha hızlı ve kesin sonuçlar elde edilmesini sağlamaktadır. Bu kitapta, kanser teşhisinde kullanılan en güncel bilgisayarla görü ve yapay zekâ modelleri detaylı olarak ele alınacak ve farklı kanser türlerine yönelik çözümler incelenecektir.

1. Kanser Teşhisinde Yapay Zekanın Rolü

Yapay zeka, kanser teşhisinde devrim niteliğinde değişiklikler getirmiştir. Geleneksel teşhis yöntemleri, genellikle uzman bir doktorun manuel olarak görüntüleri incelemesine dayanırken, yapay zeka algoritmaları bu süreci otomatikleştirir ve hızlandırır [3]. Bilgisayarla görme ve derin öğrenme, tıbbi görüntülerin büyük hacmini kısa sürede işleyerek doğru sonuçlar sunabilir. Bu teknolojiler, insan hatalarını azaltarak, doktorların gözden kaçırabileceği küçük tümörleri ve erken evre kanser belirtilerini tespit eder.

Yapay zekanın kanser teşhisinde başlıca faydaları şunlardır:

- Doğruluk: Derin öğrenme modelleri, tıbbi görüntülerdeki ince detayları insan gözünden daha doğru bir şekilde analiz edebilir. Bu, erken evrelerde kanserli hücrelerin veya tümörlerin tespit edilmesine olanak tanır.
- Hız: Yapay zeka algoritmaları, büyük miktarda görüntü verisini hızlı bir şekilde işleyebilir. Bu da, özellikle acil teşhis gereken vakalarda hayati öneme sahiptir.
- Sürekli Öğrenme: Derin öğrenme modelleri, yeni verilerle sürekli olarak öğrenir ve kendilerini geliştirir. Bu sayede, teşhis süreçlerinde zamanla daha yüksek doğruluk oranlarına ulaşırlar.

Yapay zeka ayrıca, görüntüleme teknikleri (MRI, CT, PET vb.) arasındaki farklılıkları birleştirerek çoklu görüntüleme yöntemlerini entegre bir şekilde kullanabilir [4]. Bu da doktorların kanserli dokuların daha net bir haritasını çıkararak daha iyi kararlar vermesini sağlar.

Tıbbi görüntüleme, kanser teşhisinin temel taşlarından biridir. Görüntüleme teknikleri, kanserin erken evrede teşhis edilmesi ve tedavi sürecinin planlanması için kritik bilgiler sağlar. Geleneksel görüntüleme yöntemleri (röntgen, CT taraması, MRI ve ultrason), genellikle manuel analizlere dayanırken, günümüzde yapay zeka ve bilgisayarla görme teknolojileri, bu görüntülerin otomatik olarak analiz edilmesini sağlamaktadır.

MRI (Manyetik Rezonans Görüntüleme), beyin ve yumuşak dokulardaki tümörlerin tespiti için en yaygın kullanılan yöntemlerden biridir. CT taramaları (Bilgisayarlı Tomografi), vücut içindeki kemik ve organların detaylı kesit görüntülerini sağlar. PET taramaları (Pozitron Emisyon Tomografisi), vücuttaki kanser hücrelerinin metabolik aktivitesini görüntüleyerek kanserli hücrelerin yayılımını takip eder. Yapay zeka, bu görüntüleme teknikleriyle elde edilen verileri analiz ederek, kanserli dokuları daha hızlı ve doğru bir şekilde teşhis eder [5].

Görüntüleme tekniklerinin evrimiyle birlikte, bu verilerin işlenmesi ve analiz edilmesi için kullanılan yapay zeka yöntemleri de gelişmiştir. Bilgisayarla görme ve derin öğrenme, görüntüleme verilerinden daha fazla bilgi çıkarılmasını sağlayarak, hem teşhis sürecini iyileştirir hem de kanser tedavisinde kişiselleştirilmiş yaklaşımlar sunar.

Bu kitap, kanser teşhisinde makinesi ve derin öğrenme uygulamalarını kapsamlı bir şekilde ele almayı amaçlamaktadır. Kitap boyunca, tıbbi görüntüleme verilerinin nasıl işlenip analiz edileceği, yapay zeka modellerinin kanser teşhisinde nasıl kullanılacağı ve bu teknolojilerin sağlık hizmetlerine nasıl entegre edilebileceği detaylı olarak ele alınacaktır. Aynı zamanda, bu teknolojilerin etik ve veri güvenliği boyutları da tartışılacaktır.

Başlıca hedefleri şunlardır:

- Kanser teşhisinde kullanılan başlıca tıbbi görüntüleme tekniklerinin (MRI, CT, PET vb.) analizinde yapay zeka ve derin öğrenme modellerinin nasıl uygulandığını açıklamak.
- Bilgisayarla görme ve derin öğrenme teknolojilerinin kanserli hücrelerin tespiti, tümör sınırlarının belirlenmesi ve hastalık sınıflandırması gibi alanlardaki faydalarını göstermek.
- Yapay zeka destekli teşhis sistemlerinin klinik uygulamalarda nasıl kullanıldığını ve gelecekteki potansiyelini incelemek.
- Derin öğrenme algoritmalarının eğitimi ve tıbbi verilerin işlenmesi sırasında karşılaşılan veri gizliliği ve etik sorunları tartışmak.

Kitap, hem yapay zeka, makine öğrenmesi ve derin öğrenme teknolojilerine ilgi duyan araştırmacılar için bir rehber niteliğinde olacak hem de tıbbi profesyonellere bu teknolojilerin klinik uygulamadaki faydalarını göstermeyi hedefleyecektir. Tıbbi görüntüleme ile yapay zeka teknolojilerinin kesişimindeki bu yenilikler, kanser teşhisinde geleceğin önemli bir bileşeni olarak görülmektedir.

2. Bilgisayarla Görme ve Makine Öğrenmesi ve Derin Öğrenmenin Temelleri

Bilgisayarla görme ve derin öğrenme, yapay zeka alanında hızla gelişen ve özellikle tıbbi görüntüleme devrim yaratan iki ana teknoloji olarak karşımıza çıkar. Bilgisayarla görme, makinelerin görüntüleri algılamasını ve analiz etmesini sağlarken, derin öğrenme çok katmanlı yapay sinir ağları aracılığıyla büyük veri kümelerinden anlamlı bilgiler çıkarır. Bu iki teknolojinin birleşimi, kanser teşhis süreçlerini büyük ölçüde iyileştirerek, sağlık hizmetlerinin doğruluğunu ve hızını artırmaktadır [6].

Bilgisayarla görme (computer vision), makinelerin dijital görüntüleri ve videoları algılayarak anlamlandırmasını sağlayan bir yapay zeka dalıdır. Bu teknoloji, insanların görme yetisine benzer şekilde, makinelerin bir görüntüde ne olduğunu anlamalarına olanak tanır. Görüntü tanıma, nesne tespiti, segmentasyon ve hareket analizi gibi çeşitli görevlerde kullanılır.

Tıbbi alanda bilgisayarla görme, tıbbi görüntülerin otomatik olarak analiz edilmesi, tümörlerin tespiti, organ sınırlarının belirlenmesi ve anormal dokuların tanımlanması için kullanılır. Örneğin, kanser teşhisinde bilgisayarla görme, MRI ve CT taramaları gibi görüntüleri analiz ederek kanserli dokuları tespit edebilir [7]. Temel olarak, bilgisayarla görme sistemleri, bir görüntüdeki piksel desenlerini inceleyerek belirli özellikleri tanımlar ve bu özelliklere dayanarak teşhis veya sınıflandırma yapar.

Bilgisayarla görme sistemleri genellikle birkaç temel aşamadan oluşur:

- **Görüntü Edinimi:** İlk adım, görüntüleme cihazlarından (MRI, CT vb.) gelen görüntülerin dijital formatta alınmasıdır.
- **Özellik Çıkarma (Feature Extraction):** Görüntüdeki belirli yapısal özelliklerin (örneğin, kenarlar, dokular, bölgeler) tanımlanması ve çıkarılmasıdır.
- **Segmentasyon:** Görüntünün belirli bölgelere (örneğin, tümör, sağlıklı doku) ayrılmasıdır.
- **Sınıflandırma:** Bilgisayarla görme algoritmaları, elde edilen özelliklere dayanarak görüntüdeki yapıları sınıflandırır. Örneğin, bir tümörün kanserli veya kanserli olmayan bir doku olup olmadığını belirler.

Bu adımlar, tıbbi görüntülerin anlamlandırılmasında ve doğru teşhis süreçlerinde kritik rol oynar.

2.1 Makine Öğrenmesi

Makine Öğrenmesi (ML), bilgisayarların açıkça programlanmadan verilerden öğrenmesini sağlayan bir yapay zeka alt alanıdır. Geleneksel programlamada, bilgisayara bir problemi çözmesi için belirli kurallar verilirken, makine öğrenmesinde algoritmalar büyük veri setlerini analiz ederek veriler arasındaki örüntüleri ve ilişkileri öğrenir. Bu öğrenme süreci sonucunda sistem, yeni verilerle karşılaştığında tahmin yapabilme, sınıflandırma gerçekleştirme ve karar verme yeteneğine sahip olur. Makine öğrenmesi, günümüzde sağlık, finans, eğitim, sanayi, tarım, otomotiv ve birçok farklı alanda yaygın olarak kullanılmaktadır [8], [9]. Özellikle kanser teşhisi, hastalık tespiti ve sınıflandırma gibi sağlık alanındaki uygulamalar, makine öğrenmesinin önemini bir kez daha ortaya koymaktadır.

2.2 Makine Öğrenmesi Türleri

Makine öğrenmesi, öğrenme türüne göre üç ana grupta incelenir:

2.3 Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenmede, modelin eğitimi için etiketli veri setleri kullanılır. Giriş (input) verileri ile hedef çıktılar (output) arasındaki ilişkiyi öğrenen model, yeni verilerle karşılaştığında tahmin yapar [10].

- Kullanım Alanları: Sınıflandırma (Classification) ve Regresyon (Regression) problemleri.
- Örnek Algoritmalar:
 - Destek Vektör Makineleri (SVM): Verileri doğrusal veya doğrusal olmayan bir ayırıcı kullanarak sınıflandırır.
 - Lojistik Regresyon: Sınıflandırma problemlerinde olasılık tahmini yapar.
 - Karar Ağaçları (Decision Trees): Veriyi dallara ayırarak karar verme süreci oluşturur.
 - Random Forest (Rastgele Orman): Birden fazla karar ağacının birleşiminden oluşan topluluk öğrenme yöntemidir.
 - XGBoost: Güçlü bir topluluk öğrenme yöntemi olan gradient boosting algoritmasının optimize edilmiş versiyonudur.

2.4 Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenmede etiketsiz veri setleri kullanılır. Algoritma, veriler arasındaki gizli ilişkileri keşfederek verileri gruplandırır veya örüntüleri tespit eder [11].

- Kullanım Alanları: Kümeleme (Clustering) ve Boyut Azaltma (Dimensionality Reduction).
- Örnek Algoritmalar:
 - K-Means Kümeleme: Verileri belirli sayıda kümeye ayırır.
 - Principal Component Analysis (PCA): Boyut azaltma yöntemidir.
 - Autoencoders: Girdi verilerini sıkıştırarak düşük boyutlu bir temsil oluşturur.

2.5 Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme, bir ajanın (öğrenen sistem) bir ortamda hareket ederek belirli hedeflere ulaşmaya çalıştığı öğrenme türüdür. Ajan, ödül (reward) ve ceza (penalty) sistemiyle en uygun stratejiyi öğrenir [12].

- Kullanım Alanları: Otonom araçlar, robotik, oyun geliştirme.
- Örnek Algoritmalar: Q-Learning, Deep Q Networks (DQN).

2.6 Sınıflandırma (Classification)

Sınıflandırma, verilerin belirli kategorilere ayrılmasını sağlayan bir makine öğrenmesi yöntemidir. Girdi verileri analiz edilerek, her veri bir sınıfa atanır.

Örnek Modeller:

- Destek Vektör Makineleri (SVM)
- Karar Ağaçları (Decision Trees)
- Random Forest
- K-En Yakın Komşu (KNN)

2.7 Regresyon (Regression)

Regresyon, sayısal bir çıktıyı tahmin etmek için kullanılır. Bağımsız değişkenlerle bağımlı değişken arasındaki ilişkileri modelleyerek gelecekteki değerleri tahmin eder [13].

Örnek Modeller:

- Lineer Regresyon
- Lojistik Regresyon
- Ridge ve Lasso Regresyon

2.8 Kümeleme (Clustering)

Kümeleme, verileri benzer özelliklere sahip gruplar halinde toplamak için kullanılır [14].

Örnek Modeller:

- K-Means
- DBSCAN
- Gaussian Mixture Model (GMM)

2.9 Boyut Azaltma (Dimensionality Reduction)

Yüksek boyutlu veri setlerinin daha az boyuta indirgenerek analiz edilmesini sağlar .

Örnek Modeller:


- Principal Component Analysis (PCA)
- Autoencoders

2.10 Derin Öğrenme ve Sinir Ağlarının Yapısı

Derin öğrenme (deep learning), yapay sinir ağlarının çok katmanlı yapılarından oluşan bir makine öğrenmesi dalıdır. Derin öğrenme modelleri, büyük miktarda veriyi işleyerek bu verilerden öğrenme ve genelleme yapabilme yeteneğine sahiptir [15], [16]. Derin öğrenme, özellikle büyük ve karmaşık veri setlerinde (örneğin tıbbi görüntülerde) son derece etkilidir.

2.11 Yapay Sinir Ağları

Yapay sinir ağları (artificial neural networks), biyolojik sinir sistemlerinden esinlenerek geliştirilen bir yapıdır. Bu ağlar, verileri işlemek ve öğrenmek için kullanılan bir dizi yapay nöron katmanından oluşur [16], [17]. Sinir ağlarının temeli, girdi katmanı, gizli katmanlar ve çıktı katmanından oluşur:



Şekil 1. Yapay Sinir Ağ Modeli

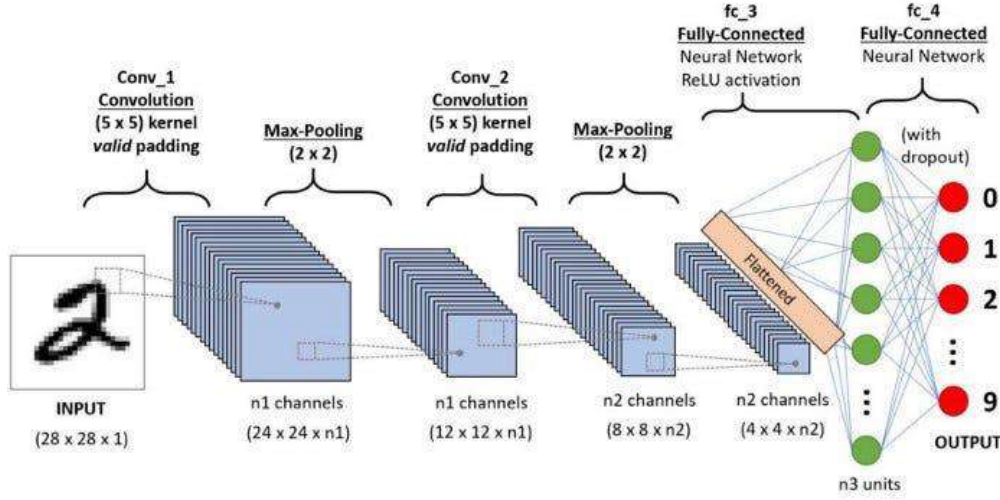
- Girdi Katmanı: Tıbbi görüntülerin dijital formatta girdi olarak verildiği katmandır.
- Gizli Katmanlar: Girdi verilerinin işlendiği, örüntülerin ve özelliklerin öğrenildiği ara katmanlardır. Bu katmanlar derin öğrenme modellerinin temelini oluşturur.
- Çıktı Katmanı: Modelin sonunda elde edilen çıktıyı (örneğin, kanserli veya kanserli olmayan doku) üreten katmandır.

2.12 Evrişimsel Sinir Ağları (CNN)

Evrişimsel Sinir Ağları (Convolutional Neural Networks - CNN), özellikle görüntü tanıma ve sınıflandırma görevlerinde kullanılan bir yapay sinir ağı türüdür. CNN'ler, tıbbi görüntülerdeki ince ayrıntıları öğrenme ve bu ayrıntılardan anlamlı sonuçlar çıkarma konusunda son derece başarılıdır [18], [19]. CNN'ler genellikle üç ana bileşenden oluşur:

- Evrişim Katmanı (Convolutional Layer): Görüntüdeki yerel özelliklerin (örneğin, kenar, doku, şekil) çıkarıldığı katmandır. Evrişim işlemi, görüntü üzerinde bir filtre matrisi (kernel) dolaştırarak görüntünün belirli özelliklerini öne çıkarır.
- Havuzlama Katmanı (Pooling Layer): Görüntünün boyutunu küçülterek işlem süresini hızlandırır ve önemli özelliklerin korunmasını sağlar.

- Tam Bağlantılı Katman (Fully Connected Layer): Çıkarılan özellikleri sınıflandırmak için kullanılan son katmandır.



Şekil 2. CNN Ağ Modeli

Tıbbi görüntüleme analizlerinde CNN'ler, kanserli dokuların tespiti, tümör sınırlarının belirlenmesi ve anormal dokuların sınıflandırılması için yaygın olarak kullanılır [20]. Derin öğrenme modelleri, veriler üzerinde eğitildikçe, daha doğru ve hassas teşhisler yapma kapasitesine ulaşır.

2.13 Transfer Öğrenme

Transfer öğrenme, bir modelin önceden öğrenilmiş bilgilerini farklı ancak benzer bir problem için yeniden kullanılmasına dayanan bir makine öğrenmesi ve derin öğrenme tekniğidir. Geleneksel öğrenme yöntemlerinde, bir model sıfırdan eğitilirken, transfer öğrenmede bir modelin farklı bir veri kümesinde eğitilmiş olan ağırlıkları başka bir veri kümesine adapte edilir. Bu yöntem, özellikle veri yetersizliği ve hesaplama maliyeti sorunlarını çözmek için güçlü bir alternatiftir. Transfer öğrenme, özellikle derin öğrenme alanında yaygın olarak kullanılmaktadır. Büyük veri kümelerinde eğitilmiş olan evrensel modeller, küçük ve özel veri kümelerinde sonlandırılarak (fine-tuning) yeniden eğitilir ve uyarlanır [20].

