

Yapay Zeka ile Kanser Tedavisini Geliştirme: Neoadjuvan Tedavi Yanıtını Tahmin Etmek İçin Derin Öğrenme

Bitir KHEIBARI^{1*}, Şebnem BORA², Burçin PEHLIVANOĞLU³, Anıl AYSAL⁴, Özgül SAĞOL⁵

^{1*} Fen Enstitüsü, Bilgisayar Mühendisliği, EGE Üniversitesi, İzmir, Türkiye (bitir.kheibari@gmail.com) (ORCID: 0000-0002-1930-2311)

² Fen Enstitüsü, Mühendislik Fakültesi, EGE Üniversitesi, İzmir, Türkiye (sebnem.bora@ege.edu.tr) (ORCID: 0000-0003-0111-4635)

³ Patoloji Anabilim Dalı, Tıp Fakültesi, Dokuz Eylül Üniversitesi, İzmir, Türkiye (burcin.pehlivanoglu@deu.edu.tr) (ORCID: 0000-0001-6535-8845)

⁴ Patoloji Anabilim Dalı, Tıp Fakültesi, Dokuz Eylül Üniversitesi, İzmir, Türkiye (anil.aysal@deu.edu.tr) (ORCID: 0000-0003-4428-7210)

⁵ Patoloji Anabilim Dalı, Tıp Fakültesi, Dokuz Eylül Üniversitesi, İzmir, Türkiye (ozgul.sagol@deu.edu.tr) (ORCID: 0000-0001-9136-5635)

Özet – Mide kanseri, dünya genelinde en ölümcül hastalıklardan biri olup, kanserle ilişkili ölümler arasında üçüncü sırada yer almaktadır. Neoadjuvan tedavi, ameliyat öncesinde tümörleri küçültmek için uygulanan bir yöntemdir. Ancak, bu tedaviye verilen yanıtın doğru bir şekilde değerlendirilmesi, geleneksel histopatolojik incelemelerde zaman alıcı olması ve gözlemciler arası farklılık göstermesi nedeniyle zorluklar barındırmaktadır. Bu çalışmada, yapay zeka ve derin öğrenme tabanlı modellerin bu süreci daha hızlı, doğru ve standart hale getirme potansiyeli araştırılmıştır. Bu kapsamda, YOLOv9 ve EfficientDet modelleri kullanılarak histopatolojik görüntüler analiz edilmiştir. YOLOv9, gerçek zamanlı tümör tespiti sağlarken, EfficientDet çok ölçekli özellik çıkarımı ve sınıflandırma işlemlerinde kullanılmıştır. Çalışmada, veri toplama, görüntü işleme, transfer öğrenme ve model optimizasyonu aşamaları uygulanarak modellerin performansı F1-skora, doğruluk ve geri çağırma metriklerine göre değerlendirilmiştir. Ön bulgular, yapay zeka destekli analizlerin, neoadjuvan tedavi yanıtlarını tahmin etmede geleneksel yöntemlerden daha başarılı olduğunu göstermektedir. Yapay zeka tabanlı modellerin patolojik incelemelere entegre edilmesi, erken teşhis süreçlerini hızlandırarak kişiselleştirilmiş tedavi yöntemlerinin geliştirilmesine katkı sağlamaktadır.

Anahtar Kelimeler –Yapay Zeka, Derin Öğrenme, Tümör Tespiti, YOLOv9, EfficientDet, Neoadjuvan Tedavi, Patoloji Analizi

Atf: Kheibari vd., (2025). Yapay Zeka ile Kanser Tedavisini Geliştirme: Neoadjuvan Tedavi Yanıtını Tahmin Etmek İçin Derin Öğrenme. International Journal of Multidisciplinary Studies and Innovative Technologies, 9(1): 129-136.

Enhancing Cancer Treatment with AI: Deep Learning for Predicting Neoadjuvant Therapy Response

Extended Abstract

Research Problem/Questions – Stomach cancer is one of the most lethal malignancies worldwide, ranking as the sixth most common cancer and the third leading cause of cancer-related deaths [1]. Neoadjuvant therapy, which includes preoperative chemotherapy or chemoradiotherapy, is widely used to shrink tumors before surgery. However, accurately assessing a patient's response to this treatment remains a significant challenge due to the limitations of traditional histopathological evaluation methods, which are time-consuming and subject to interobserver variability [2] [3]. To address this issue, artificial intelligence (AI) and deep learning models offer a more efficient, accurate, and scalable approach for evaluating treatment responses [4].

Short Literature Review – Deep learning models have been increasingly applied in medical imaging to enhance diagnostic accuracy and decision-making. YOLOv9, a real-time object detection model, has demonstrated high precision in identifying tumor regions in histopathology slides [5]. EfficientDet, on the other hand, enables multi-scale feature extraction and classification, allowing for a more detailed analysis of tumor characteristics and progression [6]. Previous studies have explored AI-based image segmentation and classification in oncology, highlighting the potential of machine learning models to standardize pathology assessments and reduce diagnostic errors [7] [8].

Methodology – This study integrates YOLOv9 and EfficientDet to analyze histopathological tissue samples and predict the effectiveness of neoadjuvant therapy. The research methodology includes data collection from medical institutions, preprocessing and augmentation of histopathological images, transfer learning for model optimization, and performance evaluation using precision, recall, and F1-score metrics [9] [10]. Additionally, AI-generated pathology reports provide automated and standardized assessments for clinicians, improving decision-making in cancer treatment planning [11] [12].

Results and Conclusions – Preliminary findings indicate that this AI-driven approach significantly improves the accuracy of neoadjuvant therapy response prediction, surpassing conventional manual assessments [13]. Integrating deep learning models in histopathological analysis presents a promising future for personalized medicine, early cancer detection, and optimized treatment strategies. This study highlights the potential of AI to revolutionize oncology, paving the way for faster and more reliable cancer diagnostics.

Keywords – Artificial Intelligence, Deep Learning, Tumor Detection, YOLOv9, EfficientDet, Neoadjuvant Therapy, Pathology Analysis

Citation: Kheibari et al., (2025). Enhancing Cancer Treatment with AI: Deep Learning for Predicting Neoadjuvant Therapy Response. International Journal of Multidisciplinary Studies and Innovative Technologies, 9(1): 129-136.

I. GİRİŞ

A. Mide Kanseri ve Etkileri

Mide kanseri, gastrik kanser olarak da bilinir ve en ölümcül kanser türlerinden biridir. Küresel olarak altıncı en yaygın kanser ve kanserle ilişkili ölümlerin üçüncü en yaygın nedeni olarak sıralanmaktadır. Bu hastalığın en büyük zorluklarından biri, semptomların genellikle ileri evrelerde ortaya çıkmasıdır, bu da erken teşhisi zorlaştırmaktadır. Neoadjuvan tedavi, ameliyat öncesinde kemoterapi veya kemoradyoterapi uygulanarak tümörü küçültmeye yönelik etkili bir tedavi stratejisidir. Bu tedavinin amacı, cerrahi sonuçları iyileştirmek ve hayatta kalma oranlarını artırmaktır [14].

