

Patolojik Meme Kanseri Görüntülerinin YOLOv5 Algoritması ile Sınıflandırılması

Şeyma ÇEÇEN^{1*}, Ahmet Bedri ÖZER²

¹Bilgisayar Mühendisliği / Mühendislik ve Doğa Bilimleri Fakültesi, Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Türkiye

²Bilgisayar Mühendisliği / Mühendislik Fakültesi, Fırat Üniversitesi, Türkiye

*(seyma.cecen@gibtu.edu.tr)

Özet – Tıp alanı geleneksel yaklaşım olarak hastalığa tanı konulması ve tanıya yönelik tedavi yöntemlerinin uygulanması esasına dayalıdır. İnsan doku , hücre ve organlarındaki hastalıkların gelişimi ve sebeplerini Patoloji bilim dalı incelemektedir. Hücrelerin anormal şekilde kontrolsüz çoğalması durumunda kanser hastalığına sebep olmaktadır. Bu çalışmada meme dokusundan alınan biyopsilere ait patolojik görüntüler yapay zekanın bir alt dalı olan derin öğrenme yöntemi ile incelenmiştir. Meme kanseri türünün sınıflandırılması üzerine çalışılmıştır. Derin Öğrenme modeli olarak YOLOv5 algoritması kullanılmıştır. Deneysel sonuçta doğruluk parametresinde %95.3 oranında yüksek başarı ile tümörün sınıflandırılması sağlanmıştır.

Anahtar Kelimeler – YOLOv5, Patoloji, Derin Öğrenme, Meme Kanseri, Yapay Zeka

I. GİRİŞ

Vücudumuzda hücreler sistematik olarak bölünerek çoğalırlar. Kanser ise DNA yapısının hasar alarak bozulması sebebiyle hücrelerin kontrolsüz bir şekilde çoğalması olarak ifade edilir. Kanser türleri bu doku ve organların çeşidine göre farklılık gösterebilmektedir. Özellikle hastalığın etkenlerin biri düzensiz ve sağlıklı beslenme olarak belirtilmektedir. Dünya Sağlık Örgütü'nün son paylaştığı verilere göre özellikle kadınlarda en sık görülen kanser çeşidi meme kanseridir. Bu durum hastalığın erken tanı ve teşhisini önemli hale getirmektedir. Günümüzde yapay sinir ağlarını temel alan, makine öğrenmesinin bir alt dalı olan derin öğrenme çalışmaları büyük bir ivme kazanmıştır. Özellikle tıp alanındaki çalışmalarda yapay zekâ ile tıbbi tarama ve görüntüler kullanılarak hastalıkların tanı ve teşhisinde sağlık çalışanlarının iş yükünün azaltılması amaçlanmaktadır [1]. Görüntü tarama teknolojisinin gelişmesiyle birlikte, tam slayt görüntü (WSI) tarayıcıları patolojik tanı alanında yaygın olarak kullanılmaktadır. Bu nedenle, WSI analizi modern dijital patolojinin anahtarı haline gelmiştir. Tam

slayt görüntülerinin dijital forma dönüştürülmesi ile oluşturulan dijital slaytlar üzerinde görüntü analizi yöntemleri uygulanabilmektedir [2]. İlgili dokulardan alınan hematoksilen ve Eozin (H&E) boyalı kesitler mikroskop altında incelenerek dijital ortama aktarılabilir. Görüntüleme teknolojileri sayesinde hastalıkların tanı ve teşhisinde uzmanların daha kararlı ve nicel analiz sonuçlar elde etmesine, işçilik maliyetlerinin minimize edilmesine ve tanı nesneliğini geliştirilmesine imkan vermektedir. Derin öğrenme yöntemleri kullanılarak patolojik dokuların analizi ile uzman patolojlara ikinci bir görüş desteği sağlamaktadır.