Transfer öğrenmede süreç şu adımlarla işler:

1. Kaynak Modelin Seçilmesi: Genellikle büyük veri kümeleri üzerinde eğitilmiş önceden tanımlı bir model seçilir (örneğin, ImageNet üzerinde eğitilmiş ResNet, VGG, EfficientNet gibi modeller).
2. Önceden Eğitilmiş Ağırlıkların Yüklenmesi: Seçilen modelin parametreleri ve ağırlıkları kullanılır. Modelin ilk katmanları (temel özellik çıkarma kısmı) korunur.
3. Son Katmanların Güncellenmesi: Hedef problem için modelin son katmanları yeniden eğitilir. Bu katmanlar, hedef veri kümesine özgü çıktılar üretmek için yapılandırılır.
4. Modelin İncelenmesi (Fine-Tuning): Model, hedef veri kümesinde yeniden eğitilerek performansı optimize edilir.

3. Tıbbi Görüntüleme ve Veri İşleme Teknikleri

Tıbbi görüntüleme, hastalıkların teşhis edilmesi, tedavi süreçlerinin planlanması ve hastalıkların takibi için kullanılan önemli bir araçtır. Teknolojinin ilerlemesiyle birlikte, tıbbi görüntüleme teknikleri, daha

yüksek çözünürlükte ve daha hızlı bir şekilde görüntüler elde etmeyi mümkün kılmıştır. Bu süreçte elde edilen verilerin doğru bir şekilde işlenmesi, analiz edilmesi ve yorumlanması, sağlık sektöründe büyük önem taşımaktadır.

3.1 Veri Ön İşleme

Tıbbi görüntülerin derin öğrenme algoritmaları tarafından doğru şekilde işlenebilmesi için öncelikle veri ön işleme aşamasından geçmesi gerekmektedir. Bu adımlar şunları içerir:

- Görüntü Normalizasyonu: Farklı hastaneler veya cihazlar tarafından elde edilen görüntülerin çözünürlüğü, kontrastı veya parlaklığı farklı olabilir. Normalizasyon, bu farklılıkları ortadan kaldırarak verilerin tutarlı olmasını sağlar.
- Veri Zenginleştirme (Augmentation): Eğitim veri setini artırmak amacıyla, görüntülerin döndürülmesi, kaydırılması veya yakınlaştırılması gibi tekniklerle veri setinin çeşitlendirilmesidir.
- Gürültü Giderme: Görüntülerdeki parazitleri (noise) kaldırarak daha net ve temiz görüntüler elde edilmesi sağlanır.

3.2 Veri Etiketleme

Derin öğrenme modelleri, denetimli öğrenme (supervised learning) sürecinde, etiketlenmiş veri setleri üzerinde eğitilir. Tıbbi görüntülerde, örneğin bir tümörün hangi bölgede olduğu veya bir hücrenin kanserli olup olmadığı bilgileri veri etiketi olarak kullanılır. Bu etiketler, modelin doğru sonuçlar üretebilmesi için kritik öneme sahiptir. Etiketleme süreci genellikle uzman doktorlar tarafından yapılır [21].

3.3 Makine Öğrenmesi ve Derin Öğrenmenin Kanser Teşhisindeki Rolü

Makine öğrenmesi ve derin öğrenme teknolojileri, kanser teşhisi ve tıbbi görüntüleme alanında önemli yenilikler sunmuştur. Makine öğrenmesi algoritmaları, yapılandırılmış veri kümelerini analiz ederek kanserli ve sağlıklı dokular arasındaki farkları belirleyebilirken, derin öğrenme yöntemleri özellikle görüntü verilerinde olağanüstü başarı göstermektedir. Özellikle Konvolüsyonel Sinir Ağları (CNN) gibi derin öğrenme modelleri, tıbbi görüntülerdeki en küçük detayları bile öğrenerek kanserli dokuların yüksek doğrulukla tespit edilmesini sağlar. Kanserlin erken teşhisi, tedavi başarısını ve hasta yaşam süresini önemli ölçüde artırır. Makine ve derin öğrenme algoritmaları, kanserli hücreleri ve tümörleri henüz erken evrelerinde tespit ederek doktorların zamanında ve doğru müdahalede bulunmasına yardımcı olur. Geleneksel yöntemlerle yapılan teşhislerde gözden kaçabilecek detaylar, yapay zeka destekli modeller sayesinde hassas bir şekilde analiz edilebilmektedir. Bu teknolojiler, tıbbi görüntülerin her pikselini inceleyerek sağlıklı ve kanserli dokular arasındaki farkları ortaya koyar.

Makine öğrenmesi ve derin öğrenme uygulamaları yalnızca teşhis hızını artırmakla kalmaz, aynı zamanda hastaya özel tedavi planlarının oluşturulmasına da katkıda bulunur. Hastaların genetik verileri, tıbbi geçmişi ve klinik bilgileri analiz edilerek en uygun tedavi yöntemleri önerilebilir. Bu da sağlık hizmetlerinde kişiselleştirilmiş tıp uygulamalarının önünü açar. Sonuç olarak, makine öğrenmesi ve derin öğrenme teknolojileri, kanser teşhisinde insan hatalarını en aza indirirken, teşhis süreçlerini hızlandırır ve doğruluğu artırır.

3.4 Kanser Teşhisinde Tıbbi Görüntüleme Teknikleri

Tıbbi görüntüleme, kanser teşhisinin temel taşlarından biridir. Erken teşhis, tedavi planlaması ve hastalığın izlenmesi, doğru ve zamanında görüntüleme teknikleriyle mümkün olmaktadır. Kanser teşhisinde kullanılan tıbbi görüntüleme yöntemleri, organlardaki yapısal değişiklikleri veya hücresel anormallikleri gözlemlemeye olanak tanır. Bu görüntülerin bilgisayarla görme ve derin öğrenme algoritmaları ile analiz edilmesi, kanserli dokuların daha hızlı ve doğru bir şekilde tespit edilmesini sağlar. Bu bölümde, kanser teşhisinde en yaygın kullanılan tıbbi görüntüleme yöntemleri, bu yöntemlerin nasıl çalıştığı ve yapay zeka algoritmalarının bu süreçlere nasıl entegre edildiği detaylı bir şekilde ele alınacaktır.

3.5 MRI, CT, PET ve Ultrason Görüntüleme Yöntemleri

Kanser teşhisinde kullanılan en önemli tıbbi görüntüleme teknikleri Manyetik Rezonans Görüntüleme (MRI), Bilgisayarlı Tomografi (CT), Pozitron Emisyon Tomografisi (PET) ve Ultrason olarak sıralanabilir. Her bir yöntem, vücudun farklı bölgelerindeki kanserli hücreleri tespit etmek için farklı teknolojilere dayanır. Yapay zeka bu yöntemlerle elde edilen görüntüleri analiz ederek kanser teşhis sürecine hız ve doğruluk kazandırır.

3.6 Manyetik Rezonans Görüntüleme (MRI)

Manyetik Rezonans Görüntüleme (MRI), vücut dokularının ayrıntılı görüntülerini elde etmek için güçlü manyetik alanlar ve radyo dalgaları kullanır. Özellikle beyin, omurilik, yumuşak doku ve iç organlardaki tümörlerin tespitinde yaygın olarak kullanılır. MRI görüntülerinde, tümörlerin boyutları, konumları ve dokularla olan ilişkileri net bir şekilde gözlemlenebilir. Bilgisayarla görme ve derin öğrenme algoritmaları, MRI görüntülerini analiz ederek kanserli dokuları sağlıklı dokulardan ayırt edebilir. Bu süreç, doktorlara teşhis sırasında büyük bir destek sağlar ve zaman kaybını önler. Şekil 1’de örnek MRI görüntüsü verilmiştir.




Şekil 1. Örnek MRI görüntüsü

3.7 Bilgisayarlı Tomografi (CT)

Bilgisayarlı Tomografi (CT), X-ışınları kullanarak vücudun kesitsel görüntülerini elde eden bir görüntüleme tekniğidir. CT, vücut içindeki organların ve dokuların detaylı görüntülerini sağlar ve akciğer kanseri, karaciğer kanseri gibi çeşitli kanser türlerinin teşhisinde kritik bir rol oynar.


CT taramaları, büyük miktarda veri üretebilir ve bu verilerin manuel olarak analiz edilmesi oldukça zaman alıcı olabilir. Derin öğrenme algoritmaları, CT taramalarını analiz ederek tümörlerin yerini ve büyüklüğünü tespit eder. Ayrıca, algoritmalar kanserli hücrelerin zaman içindeki değişimlerini izleyerek, kanserin ilerlemesini takip edebilir. Şekil 2’de örnek CT görüntüsü verilmiştir.



Şekil 2. Örnek CT görüntüsü

3.8 Pozitron Emisyon Tomografisi (PET)

Pozitron Emisyon Tomografisi (PET), radyoaktif maddelerin vücutta nasıl emildiğini gözlemleyerek organların ve dokuların işlevini ölçen bir görüntüleme tekniğidir. PET, kanserli hücrelerin metabolik aktivitelerini izleyerek tümörlerin varlığını ve yayılma derecesini belirler. PET taramaları, genellikle CT ile birleştirilir ve bilgisayarla görme algoritmaları bu iki kaynağı birleştirerek kanserli bölgeleri daha kesin bir şekilde tespit eder. PET-CT kombinasyonu hem metabolik hem de yapısal bilgi sağlar ve böylece kanserli hücrelerin yerini ve işlevini hassas bir şekilde analiz edebilir. Şekil 3’de örnek PET görüntüsü verilmiştir.



Şekil 3. Örnek PET görüntüsü

3.9 Ultrason

Ultrason, ses dalgalarını kullanarak vücut içindeki organları ve dokuları görüntüleyen bir tekniktir. Özellikle meme, karaciğer ve tiroid kanserlerinin teşhisinde yaygın olarak kullanılır. Diğer görüntüleme yöntemlerine kıyasla, ultrason daha düşük maliyetlidir ve hastaya zarar vermeyen bir tekniktir. Ultrason verilerinin manuel analizi zordur ve bu süreçte yapay zeka sistemleri büyük bir fayda sağlar. Bilgisayarla görme algoritmaları, ultrason görüntülerindeki tümörleri tespit edebilir ve tümörlerin sınırlarını belirleyerek doktorlara teşhis sürecinde yardımcı olabilir. Şekil 4’te örnek Ultrason görüntüsü verilmiştir.



Şekil 4. Örnek Ultrason görüntüsü

4. Yapay Zeka ile Kanser Teşhisinde Etik ve Veri Güvenliği

Yapay zeka (YZ) ve derin öğrenme teknolojileri, kanser teşhis süreçlerinde devrim niteliğinde ilerlemeler sağlamış olsa da, bu teknolojilerin kullanımında etik ve veri güvenliği konuları önemli bir tartışma alanı olarak karşımıza çıkmaktadır. Yapay zeka destekli sistemlerin klinik karar alma süreçlerinde etkin bir şekilde kullanılabilmesi için hasta verilerinin gizliliği, algoritmik tarafsızlık ve sorumluluk paylaşımı gibi etik ve güvenlik konularının dikkatle ele alınması gerekmektedir. Bu bölümde, yapay zeka ile kanser teşhisinde karşılaşılan etik ve veri güvenliği sorunları ile bu sorunların üstesinden gelmek için alınabilecek önlemler ele alınacaktır. Yapay zeka algoritmalarının başarılı bir şekilde eğitilebilmesi için büyük miktarda veri gereklidir. Kanser teşhisinde kullanılan yapay zeka sistemleri, genellikle hastaların biyopsi, MRI, CT ve diğer tıbbi görüntülerini kullanır. Ancak, bu tıbbi veriler son derece hassas ve gizli bilgilerdir. Hasta verilerinin gizliliğinin korunması, yapay zeka uygulamalarının en önemli etik meselelerinden biridir. Hasta verilerinin gizliliğini koruma amacıyla kullanılan en yaygın yöntemlerden biri, verilerin anonimleştirilmesidir. Anonimleştirme, tıbbi görüntülerdeki kişisel bilgilerin kaldırılarak, hasta kimliğinin gizli tutulmasını sağlar. Yapay zeka sistemleri, bu anonimleştirilmiş veriler üzerinde çalışarak hem gizliliği korur hem de öğrenme süreçlerini sürdürebilir.

Hastaların tıbbi verilerinin korunması için gelişmiş veri güvenliği protokollerinin uygulanması gerekir. Sağlık verileri, yetkisiz erişimlere karşı koruma altına alınmalı ve yapay zeka sistemlerinin kullandığı veri depolama alanları şifrelenmelidir. Ayrıca, verilerin paylaşımı ve işlenmesi sırasında sıkı yasal düzenlemeler ve protokoller göz önünde bulundurulmalıdır. Yapay zeka sistemlerinin kanser teşhisinde kullanımı sırasında ortaya çıkan etik sorunlardan biri, algoritmik tarafsızlık ve önyargıdır. Yapay zeka algoritmaları, eğitildikleri veri setlerindeki önyargıları öğrenebilir ve bu önyargıları yeni verilerde de uygulayabilir. Örneğin, yapay zeka sistemleri, belirli demografik grupların verileri üzerinde eğitildiklerinde, diğer gruplar için yanlış sonuçlar verebilir. Yapay zeka algoritmalarının adil ve tarafsız sonuçlar verebilmesi için, eğitildikleri veri setlerinin toplumu temsil etmesi gerekmektedir. Ancak, bazı veri setleri belirli cinsiyet, ırk veya yaş gruplarını yeterince temsil etmeyebilir. Bu durumda, yapay zeka sistemleri belirli hasta grupları için hatalı teşhisler üretebilir. Örneğin, bazı veri setlerinde beyaz hastaların daha fazla temsil edilmesi, siyah veya diğer etnik gruplar için daha az doğru teşhis sonuçları doğurabilir. Bu önyargılar, yapay zeka destekli teşhis süreçlerinde adalet sorunlarına yol açabilir.

Algoritmik önyargıları azaltmak amacıyla, yapay zeka algoritmalarının eğitildiği veri setleri dikkatle dengelenmeli ve her hasta grubunun eşit şekilde temsil edilmesi sağlanmalıdır. Bunun yanı sıra, algoritmaların tarafsızlığını test etmek ve önyargılarını analiz etmek için geliştirilen araçlar kullanılmalıdır. Bu tür kontroller, yapay zeka sistemlerinin daha adil ve doğru sonuçlar üretmesini sağlar. Yapay zeka sistemleri, kanser teşhisinde doktorlara büyük bir destek sunsa da, bu sistemlerin verdiği kararların sorumluluğu konusunda çeşitli etik sorular ortaya çıkmaktadır. Yapay zeka, özellikle kritik teşhis süreçlerinde yanlış sonuçlar verebilir ve bu yanlış sonuçlar, hastaların yanlış tedavi edilmesine neden olabilir.

Yapay zeka destekli sistemler, tıbbi karar alma süreçlerinde doktorlara destek sunar; ancak nihai teşhis ve tedavi kararı her zaman doktor tarafından verilmelidir. Yapay zeka sistemlerinin verdiği kararlar, doktorun deneyimi ve bilgi birikimi ile birleştirildiğinde en doğru sonuçlar elde edilebilir. Ancak, yapay zeka sistemleri yanlış teşhis koyarsa, bu durumda sorumluluğun kimde olacağı tartışmalıdır. Doktorlar, yapay zekanın önerilerini dikkate almalı ancak nihai kararı kendi klinik değerlendirmelerine göre vermelidir. Yapay zeka sistemleri, kanser teşhisi sırasında hatalı sonuçlar verdiğinde, bu hataların sorumluluğunun kimde olduğu belirsiz olabilir. Bir yanlış teşhis sonucu, hastanın yanlış tedavi

edilmesine veya hastalığın ilerlemesine neden olabilir. Bu durumda, yapay zeka sistemini geliştiren mühendislerin, sistemi kullanan doktorların veya sağlık kuruluşunun sorumluluğu tartışma konusu olabilir. Bu tür durumlarda, sorumluluk paylaşımı açık bir şekilde tanımlanmalı ve yapay zeka sistemlerinin kullanımına yönelik yasal düzenlemeler geliştirilmelidir. Yapay zeka teknolojilerinin sağlık sektöründe kullanımı, yasal ve etik düzenlemelere tabi olmalıdır. Sağlık verilerinin doğru bir şekilde yönetilmesi ve yapay zeka sistemlerinin güvenli bir şekilde geliştirilmesi için ulusal ve uluslararası düzeyde düzenlemeler gereklidir. Bu düzenlemeler, hasta verilerinin korunmasını sağlarken, yapay zeka sistemlerinin etik ve güvenli bir şekilde kullanılmasını garanti altına alır. Avrupa Birliği'nde uygulanan Genel Veri Koruma Tüzüğü (GDPR), kişisel verilerin korunmasını sağlamak amacıyla kapsamlı bir düzenleme sunar. Sağlık verileri, GDPR kapsamında en hassas veri türlerinden biri olarak kabul edilir. Yapay zeka sistemlerinin sağlık verilerini kullanırken GDPR ile uyumlu olması, hasta gizliliğini koruma açısından büyük önem taşır. Bu düzenleme, yapay zeka sistemlerinin izinsiz veri kullanımını yapmasını engeller ve hasta haklarını korur.

Amerika Birleşik Devletleri'nde sağlık verilerinin gizliliğini düzenleyen HIPAA yasası, sağlık hizmeti sağlayıcılarının hasta verilerini nasıl yönetmesi gerektiğine dair kurallar belirler. Yapay zeka sistemleri, HIPAA ile uyumlu olacak şekilde geliştirilmeli ve hasta verilerinin güvenli bir şekilde işlenmesini sağlamalıdır. HIPAA, hasta verilerinin izinsiz paylaşımını önler ve sağlık bilgilerinin korunmasını güvence altına alır. Yapay zeka sistemlerinin sağlık sektöründe yaygınlaşmasıyla birlikte, bu sistemlerin nasıl çalıştığı konusunda şeffaflık ve denetlenebilirlik büyük önem kazanmıştır. Yapay zeka sistemlerinin verdiği kararların nasıl alındığını açıklamak ve bu sistemleri denetlemek, hasta güvenliği ve etik sorumluluklar açısından kritik bir adımdır. Yapay zeka sistemlerinin sağlık hizmetlerinde kullanımı sırasında, bu sistemlerin verdiği kararların nasıl alındığı açıkça anlaşılmalıdır. Şeffaflık, yapay zeka sistemlerinin güvenilirliğini artırır ve doktorların bu sistemlere güvenmesini sağlar. Derin öğrenme modelleri genellikle "kara kutu" olarak adlandırılan bir yapıya sahiptir ve karar verme süreçleri dışarıdan net bir şekilde görülemez. Bu nedenle, yapay zeka sistemlerinin karar alma süreçlerinin anlaşılır hale getirilmesi, klinik kullanım açısından önemlidir. Yapay zeka sistemlerinin denetlenmesi ve bu sistemlerin etik kurallara uygun çalışıp çalışmadığının kontrol edilmesi gerekmektedir. Bu denetim süreci, yapay zeka sistemlerinin tarafsız, güvenli ve doğru bir şekilde çalışmasını sağlar. Ayrıca, yapay zeka sistemlerinin yanlış teşhisler veya hatalı sonuçlar vermesi durumunda sorumluluk mekanizmalarının devreye girmesi gerekir. Denetim süreçleri, yapay zeka sistemlerinin düzenli olarak test edilmesini ve güncellenmesini içerir.