B. Tedavi Yanıtının Değerlendirilmesindeki Zorluklar

Neoadjuvan tedavi yaygın olarak kullanılsa da, hastanın tedaviye verdiği yanıtın belirlenmesi hâlâ önemli bir zorluktur. Mevcut değerlendirme yöntemi, biyopsi örneklerinin patoloğlar tarafından manuel olarak analiz edilmesine dayanır. Ancak bu süreç bazı sınırlamalara sahiptir. Öncelikle, manuel analiz zaman alıcıdır ve saatler hatta günler sürebilir. Ayrıca, bu değerlendirme öznel yorumlama gerektirir; farklı patoloğlar aynı örnek üzerinde farklı sonuçlar çıkarabilir [15]. Bunun yanı sıra, yanıt kriterleri hastaneler arasında tutarsızlık gösterebilir ve yüksek değişkenlik içerebilir. Bu zorlukları aşmak için yapay zeka (YZ) ve derin öğrenme teknikleri, tedavi yanıtlarını tahmin etmek için hızlı, doğru ve standartlaştırılmış bir yaklaşım sunmaktadır.

C. Tıpta Derin Öğrenmenin Rolü

Derin öğrenme, yapay zekanın (AI) bir alt dalıdır ve insan beyninin veri işleme yöntemini taklit eder. Yapay Sinir Ağları (ANN'ler), özellikle de Evrimsel Sinir Ağları (CNN'ler) üzerine kuruludur ve görüntü tanıma ve sınıflandırmada uzmanlaşmıştır [16]. Tıbbi teşhislerde derin öğrenme modelleri, büyük hacimli tıbbi görüntüleri analiz ederek belirli kalıpları tespit edebilir, anormallikleri sınıflandırabilir ve tedavi sonuçlarını tahmin edebilir.

D. YZ'nin Kanser Teşhisine Katkısı

Geleneksel olarak kanser tespiti, patoloğların biyopsi analizleri yoluyla yapılmaktadır. Ancak, yapay zeka (YZ) tabanlı derin öğrenme modelleri bu süreci otomatikleştirerek daha verimli hale getirebilir. YZ, histopatolojik slaytlarda tümör segmentasyonu yaparak kanserli dokuları normal dokulardan ayırabilir [17]. Ayrıca, YZ modelleri tedavi yanıtını sınıflandırarak tümörün tedavi sonrası küçülüp küçülmediğini belirleyebilir. Bunun yanı sıra, yapay zeka

sistemleri otomatik rapor üretimi sağlayarak standartlaştırılmış patoloji raporları oluşturabilir ve hata oranlarını azaltabilir. Derin öğrenme modellerinin entegrasyonu sayesinde onkologlar ve patoloğlar daha hızlı, daha doğru ve tekrarlanabilir teşhisler yapabilir, böylece kanser teşhis sürecinin etkinliği artırılabilir.

II. YZ TABANLI TAHMİN MODELİ: METODOLOJİ

Neoadjuvan tedavi yanıtlarını tahmin eden bir YZ tabanlı sistem geliştirmek için aşağıdaki metodoloji uygulanmıştır.

A. Veri Toplama

Histopatolojik doku örnekleri, Dokuz Eylül Üniversitesi Tıp Fakültesi Patoloji Anabilim Dalı arşivinden temin edilmiştir. Çalışmaya, neoadjuvan tedavi sonrası gastrektomi uygulanmış 50 mide kanseri olgusuna ait H&E boyalı lamalar dahil edilmiştir. Bu lamalar dijitalleştirilerek toplamda 1500 adet yüksek çözünürlüklü histopatolojik görüntü elde edilmiştir.

Veriler, yalnızca tedavi öncesi ve sonrası tümör görüntülerine dayanmakta olup, görüntü işleme ve yapay zeka modeli eğitimi amacıyla kullanılmıştır. Etiketleme işlemleri, uzman patoloğ denetiminde Label Studio yazılımı aracılığıyla gerçekleştirilmiştir.

Çalışma, Dokuz Eylül Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu tarafından onaylanmıştır (Etik Kurul Karar Tarihi: 03.05.2024). Etik onay kapsamında, hiçbir hastaya ait tanımlayıcı bilgi (örneğin yaş, cinsiyet, kimlik numarası) kullanılmamıştır. Tüm veriler yalnızca olgu numarası ile anonimleştirilmiştir.

Ayrıca, hasta demografik bilgileri ve klinik veriler bu çalışmanın kapsamı dışında bırakılmış; model girdisine dahil edilmemiştir. Bu nedenle, yapay zeka modelinin çıktılarına veya istatistiksel analiz aşamalarında demografik ya da klinik değişkenlerden kaynaklanabilecek herhangi bir etki söz konusu değildir.

B. Veri Ön İşleme

Yapay zeka modeline girmeden önce görüntüler çeşitli ön işleme adımlarına tabi tutulmuştur. Bu işlemler, görüntü kalitesini artırmak ve modelin genel performansını iyileştirmek amacıyla sınırlı ve kontrollü bir şekilde gerçekleştirilmiştir.

Parlaklık ve kontrast ayarlamaları manuel olarak yapılmamış; bunun yerine, histogram eşitleme (CLAHE) gibi otomatik ve standart yöntemler kullanılmıştır. Bu işlemler sırasında görüntülerin biyolojik anlamını korumaya özen gösterilmiş, hematoksilin-eozin (H&E) boyamasına özgü renk yapısı bozulmamıştır. İşlem sonrası görüntüler, uzman

patologlar tarafından kontrol edilerek değerlendirmenin bütünlüğü teyit edilmiştir.

Veri artırma (augmentation) adımlarında yalnızca ± 90 derece rotasyon ve sınırlı renk varyasyonu uygulanmıştır. 180 derece dönüşler ya da tümör lokalizasyonunu etkileyebilecek transformasyonlar kullanılmamıştır. Yatay ve dikey çevirme işlemleri sadece lokalizasyon gerektirmeyen sınıflandırma süreçlerinde kullanılmıştır. Renk modifikasyonlarında da H&E boyama standardı korunmuş, renklerin biyolojik anlamı değiştirilmemiştir.

Bu ön işleme adımlarının model doğruluğuna olan etkisi, ham verilerle yapılan karşılaştırmalı analizlerle test edilmiştir. Elde edilen sonuçlar, F1 skoru ve doğruluk gibi metriklerde olumlu bir artış göstermiştir. Tüm işlemler etik kurul onayı kapsamında, yalnızca arşivlenmiş ve anonimleştirilmiş görüntüler üzerinde gerçekleştirilmiştir.

C. YZ Modeli Seçimi

Bu çalışmada, transfer öğrenme (transfer learning) tekniği kullanılmıştır. Transfer öğrenme, önceden eğitilmiş derin öğrenme modellerinin belirli bir görev için ince ayarlanmasını içerir. Bu bağlamda çalışmada iki son teknoloji modeli kullanılmıştır. YOLOv9, gerçek zamanlı tümör tespiti sağlamak amacıyla uygulanmıştır. EfficientDet ise çok ölçekli özellik çıkarımı ve sınıflandırma süreçlerinde kullanılarak, tümör analizi ve tespiti için daha kapsamlı bir yaklaşım sunmuştur.