5. UYGULAMA ÇALIŞMALARI

5.1 Beyin Tümörü Teşhisi Uygulamaları

Beyin tümörü, beyin veya omurilik kanalının içinde yer alan anormal hücrelerin oluşturduğu bir kitle veya büyümedir. Beyin tümörleri, iyi huylu (benign) veya kötü huylu (malign) olabilir. Beyin ve sinir sistemi, insan vücudunun en karmaşık yapılarından biri olduğu için, tümörlerin bu bölgelerde ortaya çıkması ciddi sağlık sorunlarına yol açabilir. Beyin tümörleri, doğrudan beyin hücrelerinden (primer tümörler) kaynaklanabilir veya başka bir bölgedeki kanserin metastaz yapmasıyla (sekonder tümörler) oluşabilir.

Beyin tümörleri, hücresel kökenlerine ve biyolojik davranışlarına göre sınıflandırılır. Temel beyin tümörü türleri aşağıdaki gibidir:

Primer Beyin Tümörleri

Primer tümörler, doğrudan beyindeki hücrelerden kaynaklanır. Bunlar arasında:

- **Gliomalar:** Beyindeki glial hücrelerden kaynaklanır ve en yaygın tümör tiplerinden biridir.
 - **Astrositom:** Astrosit adı verilen hücrelerden oluşur. Düşük dereceli (iyi huylu) veya yüksek dereceli (kötü huylu) olabilir.
 - **Glioblastom:** En agresif glioma türüdür ve hızlı bir şekilde büyür.
 - **Ependimom:** Beyin ve omurilik sıvısını üreten hücrelerden kaynaklanır.
 - **Oligodendrogliom:** Oligodendrosit adı verilen hücrelerden oluşur.
- **Meningiom:** Beyni çevreleyen zarlar olan meninkslerden kaynaklanır. Genellikle iyi huyludur.
- **Medulloblastom:** Çocuklarda daha sık görülen, beyincikte oluşan bir tümördür.
- **Schwannom:** Sinirleri çevreleyen Schwann hücrelerinden kaynaklanır. Akustik nörom olarak da bilinir.

Sekonder Beyin Tümörleri (Metastatik)

Sekonder tümörler, başka bir organdaki kanserin beyne yayılması sonucu oluşur. En sık metastaz yapan kanser türleri:

- Akciğer kanseri
- Meme kanseri
- Melanom (cilt kanseri)
- Böbrek kanseri
- Kolorektal kanser

İyi Huylu Tümörler

- Yavaş büyürler ve genellikle çevredeki dokulara yayılmazlar.
- Cerrahi ile tamamen çıkarıldıklarında genellikle tekrar oluşmazlar.
- Örnek: Meningiom, düşük dereceli astrositom.

Kötü Huylu Tümörler

- Hızla büyürler ve çevredeki sağlıklı dokulara yayılabilirler.
- Tedavi edilmezse ölümcül olabilirler.
- Örnek: Glioblastom.

Beyin Tümörü Tedavi Yöntemleri

Beyin tümörlerinin tedavisi, tümörün tipi, büyüklüğü, konumu ve hastanın genel sağlık Beyin tümörlerinin tedavisinde ilk adım genellikle cerrahidir. Ameliyatın amacı, mümkünse tüm tümörü tamamen çıkarmaktır. Ancak, tümör kritik beyin bölgelerine yakınsa, yalnızca bir kısmı çıkarılabilir. Cerrahi işlem sırasında kullanılan nöronavigasyon ve uyandırma ameliyatları, beyin işlevlerini korumaya yardımcı olur.

- Yüksek enerjili ışınlar kullanılarak tümör hücrelerinin yok edilmesini amaçlar.
- Özellikle cerrahi yapılamayan veya tamamen çıkarılamayan tümörlerde etkili bir yöntemdir.
- Stereotaktik radyocerrahi (Gamma Knife): Daha hassas ışın tedavisi sağlar.
- Kanser hücrelerini öldürmek veya büyümelerini durdurmak için ilaç kullanılır.
- Oral veya intravenöz yollarla uygulanabilir.
- Glioblastom gibi agresif tümörlerde temozolomid gibi ilaçlar sıklıkla kullanılır.

Hedefe Yönelik Tedaviler

- Bu tedaviler, tümör hücrelerine özgü moleküler hedeflere yönelir.
- Daha az yan etkiyle daha etkili sonuçlar sağlar.
- Anti-anjiyogenez tedaviler (bevacizumab): Tümörün kan damarı oluşturmasını engeller.

İmmünoterapi

- Bağışıklık sistemini güçlendirerek tümör hücrelerini hedef almayı amaçlar.
- Deneysel olarak bazı beyin tümörlerinde etkili olabileceği düşünülmektedir.

Destekleyici Tedavi

- Tümör ve tedavinin yan etkilerini yönetmek için kullanılır.
- Steroidler: Beyindeki şişmeyi azaltır.
- Antikonvülsanlar: Nöbetlerin kontrolü için kullanılır.
- Rehabilitasyon: Konuşma, hareket ve bilişsel fonksiyonların iyileştirilmesine yardımcı olur.

Deneysel Tedaviler

- Klinik deneylerde kullanılan yenilikçi tedavi yöntemleridir.
- Gen tedavisi, nanopartiküller, elektrik alan tedavileri (Optune) gibi yeni yaklaşımlar beyin tümörlerinin tedavisinde araştırılmaktadır.

Bu bölümde, beyin tümörlerinin teşhisinde kullanılan görüntüleme teknikleri, bilgisayarla görme ve derin öğrenme teknolojilerinin katkıları ve klinik uygulamalar detaylı bir şekilde ele alınacaktır.


5.2 Beyin Tümörü Teşhisi Uygulamaları

Uygulamada kullanılan beyin tümörü veri seti, dört farklı sınıfa ait toplam 4774 görüntü içermektedir. Bu görüntüler, eğitim ve test verisi olarak ikiye ayrılmıştır. Eğitim aşamasında modelin öğrenme sürecini gerçekleştirmesi için 3818 görüntü, test aşamasında ise modelin doğruluğunu ve performansını değerlendirmek için 956 görüntü kullanılmıştır. Veri setindeki sınıflar ve her bir sınıfa ait eğitim ve test görüntü sayıları Tablo 1’te ayrıntılı olarak verilmiştir:

Tablo 1. Beyin Tümörüne Ait Veri Setindeki Eğitim ve Test Verileri

Sınıflar	Eğitim Verisi Sayısı	Test Verisi Sayısı	Toplam Görüntü Sayısı
Glioma Tumor	980	245	1225
Meningioma Tumor	982	246	1228
Normal	888	222	1110
Pituitary Tumor	968	243	1211

Veri seti, **Glioma Tümör**, **Meningioma Tümör**, **Normal** ve **Pituitary Tümör** olmak üzere dört sınıftan oluşmaktadır. Görüntülerin eğitim ve test verisi olarak dengeli bir şekilde ayrılması, modelin öğrenme sürecinde sınıflar arası performans dengesini korumaya yardımcı olmaktadır. Eğitim verisi, modelin beyin tümörlerini doğru bir şekilde öğrenmesini sağlarken, test verisi modelin daha önce görmediği veriler üzerinde performansını ölçmek için kullanılmaktadır. Bu yapılandırılmış veri seti, beyin tümörlerinin sınıflandırılmasında makine öğrenmesi ve derin öğrenme algoritmalarının performansını değerlendirmek için uygun bir temel oluşturmaktadır. Şekil 5’de veri setindeki görüntüleri ait örnek görüntüler verilmiştir.



Şekil 5. Beyin Tümörü veri setindeki her bir sınıfa ait görüntü örnekleri

Çalışma için EfficientNet B0, EfficientNet V2 B0, MobileNet, DenseNet201 ve ResNet152 transfer öğrenme tabanlı derin öğrenme modelleri kullanıldı. Veri seti 50 epoch süresince eğitildi. Yazılan kod, beyin tümörlerinin dört farklı sınıf (adenokarsinom, büyük hücreli karsinom, normal ve yassı hücreli karsinom) üzerinden sınıflandırılması amacıyla geliştirilmiş kapsamlı bir derin öğrenme sistemi sunar. Kodun ana işlevi, farklı önceden eğitilmiş derin öğrenme modellerinin (EfficientNet B0, EfficientNet V2 B0, MobileNet V2, DenseNet 201, ResNet 152) performansını karşılaştırarak, hangi modelin bu sınıflandırma görevinde daha iyi olduğunu belirlemektir. Veriler, bir veri klasöründen yüklenir ve eğitim/test veri kümelerine ayrılmıştır. Her bir veri seti, torchvision.transforms modülü aracılığıyla standart bir işleme tabi tutulur: Görüntüler belirli bir boyuta ölçeklendirilir, tensörlere dönüştürülür ve normalize edilir. Bu işlem, modellerin beklediği giriş formatını sağlamak ve eğitim sürecini hızlandırmak için gereklidir.

Kodda, her model için bir ModelWrapper sınıfı tanımlanmıştır. Bu sınıf, önceden eğitilmiş modellerin (örneğin, EfficientNet, MobileNet, ResNet gibi) son sınıflandırma katmanını yeniden yapılandırarak, beyin tümörlerine ait dört sınıfı tanıyacak şekilde adapte eder. Eğitim süreci sırasında her bir model, eğitim veri kümesi üzerinde optimize edilir ve ardından test veri kümesi ile doğrulama yapılır. Eğitim sırasında, çapraz entropi kaybı fonksiyonu (CrossEntropyLoss) kullanılarak modelin tahminleriyle gerçek etiketler arasındaki hata hesaplanır. Bu hata, AdamW optimizasyon algoritması ile minimize edilir. Eğitim döngüsünde, model çıktıları doğruluk (accuracy) hesaplaması için izlenirken, test döngüsünde modellerin genel performansı metriklerle değerlendirilir.

Model performansını analiz etmek için kapsamlı bir metrik seti kullanılmıştır. Sınıflandırma raporunda precision, recall, f1-score gibi detaylı ölçütler, her sınıf için hesaplanır. Karmaşıklık matrisi (confusion matrix) gerçek ve tahmin edilen sınıflar arasındaki ilişkileri gösterir. Ek olarak, Mean Absolute Error (MAE) modeli genelleştirme açısından değerlendirirken, Cohen Kappa Score modelin sınıflandırmadaki tutarlılığını ölçer. Grafiksiz analizler, eğitim ve test kayıplarının yanı sıra doğrulukların görselleştirilmesini sağlar. Bu görseller, modelin öğrenme sürecindeki eğilimleri izlemek ve hangi modelin daha iyi performans gösterdiğini anlamak için kullanılır. Sonuç olarak, kod, farklı derin öğrenme modellerinin performansını değerlendirme ve karşılaştırma sürecini sistematik bir şekilde yönetir.

Modelin Kodu

Verilen kodun içerisinde her bir satırda kodu yaptığı işlere ait detaylı açıklamalar verilmiştir.

```
# Gerekli kütüphaneleri içe aktar
import time # Eğitim süresini ölçmek için
import torch # PyTorch framework'ü
import torch.nn as nn # PyTorch sinir ağı modülleri
import torch.optim as optim # Optimizasyon algoritmaları
from torch.utils.data import DataLoader # Veri yükleyici
from torchvision import transforms, models # Görüntü işleme ve hazır modeller
from torchvision.datasets import ImageFolder # Klasör yapısındaki veri setlerini okumak için
from sklearn.metrics import classification_report, confusion_matrix, mean_absolute_error, cohen_kappa_score
import matplotlib.pyplot as plt # Grafik çizimi
import seaborn as sns # Görsel istatistik
from tqdm import tqdm # Döngülerin ilerleme çubuğu
import numpy as np # Matematiksel işlemler
```

```

# **Model Wrapper (Model Sarmalayıcı)**
# Farklı derin öğrenme modellerini ortak bir çerçevede tanımlamak için kullanılır.
class ModelWrapper(nn.Module):
    def __init__(self, model_name, num_classes):
        super(ModelWrapper, self).__init__()
        # EfficientNet V2 B0 Modeli
        if model_name == "efficientnet_v2_b0":
            self.model = models.efficientnet_v2_s(pretrained=True) # Önceden eğitilmiş EfficientNet V2
            self.model.classifier[1] = nn.Linear(self.model.classifier[1].in_features, num_classes)
        # EfficientNet B0 Modeli
        elif model_name == "efficientnet_b0":
            self.model = models.efficientnet_b0(pretrained=True)
            self.model.classifier[1] = nn.Linear(self.model.classifier[1].in_features, num_classes)
        # MobileNetV2 Modeli
        elif model_name == "mobilenetv2":
            self.model = models.mobilenet_v2(pretrained=True)
            self.model.classifier[1] = nn.Linear(self.model.classifier[1].in_features, num_classes)
        # DenseNet201 Modeli
        elif model_name == "densenet201":
            self.model = models.densenet201(pretrained=True)
            self.model.classifier = nn.Linear(self.model.classifier.in_features, num_classes)
        # ResNet152 Modeli
        elif model_name == "resnet152":
            self.model = models.resnet152(pretrained=True)
            self.model.fc = nn.Linear(self.model.fc.in_features, num_classes)

    def forward(self, x):
        return self.model(x)

# **Veri Yükleme Fonksiyonu**
# Eğitim ve test verilerini yüklemek için.
def load_images(data_path, target_size=(224, 224)):
    transform = transforms.Compose([
        transforms.Resize(target_size), # Görselleri hedef boyuta ölçeklendir
        transforms.ToTensor(), # Görselleri PyTorch tensörlerine çevir
        transforms.Normalize([0.485, 0.456, 0.406], [0.229, 0.224, 0.225]) # Görselleri normalize et
    ])
    dataset = ImageFolder(data_path, transform=transform) # Görselleri klasör yapısından oku
    data_loader = DataLoader(dataset, batch_size=32, shuffle=True) # Veri yükleyiciyi oluştur
    return data_loader

# **Veri yolları**
train_data_path = "../datasets/brain_tumor_dataset_aug/train/" # Eğitim verisi
test_data_path = "../datasets/brain_tumor_dataset_aug/validation/" # Test verisi

# **Test Edilecek Modeller**
models_to_test = ["efficientnet_b0", "efficientnet_v2_b0", "mobilenetv2", "densenet201", "resnet152"]

# **Veri Yükleyiciler**
train_loader = load_images(train_data_path) # Eğitim verilerini yükle
test_loader = load_images(test_data_path) # Test verilerini yükle

```

```

# **Modellerin Eğitim ve Test Süreci**
for model_name in models_to_test:
    print(f"\nModel değerlendiriliyor: {model_name}")

    # Modeli, hata fonksiyonunu ve optimizasyon algoritmasını tanımla
    num_classes = len(train_loader.dataset.classes)
    model = ModelWrapper(model_name, num_classes)
    criterion = nn.CrossEntropyLoss() # Sınıflandırma için çapraz entropi hata fonksiyonu
    optimizer = optim.AdamW(model.parameters(), lr=2e-5) # AdamW optimizasyon algoritması

    # Cihaz ayarı (GPU varsa GPU kullan, yoksa CPU kullan)
    device = torch.device("cuda" if torch.cuda.is_available() else "cpu")
    model.to(device)

    # Eğitim süreci değişkenlerini tanımla
    train_losses, test_losses = [], []
    train_accuracies, test_accuracies = [], []

    # Eğitim zamanını ölç
    start_time = time.time()

    # **Eğitim Döngüsü**
    num_epochs = 50
    for epoch in range(num_epochs):
        model.train() # Modeli eğitim moduna al
        total_train_loss, correct_train, total_train = 0, 0, 0
        for images, labels in tqdm(train_loader, desc=f"Epoch {epoch+1}/{num_epochs}"):
            images, labels = images.to(device), labels.to(device)
            optimizer.zero_grad() # Gradyanları sıfırla
            outputs = model(images) # Model tahmini
            loss = criterion(outputs, labels) # Hata hesapla
            loss.backward() # Gradyanları hesapla
            optimizer.step() # Ağırlıkları güncelle
            total_train_loss += loss.item()
            _, predicted = torch.max(outputs, 1) # Tahmin edilen sınıf
            correct_train += (predicted == labels).sum().item()
            total_train += labels.size(0)

        train_loss = total_train_loss / len(train_loader)
        train_accuracy = correct_train / total_train
        train_losses.append(train_loss)
        train_accuracies.append(train_accuracy)

    # **Test Süreci**
    model.eval()
    total_test_loss, correct_test, total_test = 0, 0, 0
    with torch.no_grad():
        for images, labels in tqdm(test_loader, desc="Test Süreci"):
            images, labels = images.to(device), labels.to(device)
            outputs = model(images)
            loss = criterion(outputs, labels)
            total_test_loss += loss.item()
            _, predicted = torch.max(outputs, 1)
            correct_test += (predicted == labels).sum().item()
            total_test += labels.size(0)

    test_loss = total_test_loss / len(test_loader)
    test_accuracy = correct_test / total_test
    test_losses.append(test_loss)
    test_accuracies.append(test_accuracy)

    print(f"Epoch {epoch+1}/{num_epochs}: Eğitim Kaybı: {train_loss:.4f},
    Eğitim Doğruluğu: {train_accuracy:.4f}, Test Kaybı: {test_loss:.4f},
    Test Doğruluğu: {test_accuracy:.4f}")

```

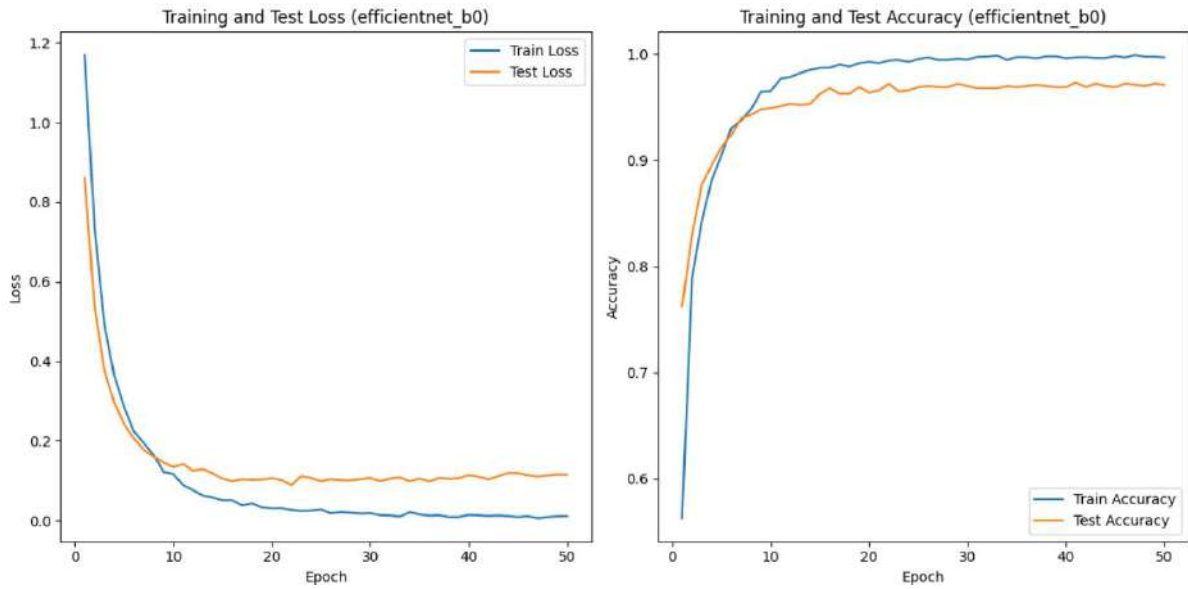
```

# Toplam süreyi ölç
end_time = time.time()
total_time = end_time - start_time
print(f"\nToplam Eğitim Süresi: {total_time:.2f} saniye")
# Eğitim ve Test Kaybını Çiz
plt.figure(figsize=(12, 6))
plt.plot(range(1, num_epochs+1), train_losses, label="Eğitim Kaybı")
plt.plot(range(1, num_epochs+1), test_losses, label="Test Kaybı")
plt.xlabel("Epoch")
plt.ylabel("Kaybı")
plt.title(f"{model_name} Modeli - Eğitim ve Test Kaybı")
plt.legend()
plt.savefig(f"loss_{model_name}.png")
plt.show()

# Sınıflandırma Raporu ve Confusion Matrix
print("Sınıflandırma Raporu:")
all_labels, all_predictions = [], []
with torch.no_grad():
    for images, labels in tqdm(test_loader):
        outputs = model(images.to(device))
        _, predicted = torch.max(outputs, 1)
        all_labels.extend(labels.cpu().numpy())
        all_predictions.extend(predicted.cpu().numpy())
print(classification_report(all_labels, all_predictions))

```

EfficientNet B0 Modelinin Başarım Metrikleri ve Grafikleri

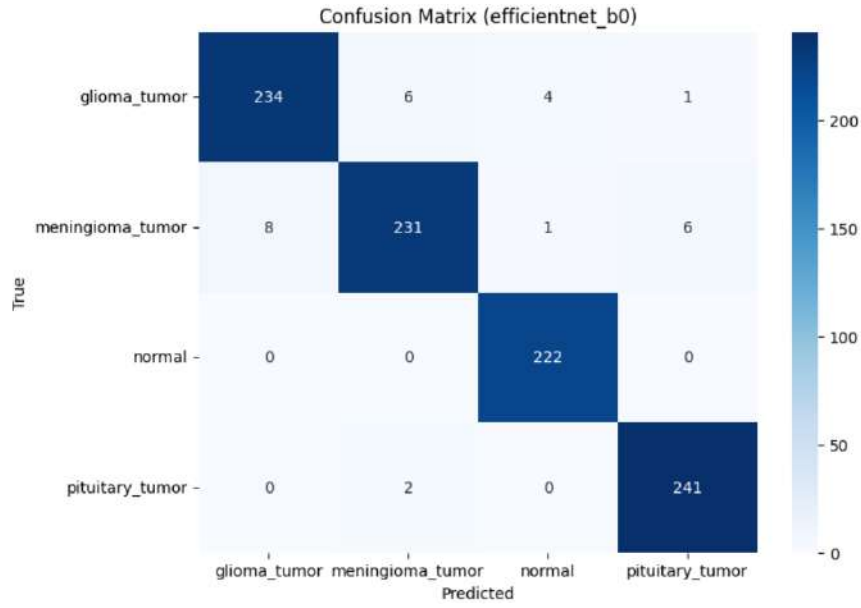


Classification Report:

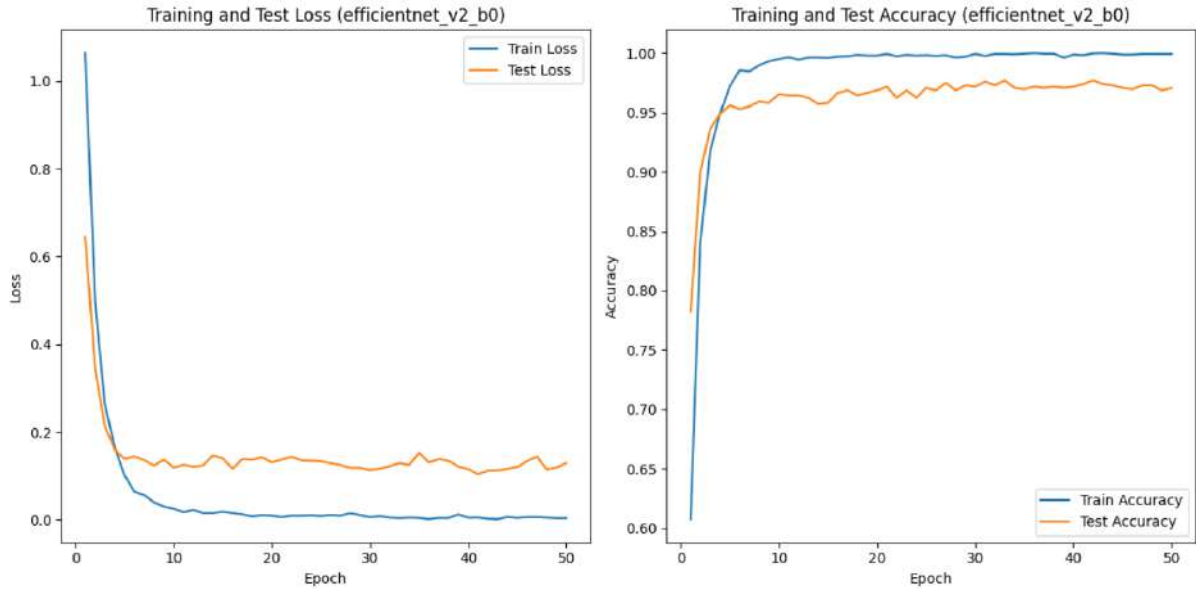
	precision	recall	f1-score	support
glioma_tumor	0.9669	0.9551	0.9610	245
meningioma_tumor	0.9665	0.9390	0.9526	246
normal	0.9780	1.0000	0.9889	222
pituitary_tumor	0.9718	0.9918	0.9817	243
accuracy			0.9707	956
macro avg	0.9708	0.9715	0.9710	956
weighted avg	0.9706	0.9707	0.9706	956

Mean Absolute Error (MAE): 0.0439

Cohen's Kappa: 0.9609



EfficientNet V2 B0 Modelinin Başarım Metrikleri ve Grafikleri




Classification Report:


	precision	recall	f1-score	support
glioma_tumor	0.9831	0.9469	0.9647	245
meningioma_tumor	0.9264	0.9715	0.9484	246
normal	0.9911	1.0000	0.9955	222
pituitary_tumor	0.9874	0.9671	0.9771	243
accuracy			0.9707	956
macro avg	0.9720	0.9714	0.9714	956
weighted avg	0.9714	0.9707	0.9708	956

Mean Absolute Error (MAE): 0.0429

Cohen's Kappa: 0.9609



MobileNetV2 Modelinin Başarım Metrikleri ve Grafikleri




Classification Report:

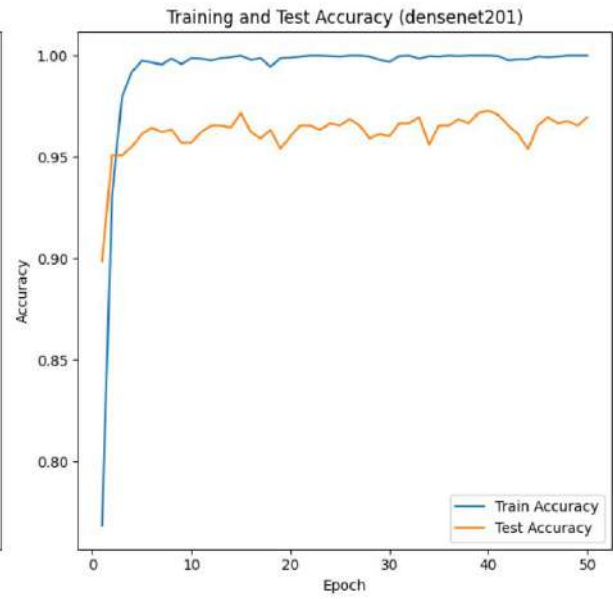
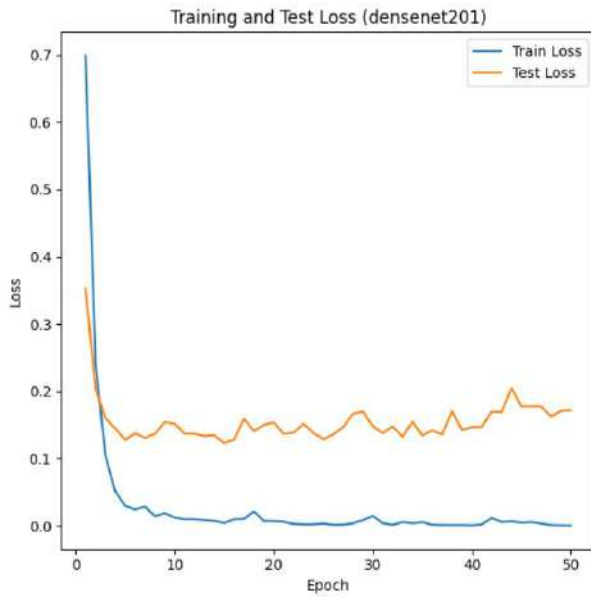
	precision	recall	f1-score	support
glioma_tumor	0.9429	0.9429	0.9429	245
meningioma_tumor	0.9483	0.8943	0.9205	246
normal	0.9609	0.9955	0.9779	222
pituitary_tumor	0.9518	0.9753	0.9634	243
accuracy			0.9508	956
macro avg	0.9510	0.9520	0.9512	956
weighted avg	0.9507	0.9508	0.9505	956

Mean Absolute Error (MAE): 0.0774

Cohen's Kappa: 0.9344



ResNet152 Modelinin Başarım Metrikleri ve Grafikleri

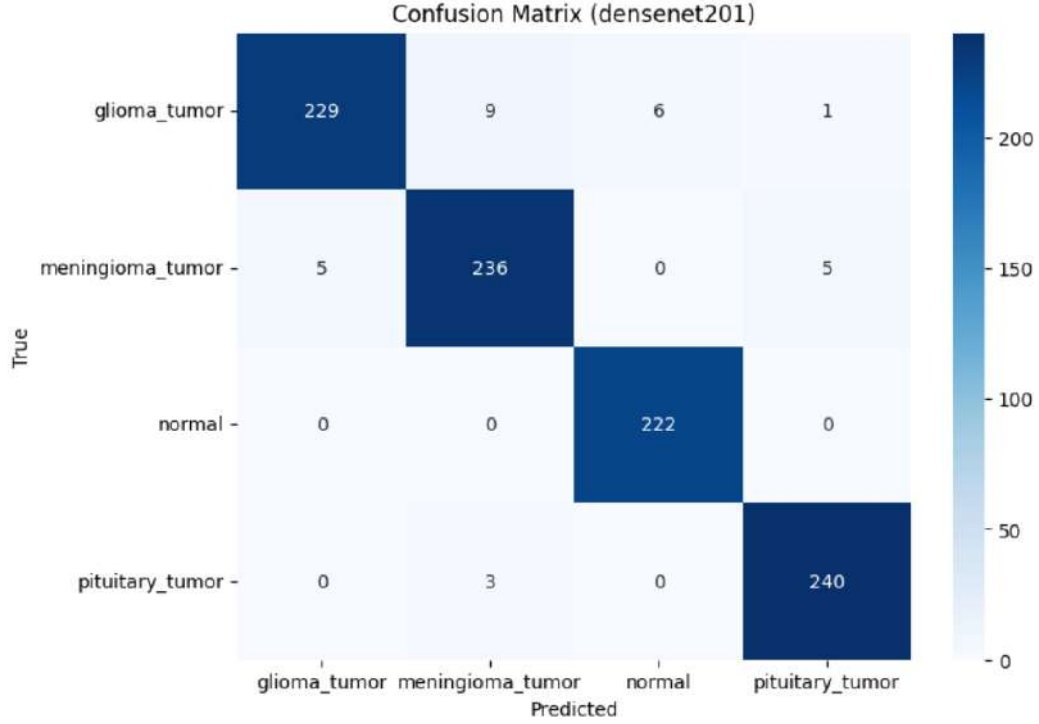


Classification Report:

	precision	recall	f1-score	support
glioma_tumor	0.9786	0.9347	0.9562	245
meningioma_tumor	0.9516	0.9593	0.9555	246
normal	0.9737	1.0000	0.9867	222
pituitary_tumor	0.9756	0.9877	0.9816	243
accuracy			0.9697	956
macro avg	0.9699	0.9704	0.9700	956
weighted avg	0.9698	0.9697	0.9695	956

Mean Absolute Error (MAE): 0.0471

Cohen's Kappa: 0.9595



Yukarıda verilen modellerin karşılaştırmalı analizi, farklı performans metrikleri kullanılarak gerçekleştirilmiştir. Tablo 2’de modellerin başarımlarına karşılaştırılmaları yapılmıştır. Bu metrikler; precision (kesinlik), recall (duyarlılık), F1-score, Confusion Matrix, Mean Absolute Error (MAE) ve Cohen’s Kappa gibi ölçütleri içerir. EfficientNet B0 modeli, dengeli bir performans sergileyerek genel doğruluk oranında (%97.07) oldukça başarılıdır. Özellikle normal sınıfında %100 duyarlılık ve %98.89 F1-score ile üstün performans göstermiştir. Ancak glioma_tumor ve meningioma_tumor sınıflarında, diğer modellere kıyasla biraz daha düşük duyarlılık (%95.51 ve %93.90) gözlemlenmiştir. MAE değeri %4.39 ile oldukça düşüktür. EfficientNetV2 B0 modeli, glioma_tumor sınıfında %98.31 precision ile yüksek performans sergilerken, meningioma_tumor sınıfında recall değerinin (%97.15) artışı dikkat çekicidir. Modelin genel doğruluk oranı %97.07 olup, AUC-PR metriği %96 ile EfficientNet B0’a göre daha iyi sonuçlar vermiştir. Ancak, confusion matrix sonuçlarında yanlış pozitifler EfficientNet B0’a göre biraz daha fazladır. MobileNetV2 modeli, diğer modellere göre daha düşük bir genel doğruluk oranına (%95.08) sahiptir. Özellikle meningioma_tumor sınıfında duyarlılığın (%89.43) düşük olması, bu modelin performansını olumsuz etkilemiştir. Ancak normal sınıfında %99.55 F1-score ile iyi sonuçlar elde edilmiştir. MAE değeri ise diğer modellere kıyasla yüksek (%7.74) olup, modelin genel doğruluk oranını etkileyen bir faktördür. DenseNet201 modeli, genel doğruluk oranında %96.97 ile yüksek performans göstermektedir. glioma_tumor sınıfında %97.86 precision, normal sınıfında %100 recall ve %98.67 F1-score elde edilmiştir. MAE değeri %4.71 ile oldukça düşüktür. Bu modelin başarımlarını, özellikle normal sınıflar ve hata oranlarının azlığı ile dikkat çekicidir. ResNet152 modeli, %97.38 doğruluk oranı ile en iyi performansını sergileyen modeldir. glioma_tumor sınıfında %99.57 precision ve meningioma_tumor sınıfında %97.56 recall ile en iyi sonuçları elde etmiştir. Ayrıca, AUC-PR (%96) ve MAE (%4.29) değerleri bu modelin üstünlüğünü ortaya koymaktadır. Ancak, confusion matrix sonuçlarında yanlış pozitif ve negatif oranlarının diğer modellere göre bir miktar daha fazla olduğu gözlemlenmiştir.

Tablo 2. Derin öğrenme modellerinin karşılaştırılması

Model	Precision	Recall	F1-score	AUC-ROC	AUC-PR	MAE	Kappa
EfficientNet B0	0.9706	0.9707	0.9706	0.99	0.98	0.0439	0.9609
EfficientNetV2 B0	0.9714	0.9707	0.9708	0.99	0.96	0.0429	0.9609
MobileNetV2	0.9507	0.9508	0.9505	0.98	0.93	0.0774	0.9344
DenseNet201	0.9698	0.9697	0.9695	0.99	0.95	0.0471	0.9595
ResNet152	0.9743	0.9738	0.9737	0.99	0.96	0.0429	0.9651

Bu analizde, önerilen modeller arasında ResNet152 ve EfficientNetV2 B0 en yüksek performansı göstermiştir. DenseNet201 ise dengeli bir performans sergilerken, MobileNetV2 daha düşük performansı ile dikkat çekmektedir. Araştırmanın ilerleyen aşamalarında ResNet152'nin performansı daha farklı veri setlerinde test edilerek genel kullanım potansiyeli artırılabilir. EfficientNetV2 B0 ve DenseNet201 ise hafif ve hızlı modeller olarak optimize edilebilir.

5.3 Akciğer Kanseri Teşhisi Uygulaması


Akciğer kanseri, akciğer dokusunda kontrolsüz hücre büyümesi ile karakterize edilen ciddi bir hastalıktır. Akciğer kanseri, dünya genelinde en yaygın kanser türlerinden biri olup, kanserden kaynaklanan ölümler arasında ilk sıralarda yer almaktadır. Akciğer kanserinin erken evrelerde teşhis edilmesi, hastanın yaşam şansını önemli ölçüde artırır. Bununla birlikte, akciğer kanseri belirtilerinin genellikle geç evrelerde ortaya çıkması, erken teşhisi zorlaştıran temel faktörlerden biridir. Risk faktörleri arasında sigara kullanımı, hava kirliliği, genetik faktörler ve zararlı kimyasallara maruz kalma yer almaktadır. Akciğer kanseri genellikle erken evrede belirti göstermediğinden, çoğu hasta ileri evrede teşhis edilir. Tıbbi görüntüleme teknikleri, özellikle bilgisayarlı tomografi (CT) ve düşük dozlu CT taramaları, akciğer kanserinin teşhisinde önemli rol oynar. Bu bölümde, akciğer kanserinin teşhisinde kullanılan tıbbi görüntüleme yöntemleri, derin öğrenme algoritmalarıyla akciğer nodüllerinin tespiti ve klinik uygulamalar ele alınacaktır.