D. Model Eğitimi ve Doğrulama

Veri kümesi, mide kanseri tanısı almış 50 hastaya ait toplam 1.500 adet etiketli histopatolojik görüntü içermektedir. Görseller, tümör ve fibrozis bölgelerini içerecek şekilde uzman patologlar tarafından manuel olarak Label Studio ile etiketlenmiştir. Görüntüler, sınıf bazında yaklaşık olarak %55 tümörlü, %45 fibrotik örneklerden oluşmaktadır.

Veri kümesi, derin öğrenme uygulamalarında yaygın olarak tercih edilen şekilde %80 eğitim ve %20 test olmak üzere ikiye ayrılmıştır. Bu oran, hem modelin öğrenme kapasitesini maksimize etmek hem de bağımsız bir test kümesi ile genellenebilirliğini değerlendirebilmek amacıyla seçilmiştir [18].

Model eğitimi, YOLOv9 ve EfficientDet tabanlı Evrişimli Sinir Ağları (CNN) mimarileri kullanılarak gerçekleştirilmiştir. Eğitim sürecinde transfer learning yaklaşımı uygulanmış; daha önce büyük veri kümelerinde eğitilmiş ağırlıklar kullanılmıştır. Aşırı öğrenmenin (overfitting) önüne geçebilmek için erken durdurma (early stopping) ve dropout gibi düzenleme teknikleri kullanılmıştır.

Bu çalışmada geliştirilen yapay zeka modelinin başarımı, medikal görüntü analizinde yaygın olarak tercih edilen dört temel metrik ile değerlendirilmiştir: Doğruluk (Precision), Geri Çağırma (Recall), F1-Skoru (F1-score) ve Genel Doğruluk (Accuracy). Bu metriklerin seçimi, özellikle sınıflar arası dengesizlik ve klinik önem taşıyan hataların önlenmesi hedeflerine dayanmaktadır [19].

Precision (%87): Modelin pozitif tahminlerinin ne kadarının gerçekten doğru olduğunu ölçer. Medikal uygulamalarda, özellikle yanlış pozitiflerin (false positive) gereksiz müdahalelere neden olabileceği durumlarda kritiktir.

Recall (%89): Gerçek pozitiflerin ne kadarının doğru tahmin edildiğini gösterir. Kanser tespiti gibi yüksek hassasiyet gerektiren uygulamalarda, yanlış negatiflerin (false negative) azaltılması öncelikli olduğundan önemli bir ölçüttür.

F1-Score (%88): Precision ve Recall arasında denge sağlar. Veri kümesinde sınıf dağılımı dengeli olmadığında daha güvenilir bir başarı ölçütüdür.

Accuracy (%84): Tüm tahminlerin genel doğruluk oranıdır. Ancak sadece accuracy'e dayanmak, dengesiz veri setlerinde yanıltıcı olabilir. Bu nedenle F1-skora öncelik verilmiştir.

$$\frac{TP}{TP + FP} = \frac{85}{85 + 12} \approx 0.876$$

$$\frac{TP}{TP + FN} = \frac{85}{85 + 10} \approx 0.895$$

$$2 \times \frac{Precision \times Recall}{Precision + Recall} \approx 0.885$$

Ayrıca elde edilen TP (Doğru Pozitif): 85, FN (Yanlış Negatif): 10, FP (Yanlış Pozitif): 12 ve TN (Doğru Negatif): 93 değerleri, Şekil 2'de sunulan karışıklık matrisi ile uyumludur.

Bu metrikler ışığında:

Geri Çağırma oranının yüksek olması, modelin tümörlü dokuları başarılı şekilde tespit ettiğini göstermektedir.

Doğruluk oranının yüksekliği, modelin yanlış pozitifleri düşük tuttuğunu ve özgüllüğünün güçlü olduğunu ortaya koymaktadır.

F1-skorunun %88 olması, modelin dengeli ve güvenilir sonuçlar sunduğunu desteklemektedir.

Özellikle Şekil 1'de sunulan F1-güven eğrisinde maksimum skorun 0.6–0.7 güven aralığında elde edilmesi, modelin istikrarlı ve klinik olarak kullanılabilir olduğunu göstermektedir.

Bu sonuçlar, geliştirilen yapay zeka sisteminin, neoadjuvan tedaviye yanıtın tahmininde etkin ve güvenilir bir destek aracı olarak kullanılabileceğini ortaya koymaktadır.

E. YZ Destekli Otomatik Raporlama

Bu çalışmada, YZ modelinden elde edilen tümör veya fibrozis tahmin sonuçlarının otomatik olarak raporlanabilmesi amacıyla GPT tabanlı büyük dil modeli (LLM) kullanılmıştır. GPT, yapılandırılmış görsel çıktıları anlaşılır klinik rapor cümlelerine dönüştürme yeteneği nedeniyle tercih edilmiştir. Özellikle tahmin güveni, tümör sınıfı ve olgu numarası gibi parametrelerin yorumlanmasında etkili ve hızlı bir şekilde doğal dil çıktıları sunabilmektedir [20] raporlarının otomatik üretilmesi sağlanmıştır.

III. MATERYALLER VE YÖNTEM

Model eğitimi, açık kaynaklı TensorFlow kütüphanesi kullanılarak gerçekleştirilmiştir. Eğitim sürecinde transfer learning (aktararak öğrenme) yöntemi uygulanmış ve modeller, önceden büyük veri kümelerinde eğitilmiş ağırlıklarla başlatılmıştır. Hiperparametreler aşağıdaki şekilde belirlenmiştir:

- Learning Rate: 0.001
- Batch Size: 16
- Epoch Sayısı: 50
- Optimizer: Adam
- Loss Fonksiyonu: Categorical Cross-Entropy

Bu ayarlar, daha önce benzer medikal görüntü sınıflandırmalarında kullanılan referanslara ve TensorFlow kütüphanesinin önerilerine dayanmaktadır.

A. YOLOv9 Nedir?

YOLO (You Only Look Once), gerçek zamanlı nesne tespiti yapan bir modeldir. Görüntüleri tek bir işlemde analiz ederek son derece hızlı ve verimli çalışır. YOLOv9, bu modelin en son sürümüdür ve artırılmış doğruluk, hız ve küçük nesne tespiti yetenekleri sunar.

YOLOv9'un kanser teşhisindeki avantajları oldukça fazladır. Bu model, küçük tümör bölgelerini yüksek hassasiyetle tespit edebilir ve böylece erken teşhis sürecine önemli katkı sağlar. Gerçek zamanlı görüntü işleme yeteneği sayesinde patolojlara anında geri bildirim sunarak daha hızlı karar verilmesine yardımcı olur. Ayrıca, otomatik tümör segmentasyonu yaparak manuel anotasyon ihtiyacını azaltır, bu da zaman tasarrufu sağlarken hata oranlarını minimize eder.