Uygulama için kullanılan akciğer kanseri veri seti benign, malignant ve normal olarak üç sınıfa ayrılmıştır. Veri setindeki her bir sınıfa ait görüntü sayıları arasında yakın değerler olmadığı için veri seti üzerinde veri zenginleştirme uygulandı. Veri zenginleştirme işleminden sonra her bir sınıf 750 görüntü içermektedir. Her sınıf için 600 görüntü eğitim setine, 150 görüntü test setine ayrılmıştır. Toplamda 1800 eğitim ve 450 test görüntüsü bulunmaktadır. Her bir görüntü (224x224) boyutunda ve renkli olup üç kanallıdır (RGB). Veri setindeki dengesizliği gidermek için zenginleştirme yöntemleri uygulanmıştır. Dönme, kırılma ve aydınlık artırma gibi veri artırma teknikleri ile daha genellenebilir bir model elde edilmesi amaçlanmıştır. Tablo 3'te veri setine ait sınıflar ve görüntü sayıları verilmiştir.

Tablo 3. Akciğer kanserine ait veri setindeki eğitim ve test verileri

Sınıflar	Eğitim	Test	Toplam Eğitim ve Test Verisi
Benign	600	150	Eğitim: 1800
Malignant	600	150	Test: 750
Normal	600	150	

Şekil 6’da veri setindeki görüntüleri ait örnek görüntüler verilmiştir.



Şekil 6. Akciğer Kanseri veri setindeki her bir sınıfa ait görüntü örnekleri

Bu çalışmada, akciğer kanseri görüntülerini sınıflandırmak için çeşitli makine öğrenmesi modelleri kullanılmıştır. SVM (Destek Vektör Makineleri), doğrusal ve doğrusal olmayan ayırıcılarla çalışabilen bir sınıflandırma algoritması olarak kullanılmıştır; ancak büyük veri setlerinde karmaşıklık nedeniyle dezavantajlıdır. Karar Ağacı (Decision Tree), veriyi dallara ayırarak hızlı ve kolay yorumlanabilir sınıflandırmalar yaparken, aşırı öğrenme riski taşıyabilir. Random Forest, birden fazla karar ağacını birleştirerek genelleme yeteneğini artırır ve overfitting sorununu azaltır. XGBoost (Extreme Gradient Boosting), optimize edilmiş gradient boosting algoritmasıyla yüksek doğruluk ve düşük hata oranı sunarak öne çıkmaktadır. Bu modellerin farklı özellikleri, çalışma kapsamında sınıflandırma görevine çeşitli perspektifler sunmuş ve performans açısından kapsamlı bir karşılaştırma yapılmasını sağlamıştır. Aşağıda kullanılan modelin kodu verilmiştir.

Modelin Kodu:

```
import os
import time
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.metrics import classification_report, confusion_matrix, mean_absolute_error
from sklearn.svm import SVC
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import RandomForestClassifier
from xgboost import XGBClassifier
from tensorflow.keras.preprocessing.image import ImageDataGenerator

# Veri yolları
train_data_path = "../datasets/lung_cancer_aug/train/"
test_data_path = "../datasets/lung_cancer_aug/validation/"

# Veri artırma
datagen = ImageDataGenerator(rescale=1.0 / 255)

# Eğitim ve test verilerini yükleme
train_generator = datagen.flow_from_directory(
    train_data_path,
    target_size=(224, 224),
    batch_size=32,
    class_mode='categorical',
    shuffle=False
)
test_generator = datagen.flow_from_directory(
    test_data_path,
    target_size=(224, 224),
    batch_size=32,
    class_mode='categorical',
    shuffle=False
)

# Görüntü ve etiketleri çıkarma
def extract_data(generator):
    X, y = [], []
    for _ in range(len(generator)):
        batch_x, batch_y = next(generator)
        X.append(batch_x)
        y.append(batch_y)
    return np.vstack(X), np.argmax(np.vstack(y), axis=1)
X_train, y_train = extract_data(train_generator)
X_test, y_test = extract_data(test_generator)

print(f"Training data shape: {X_train.shape}, Training labels shape: {y_train.shape}")
print(f"Testing data shape: {X_test.shape}, Testing labels shape: {y_test.shape}")

# Reshaping data for ML models
X_train_flat = X_train.reshape(X_train.shape[0], -1)
X_test_flat = X_test.reshape(X_test.shape[0], -1)

# Model listesi
models = {
    "SVM": SVC(kernel='linear', probability=True),
    "Decision Tree": DecisionTreeClassifier(),
    "Random Forest": RandomForestClassifier(n_estimators=100),
    "XGBoost": XGBClassifier(use_label_encoder=False, eval_metric='mlogloss')
}

# Performans metrikleri için yer tutucu
results = {}
```

```

# Model eğitim ve değerlendirme
for model_name, model in models.items():
    print(f"Training {model_name}...")
    start_time = time.time()
    model.fit(X_train_flat, y_train)
    training_time = time.time() - start_time

    print(f"Testing {model_name}...")
    y_pred = model.predict(X_test_flat)
    y_prob = model.predict_proba(X_test_flat)
    # Metrikler
    accuracy = model.score(X_test_flat, y_test)
    mae = mean_absolute_error(y_test, y_pred)
    cm = confusion_matrix(y_test, y_pred)
    cr = classification_report(y_test, y_pred, target_names=test_generator.class_indices.keys())

    # Sonuçları saklama
    results[model_name] = {
        "accuracy": accuracy,
        "mae": mae,
        "confusion_matrix": cm,
        "classification_report": cr,
        "training_time": training_time
    }
    print(f"\n{model_name} Results:")
    print(f"Accuracy: {accuracy:.4f}")
    print(f"MAE: {mae:.4f}")
    print("Classification Report:")
    print(cr)
    print("Confusion Matrix:")
    print(cm)
    print(f"Training Time: {training_time:.2f} seconds\n")
# Grafikler
for model_name, metrics in results.items():
    cm = metrics["confusion_matrix"]
    plt.figure(figsize=(6, 6))
    plt.imshow(cm, interpolation='nearest', cmap=plt.cm.Blues)
    plt.title(f"Confusion Matrix: {model_name}")
    plt.colorbar()
    tick_marks = np.arange(len(test_generator.class_indices))
    plt.xticks(tick_marks, test_generator.class_indices.keys(), rotation=45)
    plt.yticks(tick_marks, test_generator.class_indices.keys())
    plt.ylabel('True Label')
    plt.xlabel('Predicted Label')
    plt.show()
    # Accuracy ve MAE karşılaştırması
    print(f"{model_name}: Accuracy: {metrics['accuracy']:.4f}, MAE: {metrics['mae']:.4f}")

# Eğitim ve test veri sayıları
print(f"Total training images: {len(train_generator.file_names)}")
print(f"Total testing images: {len(test_generator.file_names)}")

```

SVM Modelinin Başarım Metrikleri

SVM Results:
Accuracy: 0.6000
MAE: 0.5289
Classification Report:

	precision	recall	f1-score	support
Benign	0.54	0.47	0.51	150
Malignant	0.58	0.71	0.63	150
Normal	0.69	0.62	0.65	150
accuracy			0.60	450
macro avg	0.60	0.60	0.60	450
weighted avg	0.60	0.60	0.60	450

Confusion Matrix:
[[71 50 29]
[31 106 13]
[29 28 93]]
Training Time: 455.46 seconds

Decision Tree Modelinin Başarım Metrikleri

Decision Tree Results:
Accuracy: 0.6733
MAE: 0.5467
Classification Report:

	precision	recall	f1-score	support
Benign	0.56	0.55	0.55	150
Malignant	0.83	0.85	0.84	150
Normal	0.62	0.62	0.62	150
accuracy			0.67	450
macro avg	0.67	0.67	0.67	450
weighted avg	0.67	0.67	0.67	450

Confusion Matrix:
[[82 17 51]
[17 128 5]
[48 9 93]]
Training Time: 112.02 seconds

Random Forest Modelinin Başarım Metrikleri

Random Forest Results:
Accuracy: 0.9333
MAE: 0.1333
Classification Report:

	precision	recall	f1-score	support
Benign	0.91	0.89	0.90	150
Malignant	1.00	1.00	1.00	150
Normal	0.89	0.91	0.90	150
accuracy			0.93	450
macro avg	0.93	0.93	0.93	450
weighted avg	0.93	0.93	0.93	450

Confusion Matrix:
[[134 0 16]
[0 150 0]
[14 0 136]]
Training Time: 21.20 seconds

Xgboost Modelinin Sonuçları

```
XGBoost Results:
Accuracy: 0.9489
MAE: 0.1000
Classification Report:
      precision    recall  f1-score   support

   Benign      0.93      0.91      0.92      150
  Malignant    0.99      1.00      1.00      150
   Normal     0.92      0.93      0.93      150

 accuracy            0.95      450
 macro avg           0.95      450
 weighted avg        0.95      450

Confusion Matrix:
[[137  1 12]
 [ 0 150  0]
 [ 10  0 140]]
Training Time: 501.66 seconds
```

Bu çalışmada, akciğer kanseri görüntülerini sınıflandırmak için SVM, Karar Ağacı, Random Forest ve XGBoost modelleri kullanılarak performans değerlendirilmesi yapılmıştır. Modellerin doğruluk (accuracy) ve ortalama mutlak hata (MAE) değerleri arasında belirgin farklılıklar gözlemlenmiştir. SVM modeli %60 doğruluk ve 0.5289 MAE ile en düşük performansı sergilerken, Karar Ağacı modeli %67.33 doğruluk ve 0.5467 MAE ile SVM'den daha iyi bir performans göstermiştir. Random Forest modeli %93.33 doğruluk ve 0.1333 MAE ile oldukça yüksek bir başarı elde etmiş, bu da modelin genelleme yeteneğini göstermektedir. XGBoost modeli ise %94.89 doğruluk ve 0.1000 MAE ile en iyi performansı sunmuş ve sınıflandırma görevinde üstünlüğünü kanıtlamıştır. Modellerin başarı oranları ve hata değerleri aşağıdaki Tablo 4'te özetlenmiştir:

Tablo 4. Modellerin başarımlarının karşılaştırılması

Model	Accuracy (%)	MAE
SVM	60.00	0.5289
Decision Tree	67.33	0.5467
Random Forest	93.33	0.1333
XGBoost	94.89	0.1000

Aşağıda tüm modellerin detaylı sonuçlarını içeren bir tablo verilmiştir. Tablo5 , her modelin doğruluk (accuracy), ortalama mutlak hata (MAE), precision, recall, F1-score değerlerini ve destek (support) sayısını kapsamaktadır. Bu tablo, modellerin genel performansını ve sınıflandırma yeteneklerini özetlemektedir. Özellikle Random Forest ve XGBoost, diğer modellere göre daha yüksek doğruluk ve daha düşük hata oranıyla akciğer kanseri sınıflandırmasında başarılı sonuçlar elde etmiştir.

Tablo 5. Modellerin her bir sınıfa ait detaylı başarımların karşılaştırılması

Model	Accuracy (%)	MAE	Precision (Macro Avg)	Recall (Macro Avg)	F1-Score (Macro Avg)	Benign Support	Malignant Support	Normal Support
SVM	60.00	0.5289	0.60	0.60	0.60	150	150	150
Decision Tree	67.33	0.5467	0.67	0.67	0.67	150	150	150
Random Forest	93.33	0.1333	0.93	0.93	0.93	150	150	150
XGBoost	94.89	0.1000	0.95	0.95	0.95	150	150	150

5.4 Meme Kanserinin Teşhisi için Uygulama

Meme kanseri, meme dokusundaki hücrelerin kontrolsüz bir şekilde büyümesi sonucu oluşan bir kanser türüdür. Genellikle süt kanalları (duktal kanser) veya süt bezleri (lobüler kanser) gibi meme dokularında başlar. Meme kanseri kadınlarda en sık görülen kanser türüdür ve dünya genelinde kanser kaynaklı ölümlerin önemli bir kısmını oluşturur. Ancak, erkeklerde de nadiren görülebilmektedir.

Meme kanseri, başlangıç bölgesi ve hücre tipine bağlı olarak çeşitli alt tiplere ayrılır:

1. Duktal Karsinom: Süt kanallarında başlayan en yaygın meme kanseri türüdür.
 - o Duktal Karsinoma in Situ (DCIS): Kanser hücreleri süt kanallarında sınırlıdır, henüz çevre dokulara yayılmamıştır.
 - o İnvaziv Duktal Karsinom (IDC): Kanser hücreleri süt kanallarından çıkarak çevre dokulara yayılmıştır.
2. Lobüler Karsinom: Süt bezlerinde (lobüllerde) başlayan kanser türüdür.
 - o Lobüler Karsinoma in Situ (LCIS): Kanser hücreleri lobüllerde sınırlıdır ve henüz invaziv değildir.
 - o İnvaziv Lobüler Karsinom (ILC): Kanser hücreleri lobüllerden çıkarak çevre dokulara yayılmıştır.
3. İnflamatuvar Meme Kanseri: Nadir fakat agresif bir türdür. Meme derisinde kızarıklık ve şişlik gibi belirtilerle kendini gösterir.
4. Paget Hastalığı: Meme ucunda başlayarak yayılım gösteren nadir bir meme kanseri türüdür.
5. Üçlü Negatif Meme Kanseri: Hormon reseptörleri (östrojen, progesteron) ve HER2 proteinine sahip olmayan agresif bir kanser türüdür.

Bu çalışmada kullanılan meme kanseri veri seti, üç sınıfa ayrılmıştır:


1. Benign: İyi huylu tümörleri ifade eder.
2. Malignant: Kötü huylu ve genellikle kanserli hücrelerden oluşan tümörleri temsil eder.
3. Normal: Sağlıklı meme dokusunu ifade eder.

Veri setinin orijinal dağılımında sınıflar arasında dengesizlik gözlemlenmiştir. Örneğin, Benign sınıfı 891 görüntüye sahipken, Malignant sınıfı 421 ve Normal sınıfı sadece 266 görüntü içermektedir. Eğitim aşamasında 1260 görüntü kullanılırken test aşamasında toplam 318 görüntü kullanılmıştır. Tablo 6’da veri setine ait benign, malignant ve normal sınıfına ait görüntüler verilmiştir.

Tablo 6. Meme kanseri veri seti her bir sınıfa ait görüntü sayıları

Sınıflar	Orijinal	Eğitim	Test	Toplam Eğitim ve Test Verisi
Benign	891	712	179	Tüm Veri Seti: 1578 Eğitim: 1260 Test: 318
Malignant	421	336	85	
Normal	266	212	54	

Şekil 7’de meme kanseri veri setine ait görüntülerden örnekler gösterilmektedir.



Şekil 7. Meme kanseri veri setindeki sınıflara ait örnek görüntüler.

Geleneksel derin öğrenme modellerine kıyasla, Transformers tabanlı modeller, görüntü verilerinde daha üstün performans sergileyerek sınıflandırma görevlerinde yaygın bir şekilde kullanılmaktadır. Bu çalışmada, dört farklı transformers modeli kullanılarak meme kanseri sınıflandırması yapılacaktır:

1. Vision Transformer (ViT): Transformer mimarisini görüntü verileri için optimize eden bir modeldir. Görüntüleri, küçük parçalara (patch) ayırarak her bir parçayı birer girdi olarak işler. ViT, özellikle büyük veri setleri üzerinde etkili sonuçlar elde eder.
2. CaiT (Class-Attention in Image Transformers): ViT'nin bir varyasyonu olan CaiT, sınıf odaklı dikkat mekanizmalarını kullanarak sınıflandırma görevlerinde performansı artırmayı hedefler. Özellikle büyük boyutlu ve kompleks veri setlerinde etkili bir modeldir.
3. DeiT (Data-Efficient Image Transformer): ViT'nin daha veri verimli bir versiyonudur. Küçük veri setlerinde daha yüksek performans göstermek amacıyla tasarlanmıştır ve veri artırma stratejilerini etkili bir şekilde kullanır.
4. PiT (Pooling-based Image Transformer): Görüntü üzerinde havuzlama (pooling) yöntemini uygulayan bir modeldir. Havuzlama, bilgi kaybını minimuma indirerek özellik çıkarımı sürecinde etkinlik sağlar ve sınıflandırma doğruluğunu artırır.

Bu çalışmada, yukarıda belirtilen transformers modelleri kullanılarak meme kanseri sınıfları arasında etkili bir sınıflandırma gerçekleştirilmesi hedeflenmiştir. Eğitim ve test aşamalarında kullanılan veri seti ile modellerin performansı, doğruluk (accuracy), precision, recall, F1 skoru ve hata oranı gibi ölçütlerle değerlendirilecektir. Çalışma, transformers tabanlı modellerin tıbbi görüntüleme alanındaki potansiyelini göstermeyi ve meme kanseri teşhisinde daha etkili çözümler sunmayı amaçlamaktadır.

CaiT Modelinin Başarım Metrikleri

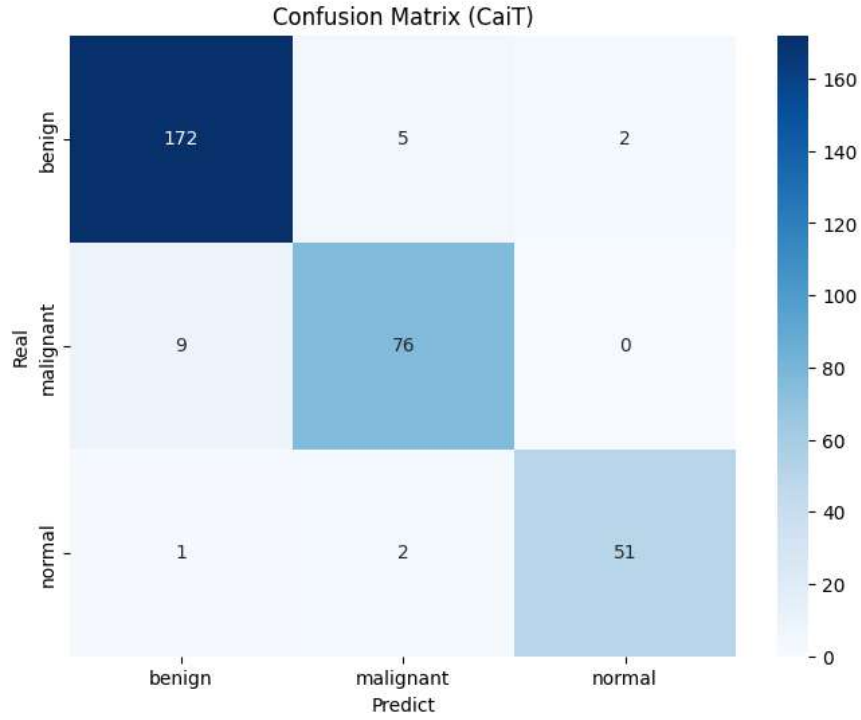
Classification Report:				
	precision	recall	f1-score	support
benign	0.9451	0.9609	0.9529	179
malignant	0.9157	0.8941	0.9048	85
normal	0.9623	0.9444	0.9533	54
accuracy			0.9403	318
macro avg	0.9410	0.9332	0.9370	318
weighted avg	0.9401	0.9403	0.9401	318

AUC-ROC: 0.9917

AUC-PR: 0.9872

Mean Absolute Error (MAE): 0.0692

Toplam çalışma süresi: 315.40 saniye

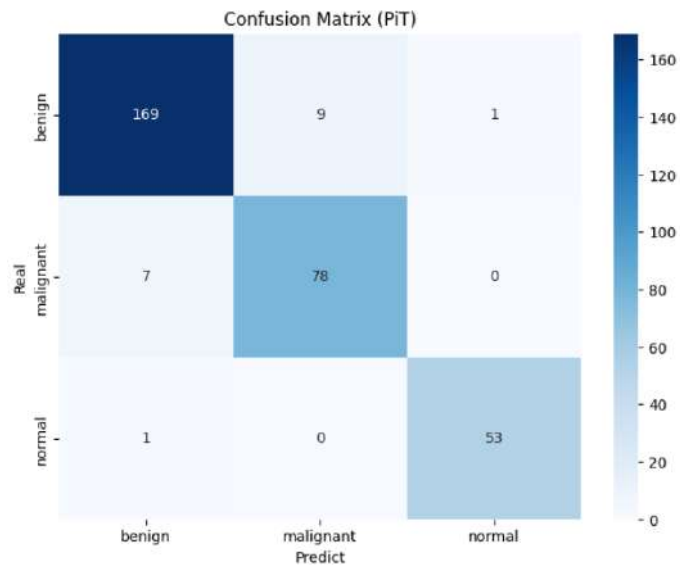


PiT Modelinin Başarım Metrikleri

Classification Report:

	precision	recall	f1-score	support
benign	0.9548	0.9441	0.9494	179
malignant	0.8966	0.9176	0.9070	85
normal	0.9815	0.9815	0.9815	54
accuracy			0.9434	318
macro avg	0.9443	0.9478	0.9460	318
weighted avg	0.9438	0.9434	0.9435	318

AUC-ROC: 0.9941
AUC-PR: 0.9898
Mean Absolute Error (MAE): 0.0629
Toplam çalışma süresi: 295.08 saniye




DeiT Modelinin Başarım Metrikleri

Classification Report:

	precision	recall	f1-score	support
benign	0.9451	0.9609	0.9529	179
malignant	0.9375	0.8824	0.9091	85
normal	0.9464	0.9815	0.9636	54
accuracy			0.9434	318
macro avg	0.9430	0.9416	0.9419	318
weighted avg	0.9433	0.9434	0.9430	318

AUC-ROC: 0.9912
AUC-PR: 0.9858
Mean Absolute Error (MAE): 0.0660
Toplam çalışma süresi: 312.66 saniye

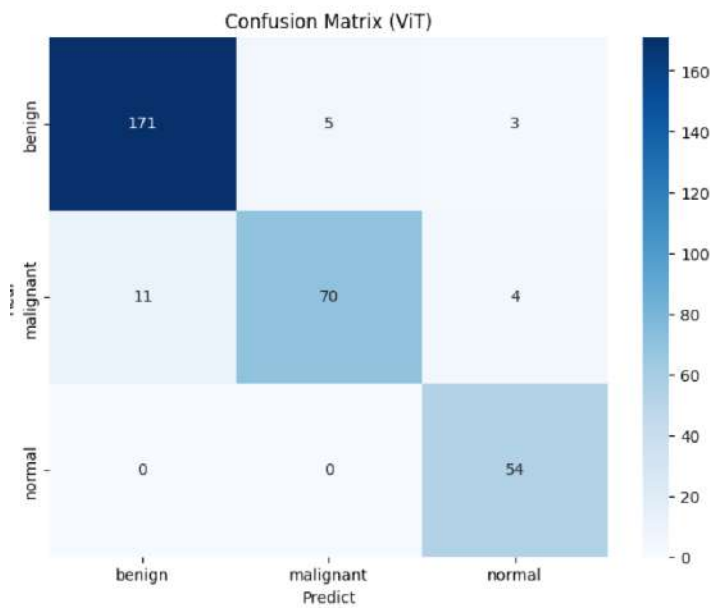


ViT Modelinin Başarım Metrikleri

Classification Report:

	precision	recall	f1-score	support
benign	0.9396	0.9553	0.9474	179
malignant	0.9333	0.8235	0.8750	85
normal	0.8852	1.0000	0.9391	54
accuracy			0.9277	318
macro avg	0.9194	0.9263	0.9205	318
weighted avg	0.9287	0.9277	0.9266	318

AUC-ROC: 0.9910
AUC-PR: 0.9849
Mean Absolute Error (MAE): 0.0818
Toplam çalışma süresi: 309.56 saniye



Dört farklı Transformer modeli (CaiT, PiT, DeiT, ViT) meme kanseri sınıflandırma problemini çözmek için test edilmiştir. Modellerin sonuçları, precision, recall, f1-score, AUC-ROC, AUC-PR, MAE, ve toplam çalışma süresi açısından analiz edilmiştir. Sonuçlar, modellerin her bir sınıfta farklı performanslar sergilediğini ve genel doğruluklarının oldukça yüksek olduğunu göstermektedir. Aşağıdaki Tablo 7’de, tüm metrikleri detaylı şekilde özetlemektedir:

Tablo 7. modellerin karşılaştırmalı performans değerleri

Model	Accuracy	Precision (avg)	Recall (avg)	F1-Score (avg)	AUC-ROC	AUC-PR	MAE	Çalışma Süresi (s)
CaiT	0.9403	0.9401	0.9403	0.9401	0.9917	0.9872	0.0692	315.40
PiT	0.9434	0.9438	0.9434	0.9435	0.9941	0.9898	0.0629	295.08
DeiT	0.9434	0.9433	0.9434	0.9430	0.9912	0.9858	0.0660	312.66
ViT	0.9277	0.9287	0.9277	0.9266	0.9910	0.9849	0.0818	309.56

Yapılan değerlendirmeler sonucunda, dört farklı Transformer modeli (CaiT, PiT, DeiT, ViT) meme kanseri sınıflandırmasında çeşitli başarı seviyeleri göstermiştir. PiT modeli, doğruluk (%94.34), F1-Skoru (%94.35), AUC-ROC (%99.41), ve AUC-PR (%98.98) gibi kritik metriklerde en iyi performansı sergileyerek en başarılı model olarak öne çıkmıştır. Ayrıca, PiT modelinin ortalama hata oranı (MAE: 0.0629) diğer modellere kıyasla en düşük değerdedir, bu da daha az tahmin hatası yapıldığını ifade etmektedir. Çalışma süresi açısından da PiT modeli, 295.08 saniye ile en hızlı performansı göstermiştir. Bu sonuçlar, PiT modelinin özellikle hassas uygulamalarda ve zaman kritik görevlerde tercih edilebilir olduğunu ortaya koymaktadır.

CaiT ve DeiT modelleri, PiT modeline oldukça yakın sonuçlar elde etmiş ve genel doğruluk (%94.03 ve %94.34) ile F1-Skoru (%94.01 ve %94.30) açısından başarılı bir performans sergilemiştir. DeiT modeli, normal sınıfta en yüksek geri çağırma oranını (%98.15) sağlayarak bu sınıfı doğru bir şekilde

ayrıt etmede öne çıkmıştır. CaiT modeli ise 0.0692 MAE değeri ile tahmin hatasını sınırlandırmayı başarmış ve bu anlamda güvenilir bir alternatif olabileceğini göstermiştir. Her iki model de hem hassasiyet hem de geri çağırma değerleri açısından dengeli sonuçlar sunarak uygulamada kullanılabilir modeller arasında yer almıştır. ViT modeli, diğer modellere göre biraz daha düşük bir doğruluk (%92.77) sergilemiş olsa da normal sınıf için %100 geri çağırma oranına ulaşarak bu sınıfta mükemmel bir performans göstermiştir. Ancak, toplam hata oranı (MAE: 0.0818) diğer modellere göre daha yüksek olup, tahmin hatalarının biraz daha fazla olduğunu ortaya koymaktadır. Bununla birlikte, ViT modelinin belirli sınıflarda üstün bir performans sergilediği ve normal sınıfı doğru tespit etme yeteneğiyle öne çıktığı görülmüştür. Sonuç olarak, bu çalışma, meme kanseri sınıflandırmasında farklı Transformer modellerinin performanslarını kapsamlı bir şekilde karşılaştırmıştır. PiT modeli, genel başarıyı ve düşük hata oranı ile en iyi sonuçları sunarken, CaiT ve DeiT modelleri de PiT modeline yakın performanslarıyla etkili alternatiflerdir. ViT modeli ise belirli sınıflarda mükemmel performans göstermesine rağmen genel doğruluk açısından biraz daha geride kalmıştır. Model seçimi, uygulamanın ihtiyaçlarına ve öncelik verilen metriklerle bağlı olarak yapılabilir.

5.5 Deri Kanseri Teşhisi Uygulamaları

Deri kanseri, cilt hücrelerinin anormal bir şekilde büyümesi sonucu oluşan ve dünya genelinde en sık görülen kanser türlerinden biridir. Genellikle güneşin zararlı ultraviyole (UV) ışınlarına uzun süre maruz kalma, deri kanserinin temel nedenlerinden biridir. Ancak, cildin güneş görmeyen bölgelerinde de oluşabileceği unutulmamalıdır. Deri kanseri, erken teşhis edildiğinde genellikle tedavi edilebilir bir hastalıktır ve bu nedenle erken tanı hayati öneme sahiptir. Deri kanserinin en yaygın üç türü; bazal hücreli karsinom, skuamöz hücreli karsinom ve melanomdur. Bazal hücreli karsinom, genellikle güneşe maruz kalan bölgelerde görülürken, skuamöz hücreli karsinom cildin daha derin katmanlarını etkileyebilir. Melanom ise en tehlikeli deri kanseri türü olup, hızlı bir şekilde metastaz yapma potansiyeline sahiptir.

Deri kanserinin teşhisi için dermatoskopi ve biyopsi gibi yöntemler yaygın olarak kullanılmaktadır. Kanserin tipi ve yayılımına göre cerrahi müdahale, radyoterapi, kemoterapi, immünoterapi veya hedefe yönelik tedavi gibi farklı tedavi yöntemleri uygulanabilir. Ayrıca, düzenli cilt kontrolleri ve koruyucu önlemler almak, deri kanserinin önlenmesinde büyük önem taşır. Güneşten korunmak için güneş kremi kullanımı, koruyucu giysiler giyme ve solaryumdan kaçınma gibi basit tedbirler, deri kanseri riskini önemli ölçüde azaltabilir. Sonuç olarak, erken teşhis ve etkili tedavi yaklaşımları sayesinde deri kanseriyle başarılı bir şekilde mücadele edilebilmektedir.

Deri hastalıkları veri seti, deri hastalıklarının sınıflandırılması amacıyla The International Skin Imaging Collaboration (ISIC) platformundan alınmış ve toplamda 2357 görüntüden oluşmaktadır. Veri seti, dermatolojik tanılarda kullanılan malign (kötü huylu) ve benign (iyi huylu) deri hastalıklarını içermektedir. Tüm görüntüler, ISIC tarafından sağlanan sınıflandırmaya uygun olarak etiketlenmiş ve veri setindeki her alt grup, melanom (malign) ve nevüs (benign) gibi bazı hastalıkların görüntü sayısındaki az bir baskınlık dışında, eşit sayıda görüntü içerecek şekilde düzenlenmiştir.

Veri seti, deri kanserleri ve diğer deri rahatsızlıklarını kapsayan toplam dokuz farklı hastalık sınıfını içermektedir. Bu sınıflar aşağıdaki gibidir:

Actinic Keratosis (Aktinik Keratoz):

- Güneşin UV ışınlarının neden olduğu ciltteki hücresel değişikliklerden oluşur. Tedavi edilmediğinde maligniteye dönüşme riski taşır.

Basal Cell Carcinoma (Bazal Hücreli Karsinom):

- Derinin en sık görülen kanseri olup, genellikle yüz ve boyun gibi güneş ışığına maruz kalan bölgelerde görülür. Yavaş büyüme eğilimi gösterir ve nadiren metastaz yapar.

Dermatofibroma:

- Genellikle zararsız olan ve deri altında gelişen küçük, yuvarlak, sert bir nodül şeklinde ortaya çıkar. Daha çok bacaklarda görülür.

Melanoma (Melanom):

- En ölümcül deri kanseri türüdür. Melanositlerden kaynaklanır ve erken teşhis edilmediğinde hızla yayılabilir.

Nevus (Benign):

- Genellikle zararsız olan cilt üzerindeki koyu renkli benlerdir. Çoğu doğuştan gelir veya zamanla ortaya çıkar.

Pigmented Benign Keratosis (Pigmente Benign Keratoz):

- Genellikle yaşlanmaya bağlı olarak gelişen, koyu renkli ve iyi huylu deri lezyonlarıdır.

Seborrheic Keratosis (Seboreik Keratoz):

- Yaşlı insanlarda sıkça görülen, genellikle yağlı bir görünüm sergileyen iyi huylu deri lezyonlarıdır.

Squamous Cell Carcinoma (Skvamöz Hücreli Karsinom):

- Ciltte ikinci en sık görülen kanser türüdür. Güneşe maruz kalan alanlarda görülür ve metastaz riski taşır.

Vascular Lesion (Vasküler Lezyon):

- Kan damarlarının anormal büyümesinden kaynaklanan deri üzerindeki kırmızı veya mor renkli lezyonlardır.

Tablo 8'de deri kanseri hastalıklarının sınıflarına ait görüntü sayıları verilmiştir.

Tablo 8. Deri kanseri veri seti

Sınıflar	Orijinal	Eğitim	Test	Toplam Eğitim ve Test Verisi
Akiec	327	262	65	Tüm Veri Seti: 5810 Eğitim: 4648 Test: 1162
bcc	514	411	103	
bkl	1099	879	220	
df	115	92	23	
mel	1113	890	223	
nv	2500	2000	500	
vasc	142	114	28	

Şekil 8’te deri kanseri veri setine ait örnek görüntüler verilmiştir.



Actinic keratosis and intraepithelial carcinoma / Bowen's disease (akiec)



basal cell carcinoma (bcc)




benign keratosis-like lesions (solar lentigines / seborrheic keratosis and lichen-planus, bkl)



dermatofibroma (df)



melanoma (mel)



Şekil 8. Deri kanseri veri setine ait örnek görüntüler

Deri kanseri sınıflandırma çalışmasında SimpleCNN, DenseNet201 ve NasNetMobile olmak üzere üç farklı derin öğrenme modeli kullanılmıştır. Bu modeller, akiec, bcc, bkl, df, mel, nv, vasc olmak üzere toplam 7 farklı deri hastalığı sınıfını sınıflandırmak için eğitilmiş ve değerlendirilmiştir. Sonuçlar, precision (kesinlik), recall (duyarlılık), F1-score ve accuracy gibi performans ölçütleri ile analiz edilmiştir. Her bir modelin mimarisi ve özellikleri, farklı karmaşıklık seviyelerinde görüntü sınıflandırma performansı sunmaktadır.

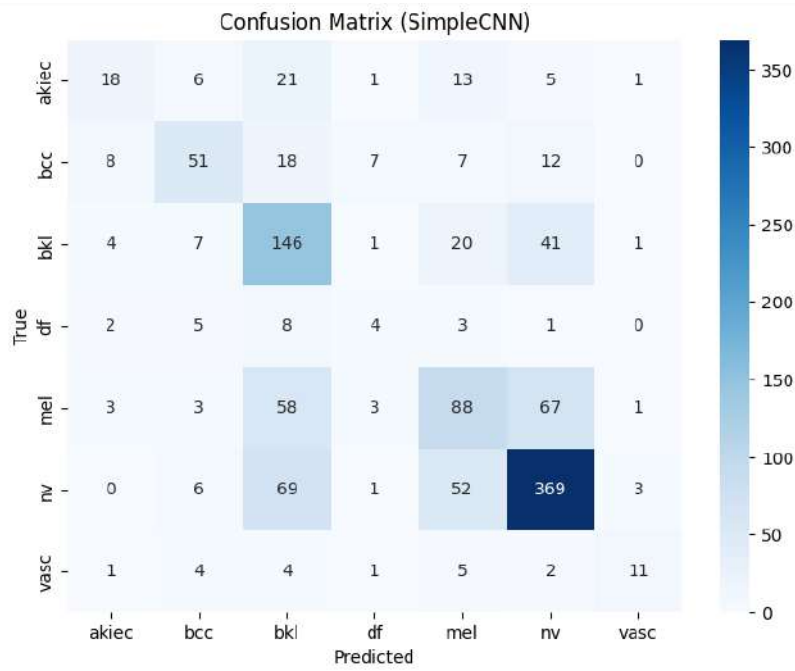
SimpleCNN (Convolutional Neural Network), derin öğrenmede yaygın olarak kullanılan temel bir modeldir. Bu model, genellikle küçük ölçekli veri setlerinde hızlı ve basit bir şekilde eğitim sağlasa da karmaşık veri setlerinde sınırlı performans göstermektedir. SimpleCNN, katman sayısının daha az olması ve özellik çıkarma yeteneğinin sınırlı olması nedeniyle detaylı sınıf ayrımı gerektiren verilerde düşük başarı göstermektedir. Bu çalışmada nv sınıfında daha iyi sonuçlar elde etmesine rağmen, küçük sınıflardaki performansı yetersiz kalmıştır. DenseNet201 (Densely Connected Convolutional Networks) ise daha derin ve bağlantılı bir mimari sunarak, modelin özellik çıkarma kapasitesini önemli ölçüde artırmaktadır. Her katmanın önceki katmanlardan gelen girdilere bağlı olması, bilgiyi kaybetmeden daha zengin özelliklerin çıkarılmasını sağlar. Bu yapı, özellikle karmaşık ve dengesiz veri setlerinde etkili sonuçlar üretmektedir. DenseNet201, bu çalışmada tüm sınıflarda tutarlı ve yüksek performans göstermiş, özellikle küçük veri örneklerine sahip olan df ve vasc sınıflarında bile başarılı sonuçlar elde etmiştir. NasNetMobile (Neural Architecture Search Network), mobil cihazlar için optimize edilmiş bir model olup düşük hesaplama maliyetiyle çalışabilmesi için tasarlanmıştır. Bu model, Google tarafından geliştirilen otomatik mimari arama yöntemleriyle elde edilen optimize edilmiş bir yapıya sahiptir. Ancak, bazı sınıflarda özellikle küçük ve dengesiz veri örnekleri üzerinde performans düşüklükleri gözlemlenmiştir. bkl sınıfında düşük recall değeri, modelin bu tür detaylı sınıf ayrımlarında zorlandığını göstermektedir. Bununla birlikte, büyük veri setlerinde, örneğin nv sınıfında, daha iyi sonuçlar elde edebilmiştir.