B. YOLOv9'un Kanser Teşhisinde Çalışma Prensibi

YOLOv9, histopatolojik görüntüleri analiz etmek için çok aşamalı bir derin öğrenme süreci izler. İlk olarak, görüntü ön işleme aşamasında giriş histopatoloji görüntüsü, modelin gerektirdiği boyutlara ölçeklendirilir. Rotasyon, çevirme ve kontrast ayarlama gibi veri artırma teknikleri uygulanarak modelin daha sağlam bir eğitim alması sağlanır. Daha sonra, özellik çıkarma aşamasında YOLOv9, tümörle ilgili önemli özellikleri belirlemek için gelişmiş bir Evrişimli Sinir Ağı (CNN) kullanır ve kanserli dokuların kenarlarını, dokularını ve desenlerini tanır.

Sınırlayıcı kutu (bounding box) tahmini aşamasında model, görüntüyü bir ızgaraya böler ve potansiyel tümör bölgeleri için sınır kutuları tahmin eder. Her kutuya, tümör içerme olasılığını temsil eden bir güven skoru atanır. Son olarak, sınıflandırma ve son işleme aşamasında tespit edilen bölgeler, eğitim verisine dayanarak tümör veya fibrozis olarak sınıflandırılır. Gereksiz bölgeler, Maksimum Olmayan Bastırma (NMS) tekniğiyle filtrelenerek yalnızca en doğru tümör tahminleri bırakılır. Bu süreç, tümör tespitinde yüksek doğruluk sağlamayı amaçlar [21][22].

C. EfficientDet Nedir?

EfficientDet, nesne tespiti ve sınıflandırmada doğruluk ile işlem verimliliğini dengeleyen bir derin öğrenme modelidir. YOLOv9, gerçek zamanlı tümör tespiti odaklı çalışırken, EfficientDet yüksek çözünürlüklü görüntü analizi, özellik çıkarımı ve çok ölçekli tümör sınıflandırması için tasarlanmıştır.

EfficientDet, Farklı Ölçeklerde Özellik Çıkarmak için İki Yönlü Özellik Piramit Ağı (BiFPN) kullanarak tümörlerin farklı büyüklüklerdeki aşamalarını algılamakta son derece etkilidir.

D. EfficientDet'in Kanser Görüntülemeye Çalışma Prensibi

EfficientDet, tümör analizi için çok aşamalı bir yaklaşım izler. İlk olarak, ön işleme ve veri artırma aşamasında histopatolojik slaytlar normalleştirilir ve yeniden boyutlandırılır. Kontrast germe ve Gauss bulanıklaştırma gibi çeşitli teknikler kullanılarak görüntü kalitesi artırılır. Daha sonra, Özellik Piramit Ağı (FPN) kullanılarak farklı ölçeklerdeki özellikler çıkarılır ve böylece farklı boyutlardaki tümörler tespit edilebilir. Bu süreç, tümörlerin zamanla büyüyüp küçülmesini izlemek için oldukça kullanışlıdır[22]. EfficientDet'in bir diğer önemli aşaması, çok ölçekli özellik birleştirme sürecidir. Geleneksel CNN'lerden farklı olarak, EfficientDet farklı seviyelerdeki özellikleri birleştirerek sınıflandırmayı iyileştirir. Bu sayede küçük tümörleri büyük

tümörlerle aynı hassasiyetle tespit edebilir ve yanlış negatifleri önleyebilir. Son aşama olan sınırlayıcı kutu regresyonu ve sınıflandırma sürecinde ise model, tümör bölgelerine sınır kutuları atar ve bu bölgeleri benign, malign veya prekanseröz olarak sınıflandırır. İleri seviye hiperparametre ayarlamaları, modelin en doğru tahminleri elde etmesini sağlar[23].

E. YOLOv9 ve EfficientDet'in Kanser Tedavi Planlamasında Entegrasyonu

Bu iki model, farklı alanlarda üstün performans gösterse de birlikte kullanıldığında daha kapsamlı bir YZ destekli kanser teşhis sistemi oluşturur:

Adım 1: YOLOv9, tümör varlığını hızlı bir şekilde tespit eder.

Adım 2: EfficientDet, tümör özelliklerini analiz eder ve kötü huyluluk durumunu sınıflandırır.

Adım 3: YZ destekli sistem, otomatik patoloji raporları üreterek doktorlara tedavi planlamasında yardımcı olur.

Bu iki modelin birleşimi sayesinde hekimler, neoadjuvan tedavi yanıtlarını daha etkili bir şekilde değerlendirebilir, tedavileri kişiselleştirebilir ve hasta hayatta kalma oranlarını artırabilir.

Tablo 1. YOLOv9'un Kanser Görüntülemesi İçin İdeal Olmasının Nedenleri

Özellik	Kanser Teşhisindeki Faydası
Kanser Teşhisindeki Faydası	Histopatolojik görüntüleri anında analiz eder.
Küçük Nesne Algılama	Küçük tümörleri yüksek hassasiyetle tespit eder.
Uçtan Uca Öğrenme	Tüm görüntüyü tek adımda işler.
Yüksek Hassasiyet	Yanlış teşhis oranlarını azaltır.
Hafif Model	Düşük işlem gücüyle çalışabilir.

Bu tablo, YOLOv9'un tıbbi görüntüleme sistemlerinde hızlı, hassas ve verimli çalışmasını sağlayan temel avantajlarını göstermektedir.

Tablo 2. EfficientDet'in Histopatoloji İçin İdeal Olmasının Nedenleri

Özellik	Kanser Teşhisindeki Faydası
Çok Ölçekli Özellik Çıkarma	Farklı boyutlardaki tümörleri tespit eder, ilerlemeyi izlemeye uygundur.
Düşük Hesaplama Maliyetiyle Yüksek Doğruluk	Yüksek hassasiyetle çalışır, düşük işlem gücü gerektirir.
Daha İyi Tümör Sınıflandırması	YOLOv9 nesne tespitine, EfficientDet evre analizine odaklanır.
Tıbbi Görüntüleme ile Entegrasyon	BT, MRI ve histopatoloji görüntüleriyle uyumludur.
Gelişmiş Teşhis Tutarlılığı	Standart teşhis sağlar, yorum farkını azaltır.

EfficientDet kullanılarak doktorlar, yalnızca tümörleri tespit etmekle kalmaz, aynı zamanda tümörleri kötü huyluluk riskine göre sınıflandırabilir, böylece daha kişiselleştirilmiş tedavi planları oluşturabilir.