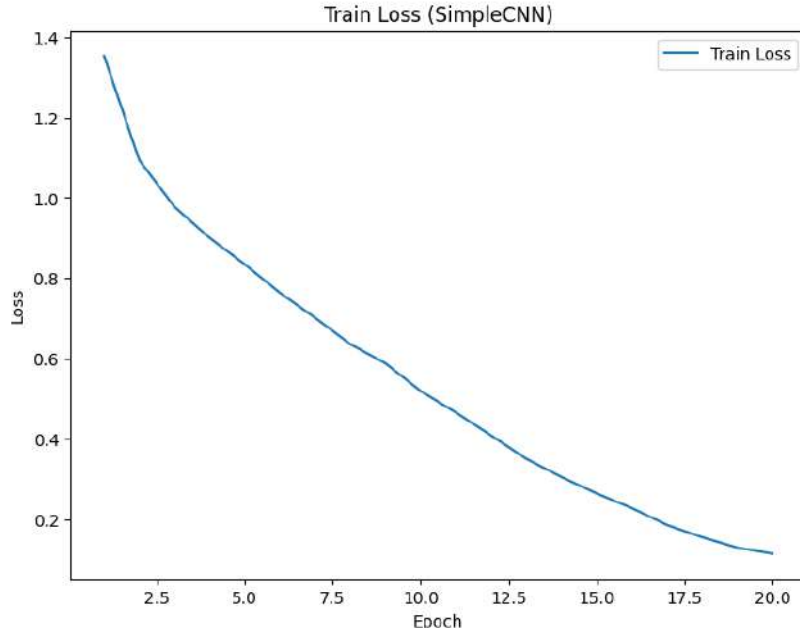
Sonuç olarak, DenseNet201 modeli karmaşık sınıflarda ve dengesiz veri setlerinde daha yüksek performans gösterirken, SimpleCNN temel bir model olarak yalnızca büyük veri örneklerinde sınırlı başarı sağlayabilmiştir. NasNetMobile ise hafif ve hızlı bir model olmasına rağmen küçük sınıflarda tutarlılık sağlayamamış ve karmaşık sınıflandırma görevlerinde beklenen performansı sergileyememiştir.

Simple CNN Modelinin Sonuçları

Classification Report for SimpleCNN:

	precision	recall	f1-score	support
akiec	0.5000	0.2769	0.3564	65
bcc	0.6220	0.4951	0.5514	103
bkl	0.4506	0.6636	0.5368	220
df	0.2222	0.1739	0.1951	23
mel	0.4681	0.3946	0.4282	223
nv	0.7425	0.7380	0.7402	500
vasc	0.6471	0.3929	0.4889	28
accuracy			0.5912	1162
macro avg	0.5218	0.4479	0.4710	1162
weighted avg	0.5977	0.5912	0.5868	1162







DenseNet201 Modelinin Sonuçları

Classification Report for DenseNet201:

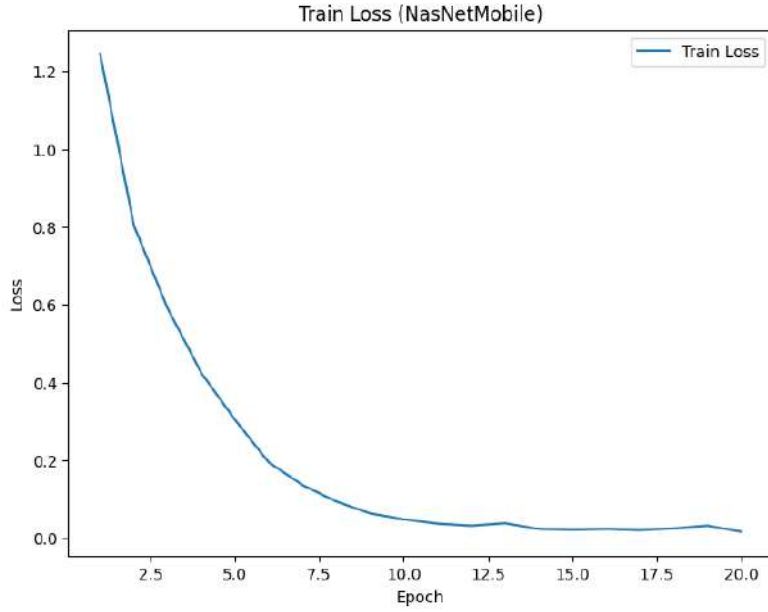
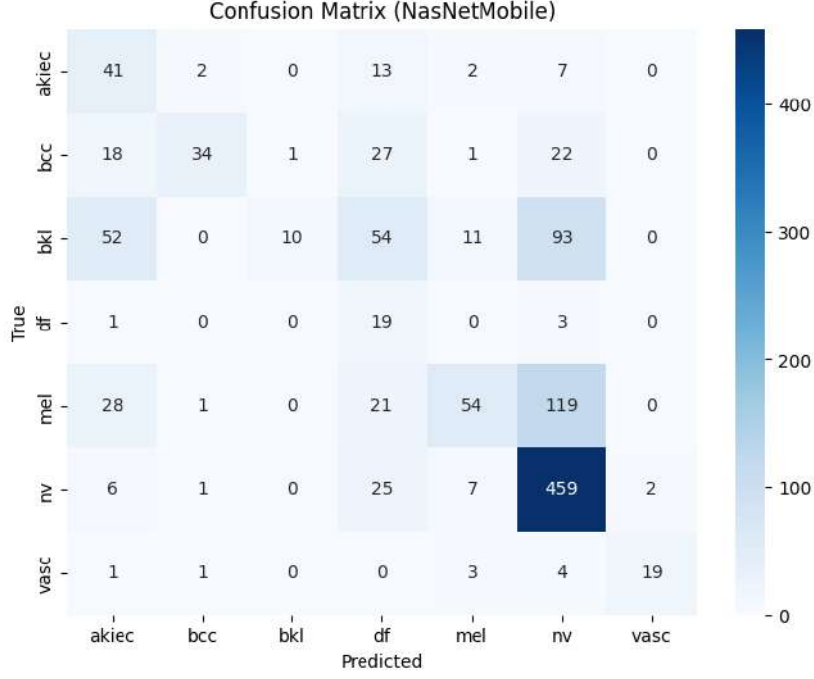
	precision	recall	f1-score	support
akiec	0.7593	0.6308	0.6891	65
bcc	0.7961	0.7961	0.7961	103
bkl	0.7313	0.7545	0.7427	220
df	0.8889	0.6957	0.7805	23
mel	0.7248	0.7085	0.7166	223
nv	0.8687	0.9000	0.8841	500
vasc	1.0000	0.8571	0.9231	28
accuracy			0.8064	1162
macro avg	0.8241	0.7632	0.7903	1162
weighted avg	0.8061	0.8064	0.8054	1162



NasNetMobile Modelinin Sonuçları

Classification Report for NasNetMobile:

	precision	recall	f1-score	support
akiec	0.2789	0.6308	0.3868	65
bcc	0.8718	0.3301	0.4789	103
bkl	0.9091	0.0455	0.0866	220
df	0.1195	0.8261	0.2088	23
mel	0.6923	0.2422	0.3588	223
nv	0.6492	0.9180	0.7606	500
vasc	0.9048	0.6786	0.7755	28
accuracy			0.5473	1162
macro avg	0.6322	0.5244	0.4366	1162
weighted avg	0.7014	0.5473	0.4994	1162



Bu çalışmada deri kanseri sınıflandırması için SimpleCNN, DenseNet201 ve NasNetMobile modellerinin performans karşılaştırması yapılmıştır. Sonuçlar incelendiğinde, DenseNet201 modelinin genel olarak en yüksek başarıyı sağladığı görülmektedir. Özellikle küçük veri setine sahip sınıflarda dahi güçlü sonuçlar elde etmiş ve toplam doğruluk oranı %80.64 olarak hesaplanmıştır. Bu modelin f1-score ve recall değerleri, özellikle df (dermatofibroma) ve vasc (vasküler lezyon) sınıflarında diğer modellere kıyasla üstün performans göstermiştir. Ayrıca nv (nevüs) gibi büyük veri örneklerinde de yüksek doğruluk sağlamıştır.

SimpleCNN modeli ise temel bir yapı sunmasına rağmen, karmaşık sınıflar arasındaki ayrımı sağlamakta zorlanmıştır. Özellikle küçük veri setine sahip sınıflarda, akiec ve df gibi, düşük recall ve

f1-score değerleriyle performans kaybı gözlemlenmiştir. Modelin toplam doğruluk oranı %59.12 olup, bu sonuç DenseNet201 ve NasNetMobile modellerinin oldukça gerisindedir. Ancak nv sınıfında, veri örneklerinin sayısının fazla olması nedeniyle bu model nispeten daha iyi sonuçlar verebilmiştir.

NasNetMobile modeli ise özellikle df ve bcc sınıflarında dikkat çekici bir şekilde dengesiz performans göstermiştir. Bazı sınıflarda yüksek recall değerlerine ulaşırken, bkl (benign keratoz) sınıfında oldukça düşük değerler elde etmiştir. Toplam doğruluk oranı %54.73 olarak hesaplanmış ve bu durum, modelin küçük ve dengesiz sınıflardaki başarısızlığını göstermektedir. Bununla birlikte, nv sınıfında yüksek recall ve f1-score değerleri ile güçlü performans sergilemiştir.

Sonuç olarak, performans değerlendirmelerinde DenseNet201 modeli, sınıflar arasındaki tutarlı performansı, yüksek doğruluk oranı (%80.64) ve güçlü f1-score değerleri ile en başarılı model olarak öne çıkmaktadır. NasNetMobile modeli büyük sınıflarda kabul edilebilir sonuçlar sağlasa da küçük sınıflarda tutarlılık sağlayamamış, SimpleCNN ise en temel model olarak karmaşık sınıfları ayırt etmede en düşük performansı göstermiştir. Tablo 9'da karşılaştırmalı sonuçlar verilmiştir.

Tablo 9. Modellerin karşılaştırmalı sonuçları

Model	Accuracy	Precision (Macro Avg)	Recall (Macro Avg)	F1-Score (Macro Avg)
SimpleCNN	59.12%	52.18%	44.79%	47.10%
DenseNet201	80.64%	82.41%	76.32%	79.03%
NasNetMobile	54.73%	63.22%	52.44%	43.66%

5.6 Kan Kanseri Teşhisi ve Uygulamaları

Kan kanseri, kan hücrelerinin anormal şekilde büyümesi ve kontrolsüz çoğalması ile ortaya çıkan bir hastalık grubudur. Temelde, kan kanseri kemik iliğinde bulunan kan yapıcı hücrelerin üretim mekanizmasındaki bozulmalardan kaynaklanır. Kan kanserleri genellikle lökositler (beyaz kan hücreleri) üzerinde etkili olur, ancak diğer kan hücrelerini de etkileyebilir.

Kan Kanseri Türleri

Kan kanserleri üç ana kategoriye ayrılır:

1. Lösemi:

Kemik iliğinde anormal beyaz kan hücrelerinin aşırı üretimi ile karakterizedir. Lösemi, akut (hızlı gelişen) ve kronik (yavaş gelişen) olmak üzere iki ana tipe ayrılır.

- Akut Lenfoblastik Lösemi (ALL)
- Akut Miyeloid Lösemi (AML)
- Kronik Lenfositik Lösemi (CLL)
- Kronik Miyeloid Lösemi (CML)

2. Lenfoma:

Lenf sistemi hücrelerinin anormal büyümesi ve çoğalması ile ortaya çıkar. Lenfomalar genellikle Hodgkin Lenfoma ve Hodgkin Dışı Lenfoma olmak üzere iki alt grupta incelenir.

3. Myeloma (Multiple Myeloma):

Plazma hücrelerinin anormal üretimi ile kemik iliğinde oluşur. Plazma hücrelerinin kontrolsüz büyümesi, bağışıklık sistemini zayıflatarak enfeksiyonlara karşı direnci azaltır.

Belirtiler

Kan kanserlerinin belirtileri hastalığın türüne bağlı olarak değişebilir, ancak yaygın belirtiler şunlardır:

- Aşırı yorgunluk ve halsizlik
- Ateş ve gece terlemeleri
- İştah kaybı ve kilo kaybı
- Kansızlık (anemi) ve ciltte solukluk
- Kolay morarma veya kanamalar
- Kemik ve eklem ağrıları

Veri Seti Hakkında Bilgi

Çalışmada kullanılan veri seti, kan kanseri görüntülerini içerir ve dört farklı sınıfa ayrılmıştır. Bu sınıflar, hücresel seviyede kan kanseri türlerinin belirlenmesini sağlar. Veri seti, kan kanseri türlerinin tespitine yönelik makine öğrenmesi ve derin öğrenme modelleriyle analiz edilmiştir. Özellikle hücresel detayların tespitinde EfficientNet B0 gibi güçlü özellik çıkarma yöntemleri kullanılmıştır.

Sınıflar

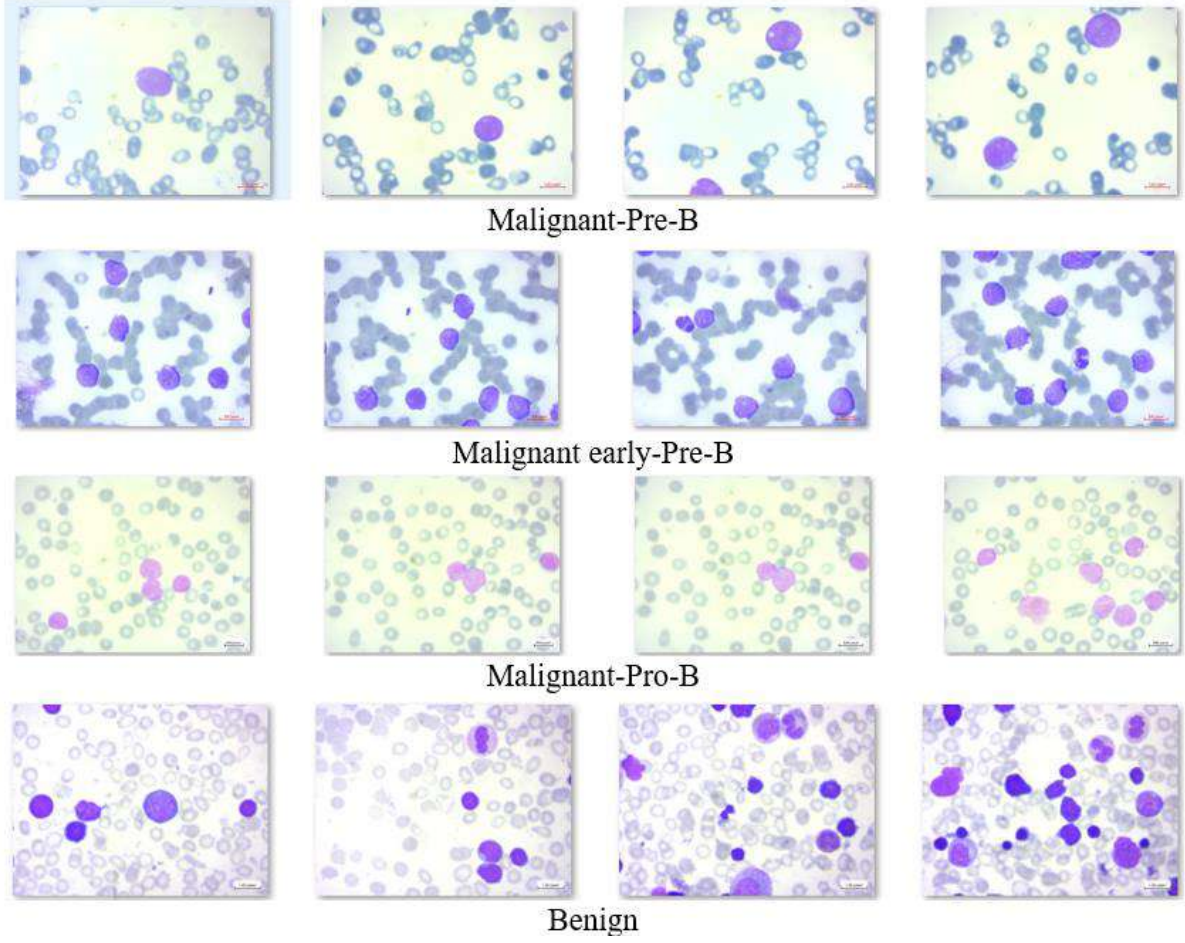
Veri setinde dört sınıf bulunmaktadır:

1. **Benign (İyi Huylu):** Hücresel büyüme normaldir ve kansere dönüşme riski yoktur.
2. **[Malignant] Pre-B:** Kanserleşme sürecinde olan öncül B hücreleriyle ilgili anormallikleri temsil eder.
3. **[Malignant] Pro-B:** İlerleyen malign kanser hücrelerinin bulunduğu aşamadır.
4. **[Malignant] early Pre-B:** Kanser hücrelerinin erken aşamada anormal şekilde çoğalmaya başladığı süreçtir.

Veri Seti Özellikleri

- **Toplam Görüntü Sayısı:** 650 adet görüntü
- **Eğitim/Test Ayrımı:** Veri seti %80 eğitim ve %20 test olarak ayrılmıştır.
 - **Eğitim Verisi:** 520 görüntü
 - **Test Verisi:** 130 görüntü
- **Sınıflara Göre Dağılım:**
 - Benign: 103 görüntü
 - Malignant Pre-B: 191 görüntü
 - Malignant Pro-B: 160 görüntü
 - Malignant Early Pre-B: 196 görüntü

Veri seti, kan hücrelerinin görüntü analizini kolaylaştırmak için homojenleştirilmiştir. Görüntüler belirli bir boyutta (örneğin 224x224 piksel) normalize edilmiş ve modele giriş için uygun hale getirilmiştir. Şekil 9'ta veri setindeki her bir sınıfa ait örnek görüntüler verilmiştir.



Şekil 9. Kan kanseri veri setine ait örnek görüntüler

Bu çalışmada, EfficientNet B0 modeli ile özellik çıkarma işlemi gerçekleştirilmiş ve bu özellikler kullanılarak SVM (Support Vector Machine), AdaBoost, CatBoost, ve Decision Tree sınıflandırıcıları ile kan kanseri türlerinin tespiti amaçlanmıştır. Dört farklı modelin performansı doğruluk, precision, recall, F1-score, Mean Absolute Error (MAE), ve Cohen's Kappa metriklerine göre karşılaştırılmıştır.