Tablo 3. Kanser Görüntülemesinde YOLOv9 ve EfficientDet Karşılaştırması

Özellik	YOLOv9	EfficientDet
Temel İşlev	Gerçek zamanlı tümör tespiti	Özellik çıkarımı ve sınıflandırma
İşleme Hızı	Son derece hızlı	yavaş ancak daha ayrıntılı
En İyi Kullanım Alanı	Hızlı kanser taraması ve erken tespit	Ayrıntılı tümör analizi ve sınıflandırma
Model Karmaşıklığı	Daha düşük karmaşıklık	Daha yüksek karmaşıklık
Kanser İçin Kullanım Durumu	Histopatoloji slaytlarında tümör tespiti	Tümör büyüme evrelerinin ve kötü huyluluğun belirlenmesi
Yanlış Pozitif Oranı	Daha düşük (gereksiz biyopsileri azaltır)	Biraz daha yüksek (yüksek hassasiyet nedeniyle)

YOLOv9, hızlı ve doğru tümör tespiti için en iyi seçenektir ve doktorların erken teşhis koymasına yardımcı olur. EfficientDet, tümör büyümesini anlamak, farklı kanser evrelerini sınıflandırmak ve tedavi kararlarını iyileştirmek için idealdir.

IV. LABEL STUDIO İLE ETİKETLEME VE TÜMÖR TESPİT VERİSETİNİN OLUŞTURULMASI

A. Label Studio Nedir?

Label Studio, makine öğrenimi projelerinde kullanılan açık kaynaklı, çok formatlı veri etiketleme aracıdır. Metin, görüntü, ses ve video verileri üzerinde çalışmaya olanak tanıyan bu platform, özellikle medikal görüntü işleme alanında yüksek doğruluk gerektiren uygulamalarda tercih edilmektedir.

Bu çalışmada, Label Studio, histopatolojik mide doku görüntülerinde tümör bölgelerinin manuel olarak işaretlenmesi amacıyla kullanılmıştır. Özellikle şu iki temel kullanım gerçekleştirilmiştir:

1. Sınırlayıcı kutular (bounding box) yardımıyla tümör ve fibrotik bölgelerin lokalizasyonu yapılmıştır.
2. Görüntüler, tümör ve fibrotik olarak sınıflandırılmıştır.

Piksel bazlı segmentasyon ve otomatik etiketleme gibi ek özellikler bu çalışmada kullanılmamış; etiketleme işlemleri, uzman patolojist rehberliğinde manuel olarak gerçekleştirilmiştir. Bu yöntem, model eğitime yüksek güvenilirlikte ve klinik geçerliliği olan veriler sağlamayı amaçlamıştır.

B. Dokuz Eylül Hastanesi'nden Alınan Görüntülerin Tümör Tespiti İçin Kullanımı

Bu veri kümesi, Dokuz Eylül Hastanesi'nden alınan histopatolojik görüntülerden oluşmaktadır. Bu çalışma kapsamında, görüntülerin işlenmesi, etiketlenmesi ve YOLOv9 ile EfficientDet gibi yapay zeka (YZ) modelleri için hazırlanması süreci uygulanmıştır. Toplanan veri kümesi, neoadjuvan tedavi gören mide kanseri hastalarına ait histopatolojik slaytları içermektedir. Ayrıca, kanserli, kanserli olmayan ve prekanseröz dokuları temsil eden görüntülerden oluşmaktadır. Tedavi öncesi ve sonrası alınan görüntüler, hastaların tedaviye verdikleri yanıtın değerlendirilmesi için kullanılmıştır. Görüntüler, dijital patoloji analizi için DICOM,

PNG veya JPEG formatında saklanmıştır. YZ modellerinin doğru şekilde eğitilebilmesi için her görüntünün dikkatlice etiketlenmesi ve kategorize edilmesi gerekmektedir.

C. Etiketlenmiş Veri ile YZ Modellerinin Eğitilmesi

Veri kümesi oluşturulduktan sonra, YOLOv9 ve EfficientDet modellerini eğitmek için kullanılmaktadır. Etiketlenmiş görüntüler ve açıklamalar şu şekilde bölünmektedir:

- %80 Eğitim Seti: Modelin eğitilmesi için kullanılır.
- %20 Test Seti: Modelin doğruluğunu değerlendirmek için kullanılır.

Eğitim süreci, TensorFlow kullanılarak gerçekleştirilmekte olup, tümör tespiti için en iyi sonuçları elde etmek amacıyla modeller hassas bir şekilde ayarlanmaktadır (fine-tuning).

TensorFlow, Google Brain ekibi tarafından geliştirilen açık kaynaklı bir derin öğrenme kütüphanesidir ve özellikle görüntü işleme, doğal dil işleme ve tıbbi yapay zeka projelerinde yaygın olarak kullanılmaktadır. Bu çalışmada TensorFlow'un tercih edilme nedeni, sunduğu geniş model kütüphanesi, aktif geliştirici topluluğu ve GPU/TPU gibi donanım hızlandırıcılarla yüksek performanslı eğitim süreçlerini desteklemesidir. Ayrıca, Label Studio gibi veri etiketleme araçlarıyla uyumlu çalışabilmesi, transfer öğrenme senaryolarına olanak tanınması ve tıbbi görüntüleme uygulamaları için hazır modeller sunması da önemli avantajlar arasındadır. TensorFlow'un bu özellikleri sayesinde, YOLOv9 ve EfficientDet gibi gelişmiş derin öğrenme mimarileri, histopatolojik görüntüler üzerinde hızlı ve doğru tahminler üretebilmiş, böylece tümör tespiti ve sınıflandırmasında etkin bir şekilde kullanılmıştır[24].

Label Studio, etiketleme sürecini basitleştirerek yüksek kaliteli veri kümeleri oluşturulmasını sağlar. Doğru şekilde etiketlenmiş verilerle YOLOv9 ve EfficientDet, tümörleri hassas bir şekilde tespit ve sınıflandırabilir, böylece kanser teşhisi ve tedavi planlaması daha etkin hale gelir.

V. SONUÇLAR

A. Kanser Tespitinde Gelişmiş Doğruluk

Geliştirilen yapay zeka (YZ) modeli, geleneksel manuel gözlem tabanlı patoloji değerlendirmelerine kıyasla daha yüksek doğruluk ve tutarlılık sağlamıştır. Literatürde, H&E boyalı histopatolojik görüntülerde manuel tümör tespitiyle elde edilen ortalama F1-skorerlarının %70–75 aralığında olduğu, uzmanlar arası tutarlılığın ise %65–75 arasında değiştiği bildirilmiştir [25]. Özellikle küçük tümör odaklarının fark edilmesinde bu yöntemlerin başarısı düşmekte, bu da yanlış negatif oranlarını artırmaktadır.

Bu çalışma kapsamında YOLOv9 modeliyle elde edilen F1-skoru %88, Precision %87 ve Recall %89 olup, geleneksel yöntemlere kıyasla anlamlı bir performans artışı gözlemlenmiştir. Modelin hata oranları aşağıda detaylandırılmıştır:

Yanlış Pozitif (FP): 12
Literatürde manuel yöntemlerle ortalama FP sayısı 21 olarak bildirilmiştir; bu modelde %43 azalma sağlanmıştır.

Yanlış Negatif (FN): 10
Klasik analizlerde FN ortalaması 18'dir; bu modelde %44 oranında düşüş gözlemlenmiştir.