SVM Modelinin Sonuçları

```

Classification Report:

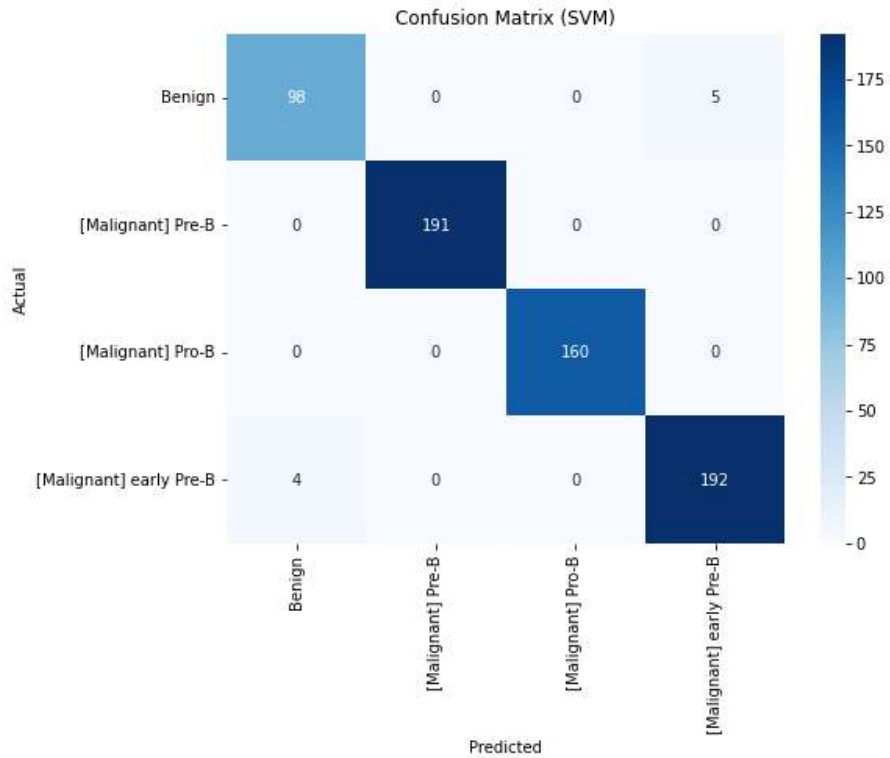

```

	precision	recall	f1-score	support
Benign	0.9608	0.9515	0.9561	103
[Malignant] Pre-B	1.0000	1.0000	1.0000	191
[Malignant] Pro-B	1.0000	1.0000	1.0000	160
[Malignant] early Pre-B	0.9746	0.9796	0.9771	196
accuracy			0.9862	650
macro avg	0.9839	0.9828	0.9833	650
weighted avg	0.9861	0.9862	0.9861	650

Mean Absolute Error (MAE): 0.0415

Cohen's Kappa: 0.9812

Train Accuracy: 0.9927, Test Accuracy: 0.9862



Catboost Modelinin Sonuçları

```

Classification Report:

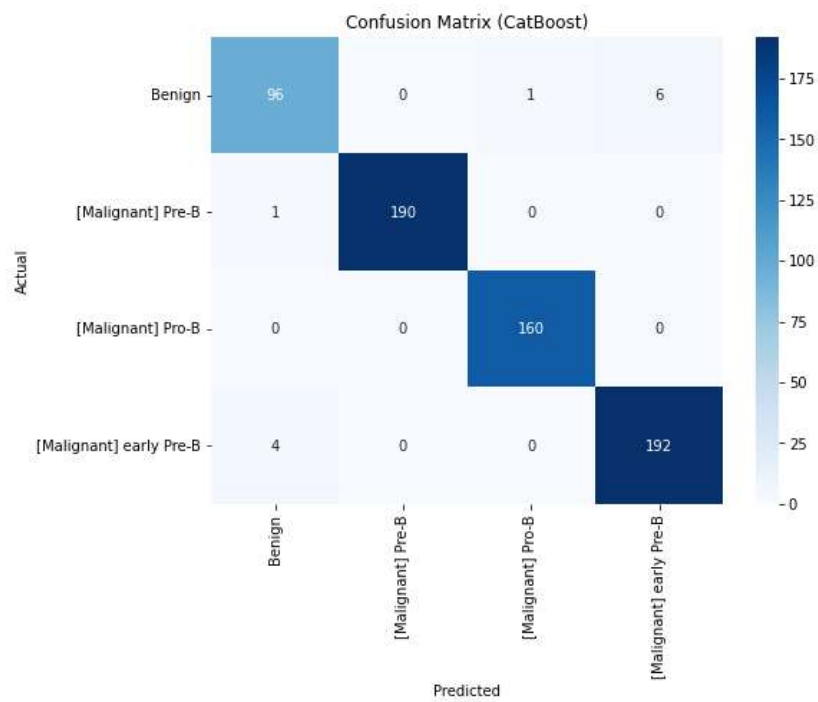

```

	precision	recall	f1-score	support
Benign	0.9505	0.9320	0.9412	103
[Malignant] Pre-B	1.0000	0.9948	0.9974	191
[Malignant] Pro-B	0.9938	1.0000	0.9969	160
[Malignant] early Pre-B	0.9697	0.9796	0.9746	196
accuracy			0.9815	650
macro avg	0.9785	0.9766	0.9775	650
weighted avg	0.9815	0.9815	0.9815	650

Mean Absolute Error (MAE): 0.0508

Cohen's Kappa: 0.9749

Train Accuracy: 1.0000, Test Accuracy: 0.9815



Adaboost Modelinin Sonuçları

```

Classification Report:

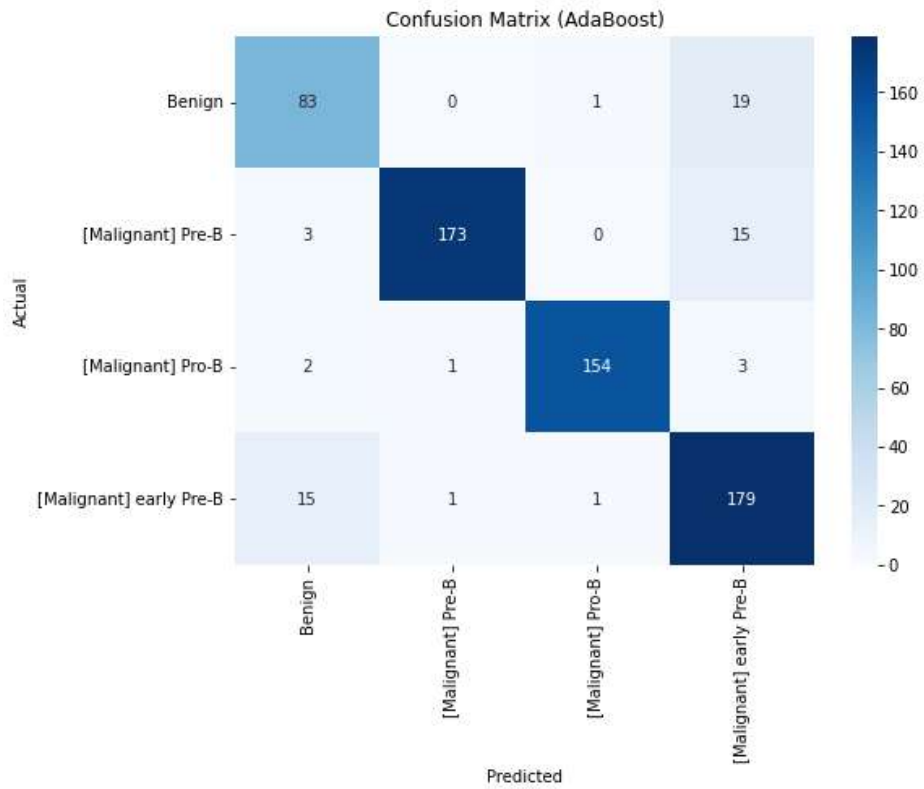

```

	precision	recall	f1-score	support
Benign	0.8058	0.8058	0.8058	103
[Malignant] Pre-B	0.9886	0.9058	0.9454	191
[Malignant] Pro-B	0.9872	0.9625	0.9747	160
[Malignant] early Pre-B	0.8287	0.9133	0.8689	196
accuracy			0.9062	650
macro avg	0.9026	0.8968	0.8987	650
weighted avg	0.9111	0.9062	0.9074	650

Mean Absolute Error (MAE): 0.2277

Cohen's Kappa: 0.8726

Train Accuracy: 0.9475, Test Accuracy: 0.9062



Decision Tree Modelinin Sonuçları

```

Classification Report:



```

	precision	recall	f1-score	support
Benign	0.7273	0.7767	0.7512	103
[Malignant] Pre-B	0.9459	0.9162	0.9309	191
[Malignant] Pro-B	0.9679	0.9437	0.9557	160
[Malignant] early Pre-B	0.8392	0.8520	0.8456	196
accuracy			0.8815	650
macro avg	0.8701	0.8722	0.8708	650
weighted avg	0.8845	0.8815	0.8828	650

Mean Absolute Error (MAE): 0.2846

Cohen's Kappa: 0.8395

Train Accuracy: 1.0000, Test Accuracy: 0.8815



SVM, ayrık sınıflar arasında optimal bir hiperdüzlem oluşturarak sınıflandırma yapan güçlü bir makine öğrenmesi algoritmasıdır. Çalışmamızda SVM modeli, sınıflandırma görevinde en yüksek doğruluğu sağlamıştır ve test doğruluğu %98.62 olarak hesaplanmıştır. Cohen's Kappa değeri 0.9812 gibi yüksek bir başarı göstermiştir. CatBoost, kategori tabanlı veri setleri üzerinde oldukça etkili olan bir gradient boosting algoritmasıdır. Eğitim süresi SVM'ye kıyasla uzun sürmüştür olsa da (%211.74 saniye), elde edilen performans son derece yüksektir. Test doğruluğu %98.15 olarak hesaplanmıştır. Precision ve recall değerleri sınıflar arasında oldukça dengelidir. Cohen's Kappa değeri 0.9749'dur. AdaBoost, zayıf sınıflandırıcıların iteratif olarak güçlendirilmesi ile çalışan bir ensemble modelidir. Bu modelde doğruluk değeri %90.62 olarak hesaplanmıştır. Diğer modellere göre performansı daha düşük olup, MAE (Mean Absolute Error) değeri 0.2277 olarak bulunmuştur. Özellikle "Benign" sınıfında hata oranı görece daha yüksektir. Decision Tree modeli, veriyi sınıflandırmak için ağaç yapısı kullanan bir algoritmadır. Eğitim süresi çok kısa olmasına rağmen (%1.93 saniye), test doğruluğu %88.15'te kalmıştır. Model, aşırı öğrenme (overfitting) sorunu yaşamış ve eğitim doğruluğu %100 olarak

gözlemlenmiştir. Cohen's Kappa değeri 0.8395 ile diğer modellere göre daha düşük bulunmuştur. Aşağıda dört modelin karşılaştırmalı performansını gösteren değerler Tablo 10'da verilmiştir:

Tablo 10. Modellerin karşılaştırmalı performans değerlendirilmesi

Model	Precision	Recall	F1-Score	Accuracy	MAE	Cohen's Kappa	Eğitim Süresi (s)
SVM	0.9839	0.9828	0.9833	98.62%	0.0415	0.9812	2.78
CatBoost	0.9785	0.9766	0.9775	98.15%	0.0508	0.9749	211.74
AdaBoost	0.9026	0.8968	0.8987	90.62%	0.2277	0.8726	55.15
Decision Tree	0.8701	0.8722	0.8708	88.15%	0.2846	0.8395	1.93

En Başarılı Model: SVM modeli %98.62 test doğruluğu, 0.9833 F1-Skoru ve 0.0415 MAE değeri ile en iyi performansı göstermiştir. Eğitim süresi kısa ve sonuçlar oldukça yüksek doğruluk seviyesinde elde edilmiştir. İkinci En İyi Model: CatBoost modeli %98.15 doğruluk ile SVM'ye çok yakın bir performans sergilemiştir. Ancak eğitim süresi oldukça uzundur. Orta Performanslı Model: AdaBoost, %90.62 doğrulukla orta düzeyde performans göstermektedir. Bu model, özellikle "Benign" sınıfında hataların arttığı gözlemlenmiştir. En Düşük Performans Gösteren Model: Decision Tree (DT), aşırı öğrenme problemi nedeniyle test doğruluğu düşük kalmış (%88.15), MAE değeri ise 0.2846 gibi yüksek bulunmuştur. EfficientNet B0 tarafından çıkarılan özellikler, sınıflandırma modelleri tarafından başarıyla kullanılmıştır. SVM ve CatBoost modelleri, diğer modellere kıyasla daha iyi sonuçlar elde etmiştir. Bu çalışma, hibrit modellemelerin kan kanseri sınıflandırma gibi kritik tıbbi görevlerde yüksek doğruluk sağlayabileceğini göstermektedir. Eğitim süreleri ve performans metrikleri birlikte değerlendirildiğinde, SVM modeli, kısa eğitim süresi ve yüksek doğruluğu sayesinde uygulama açısından en avantajlı model olarak öne çıkmaktadır.

5.7 KAYNAKÇA

- [1] T. Zeng *et al.*, “AI diagnostics in bone oncology for predicting bone metastasis in lung cancer patients using DenseNet-264 deep learning model and radiomics,” *J Bone Oncol*, vol. 48, p. 100640, Oct. 2024, doi: 10.1016/J.JBO.2024.100640.
- [2] M. Çakmak, “Heart Disease Classification Using Random Forest Machine Learning,” in *Sinop University, İzmir: 4 th International Artificial Intelligence and Data Science Congress*, Mar. 2024, pp. 232–239.
- [3] C. J. Ejyji *et al.*, “Advancing cancer diagnosis and prognostication through deep learning mastery in breast, colon, and lung histopathology with ResoMergeNet,” *Comput Biol Med*, vol. 185, p. 109494, Feb. 2025, doi: 10.1016/J.COMPBIOMED.2024.109494.
- [4] H. Kim, M. Lee, and H. J. Choi, “Improving treatment quality of gynecologic cancers with online adaptive brachytherapy using deep learning-based CT imaging,” *Nucl Instrum Methods Phys Res A*, vol. 1072, p. 170149, Mar. 2025, doi: 10.1016/J.NIMA.2024.170149.
- [5] W. Ren *et al.*, “Predicting molecular subtypes of breast cancer based on multi-parametric MRI dataset using deep learning method,” *Magn Reson Imaging*, p. 110305, Dec. 2024, doi: 10.1016/J.MRI.2024.110305.
- [6] Y. Yang *et al.*, “Development and Validation of Multiparametric MRI-based Interpretable Deep Learning Radiomics Fusion Model for Predicting Lymph Node Metastasis and Prognosis in Rectal Cancer: A Two-center Study,” *Acad Radiol*, Dec. 2024, doi: 10.1016/J.ACRA.2024.11.045.
- [7] W. Nie *et al.*, “Prediction of bladder cancer prognosis and immune microenvironment assessment using machine learning and deep learning models,” *Heliyon*, vol. 10, no. 23, p. e39327, Dec. 2024, doi: 10.1016/J.HELİYON.2024.E39327.
- [8] M. Çakmak, “Automatic Maize Leaf Disease Recognition Using Deep Learning,” *Sakarya University Journal of Computer and Information Sciences*, vol. 7, no. 1, pp. 61–76, Apr. 2024, doi: 10.35377/saucis...1418505.
- [9] M. Çakmak and Z. Albayrak, “AFCC-r: Adaptive Feedback Congestion Control Algorithm to Avoid Queue Overflow in LTE Networks,” *Mobile Networks and Applications*, vol. 27, no. 5, pp. 2138–2152, Oct. 2022, doi: 10.1007/s11036-022-02011-8.
- [10] P. Razmjouei, E. Moharamkhani, M. Hasanvand, M. Daneshfar, and M. Shokouhifar, “Metaheuristic-Driven Two-Stage Ensemble Deep Learning for Lung/Colon Cancer Classification,” *Computers, Materials and Continua*, vol. 80, no. 3, pp. 3855–3880, Sep. 2024, doi: 10.32604/CMC.2024.054460.
- [11] E. Cho, H. J. Baek, E. J. Jung, and J. Lee, “Clinical feasibility of a deep learning approach for conventional and synthetic diffusion-weighted imaging in breast cancer: Qualitative and quantitative analyses,” *Eur J Radiol*, vol. 182, p. 111855, Jan. 2025, doi: 10.1016/J.EJRAD.2024.111855.
- [12] M. Tafavvoghi *et al.*, “Deep learning-based classification of breast cancer molecular subtypes from H&E whole-slide images,” *J Pathol Inform*, vol. 16, p. 100410, Jan. 2025, doi: 10.1016/J.JPI.2024.100410.

- [13] P. Zamzam, P. Rezaei, S. A. Khatami, and B. Appasani, "Super perfect polarization-insensitive graphene disk terahertz absorber for breast cancer detection using deep learning," *Opt Laser Technol*, vol. 183, p. 112246, May 2025, doi: 10.1016/J.OPTLASTEC.2024.112246.
- [14] I. Ahmad and F. Alqurashi, "Early cancer detection using deep learning and medical imaging: A survey," *Crit Rev Oncol Hematol*, vol. 204, p. 104528, Dec. 2024, doi: 10.1016/J.CRITREVONC.2024.104528.
- [15] I. T. Sado, L. F. Fitime, G. F. Pelap, C. Tinku, G. M. Meudje, and T. B. Bouetou, "Early multi-cancer detection through deep learning: An anomaly detection approach using Variational Autoencoder," *J Biomed Inform*, vol. 160, p. 104751, Dec. 2024, doi: 10.1016/J.JBI.2024.104751.
- [16] M. Hammad, M. ElAffendi, M. Asim, A. A. Abd El-Latif, and R. Hashiesh, "Automated lung cancer detection using novel genetic TPOT feature optimization with deep learning techniques," *Results in Engineering*, vol. 24, p. 103448, Dec. 2024, doi: 10.1016/J.RINENG.2024.103448.
- [17] M. N. Nguyen, "A scoping review of deep learning approaches for lung cancer detection using chest radiographs and computed tomography scans," *Biomedical Engineering Advances*, vol. 9, p. 100138, Jun. 2025, doi: 10.1016/J.BEA.2024.100138.
- [18] Y. Yang, H. Shen, K. Chen, and X. Li, "From pixels to patients: the evolution and future of deep learning in cancer diagnostics," *Trends Mol Med*, Dec. 2024, doi: 10.1016/J.MOLMED.2024.11.009.
- [19] R. Jain, P. Singh, and A. Kaur, "An ensemble reinforcement learning-assisted deep learning framework for enhanced lung cancer diagnosis," *Swarm Evol Comput*, vol. 91, p. 101767, Dec. 2024, doi: 10.1016/J.SWEVO.2024.101767.
- [20] M. Q. Shatnawi, Q. Abuein, and R. Al-Quraan, "Deep learning-based approach to diagnose lung cancer using CT-scan images," *Intell Based Med*, vol. 11, p. 100188, Jan. 2025, doi: 10.1016/J.IBMED.2024.100188.
- [21] M. Mert Usta, M. Çakmak, and D. Ekmekçi, "Anemia Types Prediction Using Ensemble Learning," Konya, May 2024. [Online]. Available: <https://www.icensos.com/>