Bu gelişmeler, özellikle küçük çaplı tümörlerin atlanma riskini azaltarak tedavi planlamasında daha hassas ve güvenilir veri sunmuştur. Şekil 1'de sunulan F1-Güven Eğrisi

de bu başarıyı desteklemektedir. Modelin genel F1-skoru, güven eşiği 0.6–0.7 aralığında maksimuma ulaşmıştır. Eğriler doğrudan test verisi üzerinden elde edilmiş olup herhangi bir smoothing veya spline fitting işlemine tabi tutulmamıştır. Bu da modelin farklı güven eşiği değerlerinde dahi istikrarlı performans gösterdiğini ortaya koymaktadır.

B. Otomatik Patoloji Raporları

Bu çalışmada, yapay zeka modelinden elde edilen çıktılar (örneğin tümör veya fibrozis varlığı, tahmin güveni, sınıflandırma tipi) büyük dil modeli GPT-4 (Generative Pre-trained Transformer 4) aracılığıyla otomatik patoloji raporlarına dönüştürülmüştür. Bu yaklaşım, klinik süreçlerde hem zaman tasarrufu sağlamak hem de dildeki standardizasyonu artırarak raporlama hatalarını azaltmayı hedeflemektedir.

Bu hasta ya da örnek numarası (045), sistemde tanımlı bir olguyu (örneği) ifade eder. Her olgu için tahminler ayrı ayrı yapılmıştır.

Tümör Yüzdesi (%87): Bu, modelin analiz ettiği görüntüdeki (Fig 1) doku alanının %87'sinin tümörlü bölge olduğunu tahmin ettiğini gösterir. Bu oldukça yüksek bir orandır ve genellikle rezidüel (kalan) tümör varlığına işaret eder.

Fibrozis Yüzdesi (%13): Geriye kalan %13'lük kısmın fibrotik doku (yani tedavi sonrası gelişen bağ doku) olduğu öngörülmüştür. Bu, tedaviye yanıtla ilişkili bir göstergedir.

SCSS			
Olgu No	Tümör Yüzdesi (%)	Fibrozis Yüzdesi (%)	
0	45	87	13

Fig. 1. Raporlama Çıktısı

Bu tür yüzdesel tahminler, klasik patolog gözlemlerine kıyasla daha sayısal ve nesnel bilgi sağlar. Tedavi yanıtının erken evrede değerlendirilmesi için değerli bir karar destek mekanizması oluşturur.

C. Klinik Karar Verme Sürecinin Güçlendirilmesi

Modelin çıktı verileri, hekimlerin tedavi planlarını şekillendirmelerinde karar destek aracı olarak etkin şekilde kullanılabilir düzeydedir. Özellikle rezidüel tümör miktarı, tedaviye yanıt derecesi ve tahmin güveni gibi metrikler, uzmanlara tedavi protokolünü değiştirme veya sürdürme konusunda kanıta dayalı destek sunmaktadır.

Klinik açıdan önemli bir çıktı olan F1-Güven Eğrisi (Şekil 1), modelin farklı güven eşiği değerlerinde nasıl performans gösterdiğini açık biçimde sunmaktadır. Eğriler doğrudan test veri setinden elde edilen tahminler üzerinden hesaplanmış, herhangi bir spline fitting, smoothing ya da moving average yöntemiyle yumuşatma yapılmamıştır. Eğrinin düzgün yapısı, modelin farklı eşiklerde bile istikrarlı bir performans sunduğunu göstermektedir.

Bu analizler, sadece model doğruluğunu değil, aynı zamanda klinik kararların güvenilirliğini de desteklemektedir. YZ tabanlı bu yaklaşım sayesinde özellikle neoadjuvan tedavi sürecinde gerçek zamanlı olarak:

- Tümör küçülmesinin erken saptanması.
- Tedavi başarısızlığı olasılığının öngörülmesi.
- Yeni tedavi stratejilerine geçiş zamanlamasının belirlenmesi.

mümkün hale gelmektedir. Böylece sistem, yalnızca görüntü işleme değil, aynı zamanda klinik yönetimi iyileştirme amacıyla da kullanılabilir bir yapay zeka çözümüne dönüşmektedir [26].




Fig. 2. F1-Güven Eğrisi

YOLOv9 ve EfficientDet gibi derin öğrenme modelleri kullanılarak yapılan tümör tespiti için F1-Güven Eğrisi. Grafik, farklı güven eşiklerinde F1-skorunun nasıl değiştiğini göstermektedir:

Figür 2’de Mavi (Kanserli Bölgeler): Modelin, güven eşiği değiştiğçe kanserli dokuları ne kadar iyi tespit ettiğini temsil eder.

Turuncu (Kanserli Olmayan Bölgeler): Modelin, kanserli olmayan bölgeleri algılama performansını gösterir.

Yeşil (Genel F1 Skoru): Tüm sınıflar için ortalama F1-skorunu ifade eder ve modelin genel etkinliğini gösterir.

A. Veri işleme hattını (pipeline)

- **Giriş (Input):** Etiketlenmiş 1500 histopatolojik görüntü, Label Studio kullanılarak tümör ve fibrozis bölgeleri için sınırlayıcı kutular ile işaretlendi.
- **Ön İşleme:** Görüntüler normalize edildi, yeniden boyutlandırıldı ve veri artırma teknikleri (döndürme, kontrast artırma vb.) uygulandı.
- **Model Eğitimi:**
 - YOLOv9 ile tümör segmentasyonu
 - EfficientDet ile sınıflandırma
 - TensorFlow framework’ü ile eğitim
- **Tahmin:** Test verileri ile sınıflandırma ve güven skorları üretildi. Maksimum Olmayan Bastırma (NMS) ile gereksiz tahminler filtrelendi.
- **Otomatik Raporlama:** GPT tabanlı büyük dil modeli ile, tahmin çıktılarından otomatik klinik raporlar üretildi.

B. Önemli Çıkarımlar:

Güven eşikleri, modelin doğruluğunu ve hata oranlarını doğrudan etkileyen önemli bir parametredir. Yüksek güven eşikleri, modelin yalnızca en yüksek olasılıkla kanserli olarak sınıflandırdığı vakaları tespit etmesini sağlar. Bu durum, yanlış pozitifleri (hatalı kanser teşhisleri) azaltarak modelin güvenilirliğini artırır. Ancak, yüksek güven eşikleri, bazı kanserli vakaların yanlış negatif olarak sınıflandırılmasına neden olabilir, yani model bu vakaları gözden kaçırabilir. Bu tür bir hata, özellikle erken teşhis gerektiren kanser vakalarında ciddi sonuçlar doğurabilir. Çözüm olarak Kanserli örneklerin azlığı modeli zayıflatır. Veri artırma (augmentation) teknikleriyle bu sınıf çoğaltılarak

modelin tanıma gücü artırılabilir. Böylece düşük güven eşiklerinde bile yanlış negatif oranı azalır.

Öte yandan, düşük güven eşikleri modelin daha fazla vakayı kanserli olarak algılamasına yol açar. Bu, duyarlılığı artırarak gerçekten kanserli olan vakaların yakalanma olasılığını yükseltir, ancak aynı zamanda yanlış pozitiflerin (hatalı kanser teşhislerinin) artmasına neden olabilir. Yanlış pozitif oranının artması, gereksiz biyopsiler ve ek testlerin yapılmasına yol açarak hem hasta stresini artırabilir hem de sağlık sisteminde gereksiz maliyetlere neden olabilir.

Optimum güven eşiği, modelin hassasiyet (sensitivity) ve özgüllük (specificity) dengesini en iyi şekilde sağlayan aralıktır. Yapılan çalışmalar, kanser teşhisi için en uygun güven eşiğinin genellikle 0.6 - 0.7 arasında olduğunu göstermektedir. Bu aralık, hem kanserli hem de kanserli olmayan bölgeler için maksimum F1-skorunun elde edilmesini sağlar. F1-skoru, modelin hem yanlış pozitifleri hem de yanlış negatifleri dikkate alarak genel performansını ölçen bir metriktir. Bu nedenle, optimum eşik belirlenirken hasta sağlığı, teşhis doğruluğu ve klinik kararların etkisi göz önünde bulundurulmalıdır.




Fig. 3. Karışıklık Matrisi

Figür 3'te sunulduğu gibi, YOLOv9 ve EfficientDet gibi derin öğrenme modelleri kullanılarak yapılan tümör tespiti için Karışıklık Matrisi (Confusion Matrix).

Matrisi Yorumlama:

Doğru Pozitifler (TP) = 85 → Kanserli vakaların doğru şekilde tespit edilmesi.

Yanlış Negatifler (FN) = 10 → Kanserli vakaların yanlışlıkla kanserli değil olarak sınıflandırılması.

Yanlış Pozitifler (FP) = 12 → Kanserli olmayan vakaların yanlışlıkla kanserli olarak sınıflandırılması.

Doğru Negatifler (TN) = 93 → Kanserli olmayan vakaların doğru şekilde tespit edilmesi.

Önemli Çıkarımlar:

Yüksek Doğru Pozitif (TP) ve Doğru Negatif (TN) sayısı, modelin başarılı bir şekilde çalıştığını göstermektedir.

Yanlış Negatiflerin (10 vaka) varlığı, bazı kanserli bölgelerin kaçırıldığını gösterir. Bu durum, eşik değeri ayarlamaları (threshold tuning) veya ek veri artırımı (data augmentation) gerektirebilir.

Yanlış Pozitiflerin (12 vaka) varlığı, bazı kanserli olmayan bölgelerin yanlışlıkla kanserli olarak sınıflandırıldığını gösterir. Bu durum, gereksiz biyopsilere veya tedavilere neden olabileceğinden, modelin hassasiyet optimizasyonu gerektirebilir.

VI. TARTIŞMA

Bu çalışmada, yapay zeka (YZ) tabanlı derin öğrenme modellerinin mide kanseri teşhisinde nasıl kullanılabileceği incelenmiştir. YOLOv9 ve EfficientDet modelleri, histopatolojik görüntülerin analiz edilmesi ve neoadjuvan tedaviye verilen yanıtların değerlendirilmesi için entegre edilmiştir. Çalışma sonuçları, bu modellerin geleneksel manuel patoloji incelemelerine kıyasla daha hızlı, hassas ve tutarlı teşhisler sağlayabildiğini göstermektedir.

Model performansları değerlendirildiğinde, YOLOv9'un gerçek zamanlı tümör tespiti konusunda üstünlük sağladığı, EfficientDet'in ise çok ölçekli tümör analizi ve sınıflandırmada daha iyi sonuçlar verdiği görülmüştür. Bununla birlikte, yanlış pozitif ve yanlış negatif oranları gibi belirli sınırlamalar, model performansının daha da iyileştirilmesi gerektiğini ortaya koymaktadır. Yanlış negatif oranlarının azaltılması için veri kümesinin çeşitlendirilmesi ve model optimizasyon süreçlerinin geliştirilmesi gerekmektedir.

Ayrıca, YZ tabanlı patoloji raporları, klinisyenlerin teşhis süreçlerini hızlandırmasına yardımcı olmuş, otomatik raporlama sistemleriyle karar verme süreçlerinde daha yüksek doğruluk sağlanmıştır. Ancak, klinik uygulamalarda YZ'nin benimsenmesi için, sistemlerin sağlık profesyonelleriyle daha iyi entegre edilmesi ve kullanıcı dostu arayüzlerle desteklenmesi gerekmektedir.

Gelecekte, daha büyük ve çeşitli veri kümeleri ile model eğitiminin genişletilmesi, YZ'nin klinik karar destek sistemlerine entegrasyonu ve doğal dil işleme (NLP) destekli patoloji raporlarının geliştirilmesi gibi çalışmaların yapılması önerilmektedir. Bu adımlar, YZ'nin onkolojide daha yaygın ve etkili bir şekilde kullanılmasını sağlayarak erken teşhis, kişiselleştirilmiş tedavi ve hastalık yönetimini önemli ölçüde iyileştirebilir.

VII. SONUÇ

A. Onkolojide YZ'nin Geleceği

Bu çalışma, YZ'nin kanser teşhisinde devrim yaratma potansiyelini göstermektedir. Derin öğrenme modellerinin uygulanması, tedavi değerlendirmesini önemli ölçüde iyileştirerek onkologların daha hızlı ve doğru kararlar almasını sağlamaktadır.

B. Gelecek Araştırma Yönleri

Gelecekteki çalışmalar kapsamında, yapay zeka (YZ) modellerinin genelleştirilebilirliğini artırmak için daha çeşitli hasta verilerinin toplanması ve veri kümesinin genişletilmesi büyük önem taşımaktadır. Farklı yaş grupları, tümör tipleri ve klinik senaryoları içeren daha kapsamlı bir veri kümesi, modellerin farklı hasta gruplarında daha başarılı tahminler yapmasını sağlayacaktır. Bunun yanı sıra, elektronik sağlık kayıtları (EHR) ile entegrasyon sağlanarak tamamen YZ destekli bir teşhis aracı oluşturulabilir [27]. Bu entegrasyon, hastaların geçmiş tıbbi verilerini YZ sistemlerine entegre ederek daha doğru ve kişiselleştirilmiş teşhisler yapılmasına olanak tanıyacaktır. Ayrıca, doğal dil işleme (NLP) destekli patoloji raporları geliştirilerek, YZ tarafından üretilen patoloji raporlarının yorumlanabilirliği artırılabilir. NLP teknikleri kullanılarak, doktorların raporları daha kolay anlaması ve klinik kararlarını daha hızlı alması sağlanabilir. Bu gelişmeler, kanser teşhis süreçlerini daha güvenilir ve etkili hale getirmeyi amaçlamaktadır.

C. Kişiselleştirilmiş Tıbbi Etkisi

YZ destekli kanser teşhisi, erken teşhis ve kişiselleştirilmiş tedavi yaklaşımlarını daha etkili hale getirerek sağlık hizmetlerini dönüştürecektir.

TEŞEKKÜR

Bu makale, YZ destekli kanser teşhisini detaylı bir şekilde analiz etmekte ve YOLOv9 ve EfficientDet modellerinin tedavi yanıtı tahminini nasıl geliştirdiğini açıklamaktadır. Derin öğrenme, gerçek zamanlı tümör tespiti ve otomatik rapor oluşturma ile onkolojinin geleceğini yeniden şekillendirmektedir.

YAZAR KATKILARI

Yazarların çalışmaya katkıları eşittir.

ÇIKAR ÇATIŞMASI BEYANI

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

ARAŞTIRMA VE YAYIN ETİĞİ BEYANI

Yazarlar, bu çalışmanın Araştırma ve Yayın Etiği İlkelerine uygun olarak gerçekleştirildiğini beyan ederler.

REFERENCES

- [1] Deng, J., Zhang, W., Xu, M., & Zhou, J. (2023). Imaging advances in efficacy assessment of gastric cancer neoadjuvant chemotherapy. *Abdominal Radiology*, 48(12), 3661-3676.
- [2] Cui, Y., Zhang, J., Li, Z., Wei, K., Lei, Y., Ren, J., ... & Gao, X. (2022). A CT-based deep learning radiomics nomogram for predicting the response to neoadjuvant chemotherapy in patients with locally advanced gastric cancer: a multicenter cohort study. *EClinicalMedicine*, 46.
- [3] Hörst, F., Ting, S., Liffers, S. T., Pomykala, K. L., Steiger, K., Albertsmeier, M., ... & Kleesiek, J. (2023). Histology-based prediction of therapy response to neoadjuvant chemotherapy for esophageal and esophagogastric junction adenocarcinomas using deep learning. *JCO Clinical Cancer Informatics*, 7, e2300038.
- [4] Li, C., Qin, Y., Zhang, W. H., Jiang, H., Song, B., Bashir, M. R., ... & Zhong, L. (2022). Deep learning-based AI model for signet-ring cell carcinoma diagnosis and chemotherapy response prediction in gastric cancer. DOI: <https://doi.org/10.1002/mp.15437>, 1535-1546.
- [5] WongKinYiu. (n.d.). YOLOv9: Real-time object detection. Retrieved from <https://github.com/WongKinYiu/yolov9>.
- [6] Wightman, R. (n.d.). EfficientDet in PyTorch. GitHub repository. Retrieved from <https://github.com/rwightman/efficientdet-pytorch>.
- [7] Tan, M., Pang, R., & Le, Q. V. (2020). EfficientDet: Scalable and efficient object detection. Retrieved from <https://arxiv.org/abs/1911.09070>.
- [8] TensorFlow. (n.d.). EfficientDet with TensorFlow. TensorFlow Documentation. Retrieved from <https://www.tensorflow.org/lite/models/efficientdet/overview>.
- [9] Fang, M., Tian, J., & Dong, D. (2022). Non-invasively predicting response to neoadjuvant chemotherapy in gastric cancer via deep learning radiomics. *EClinicalMedicine*, 46.
- [10] Ouyang, G., Chen, Z., Dou, M., Luo, X., Wen, H., Deng, X., ... & Wang, X. (2023). Predicting Rectal Cancer Response to Total Neoadjuvant Treatment Using an Artificial Intelligence Model Based on Magnetic Resonance Imaging and Clinical Data. *Technology in Cancer Research & Treatment*, 22, 15330338231186467.
- [11] She, Y., He, B., Wang, F., Zhong, Y., Wang, T., Liu, Z., ... & Tian, J. (2022). Deep learning for predicting major pathological response to neoadjuvant chemoimmunotherapy in non-small cell lung cancer: A multicentre study. *EBioMedicine*, 86.
- [12] Zhu, H. T., Zhang, X. Y., Shi, Y. J., Li, X. T., & Sun, Y. S. (2020). A deep learning model to predict the response to neoadjuvant chemoradiotherapy by the pretreatment apparent diffusion coefficient images of locally advanced rectal cancer. *Frontiers in Oncology*, 10, 574337.
- [13] Li, Z., Zhang, D., Dai, Y., Dong, J., Wu, L., Li, Y., ... & Liu, Z. (2018). Computed tomography-based radiomics for prediction of neoadjuvant chemotherapy outcomes in locally advanced gastric cancer: a pilot study. *Chinese Journal of Cancer Research*, 30(4), 406.
- [14] Janssen, B., Theijse, R., van Roessel, S., de Ruiter, R., Berkel, A., Busch, O., ... & Besselink, M. (2022). Artificial Intelligence-Based Segmentation of Residual Tumor in Histopathology of Pancreatic Cancer after Neoadjuvant Treatment. *HPB*, 24, S294.
- [15] Springer. (2021). A survey of object detection models: From YOLO to EfficientDet. Retrieved from Springer database.
- [16] TensorFlow Developers. (2020, March). AutoAugment for object detection with EfficientDet. Retrieved from <https://blog.tensorflow.org/2020/03/efficientdet-object-detection-on-tpus.html>.
- [17] Towards Data Science. (2020). EfficientDet and augmentation techniques. Retrieved from <https://towardsdatascience.com/efficientdet-scalable-and-efficient-object-detection-807f77a93a7>.
- [18] Zhang, Y., Chen, H., Liu, Q., & Wu, J. (2023). Best practices for training and evaluating deep learning models in medical imaging. *IEEE Transactions on Medical Imaging*, 42(5), 1201-1215. <https://doi.org/10.1109/TMI.2023.3245678>
- [19] Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>
- [20] OpenAI. (2023). GPT-4 Technical Report. <https://doi.org/10.48550/arXiv.2303.08774>
- [21] Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*. <https://doi.org/10.48550/arXiv.1804.02767>
- [22] Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2020). Deep learning-based object detection and instance segmentation in medical imaging. *Computers in Biology and Medicine*, 123, 103865. <https://doi.org/10.1016/j.combiomed.2020.103865>
- [23] Tan, M., Pang, R., & Le, Q. V. (2020). EfficientDet: Scalable and efficient object detection. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 10781-10790). <https://doi.org/10.1109/CVPR42600.2020.01080>
- [24] TensorFlow ekibi. (2024). TensorFlow (Version 2.18.0) [Computer software]. <https://www.tensorflow.org>
- [25] Komura, D., & Ishikawa, S. (2018). *Machine learning methods for histopathological image analysis. Frontiers in Medicine*, 5, 241. <https://doi.org/10.3389/fmed.2018.00241>
- [26] Steiner, D. F., MacDonald, R., Liu, Y., & Stumpe, M. C. (2020). Impact of deep learning assistance on the histopathologic review of lymph nodes for metastatic breast cancer. *The American Journal of Surgical Pathology*, 44(2), 220-226. <https://doi.org/10.1097/PAS.0000000000001368>
- [27] Bera, K., Schalper, K. A., Rimm, D. L., Velcheti, V., & Madabhushi, A. (2019). *Artificial intelligence in digital pathology — new tools for diagnosis and precision oncology. Nature Reviews Clinical Oncology*, 16(11), 703-715. <https://doi.org/10.1038/s41571-019-0252-y>