Kanser hastalığının tespitinde ilgili tümörlü dokular iyi huylu ya da kötü huylu olarak sınıflandırılmaktadır. İyi huylu ya da kanserli olmayan dokular etrafındaki yapılara baskı uygulayan ancak hızlı bölünerek çoğalmayan, istilacı yapıda olmayan türü ifade etmektedir. Kötü huylu ya da kanserli olan dokular ise hızlı bölünerek çoğalan, hücre yapısını bozan diğer dokulara yayılan türler olarak açıklanmaktadır. Literatürde derin öğrenme teknikleri kullanılarak patolojik

görüntüler üzerinden kanser hastalığının sınıflandırılması alanında yapılan çok sayıda çalışma bulunmaktadır. 2022 yılında Meral Karakurt ve İsmail İşeri tarafından yapılan çalışmada meme dokusuna ait patoloji görüntüleri üzerinde sınıflandırma işlemi CNN mimarisi kullanılarak uygulanmıştır. 2017 yılında Kaggle web sitesinde paylaşılan meme patolojilerinden oluşan bir veri seti kullanılmıştır. Eşit sayıda kanser ve kanser olmayan toplam 60000 verileri kullanılarak eğitim ve test işlemleri uygulanmıştır. Elde edilen veriler ışığında 50x50 boyutlu görüntüler kullanılarak sınıflandırma işlemi yapılmıştır. Patoloji görüntülerin sınıflandırmasında model ile kanser ve kanserli olmayan veriler arasındaki doğruluk değeri 0.8775 ve F1 skoru 0.8238 elde edilmiştir [3]. 2020 yılında yapılan Rui ve arkadaşları tarafından meme kanseri alanında yapılan çalışmada ise hibrit evrişimli ve tekrarlayan yeni bir derin sinir ağı tavsiye edilerek 6 histopatolojik görüntü sınıflandırma yapılmıştır. Çalışmada 3771 meme kanserinin histopatolojik görüntüsü kullanılarak %91.3 doğrulukla iyi sonuçlar verdiği görülmektedir[4]. Sevcan Turan ve Gökhan Bilgin tarafından 2019 yılında yapılan çalışmada meme kanseri tespiti için alınan histopatolojik görüntüler kullanılmıştır. SegNet algoritmasının ortalama F-ölçüm değeri 0.73 ve eğitim hassasiyeti %85.64, U-Net'in ortalama F ölçümü değeri 0.62 ve eğitim hassasiyeti %72.87 olarak belirtilmiştir [5]. Y Wang ve ark. tarafından 2020 yılında yapılan çalışmada tümör sınıflandırması için Evrişimli sinir ağları (CNN) kullanılarak yeni bir yöntem önerilmiştir. Çalışmada ICIAR 2018 yarışmasının meme kanseri veri seti, DigestPath 2019 ve önerilen yöntemlerin geçerliliğini ve uygulanabilirliğini doğrulamak için yeni bir kolorektal tümör veri seti ile çalışılmıştır. Sonuçlara göre mAP değeri 0,83 ve F1 score değeri 0,82 olarak verilmiştir [6].


Özetle bu çalışmanın katkıları şunlardır:

- Dijital patolojik görüntülerin yapay zeka tabanlı çalışmalar için girdi olarak kullanılabilmesi
- Tıp ve bilgisayar bilimlerini bir araya getiren disiplinlerarası bir çalışma olması
- Nesne tespitinde yaygın olarak tercih edilen YOLOv5 algoritmasının sınıflandırılma alanında kullanılması.
- Hastalıkların tespitinde uzman patoloğlara tanı nesneliği konusunda ikinci bir görüş desteği sağlaması.

Bu çalışmada, meme kanserinin minimum zaman maliyeti ve yüksek doğruluk değeri ile tespiti amacıyla YOLOv5 modeli önerilmektedir. İkinci bölüm olan materyal bölümünde kullanılan veri seti hakkında bilgi verilmiştir. Üçüncü bölüm olan yöntem bölümünde veri setinin hazırlanması, önerilen mimarinin detayları ve performans değerlendirme metrikleri açıklanmıştır. Dördüncü bölüm olan tartışma bölümünde veri seti kullanılarak eğitim ve test işlemlerine ilişkin deneysel sonuçlara yer verilmektedir. Son bölüm olan sonuçlarda ise çalışmanın deneysel sonuçları ve genel bir değerlendirmesi yapılmaktadır.

II. MATERYAL

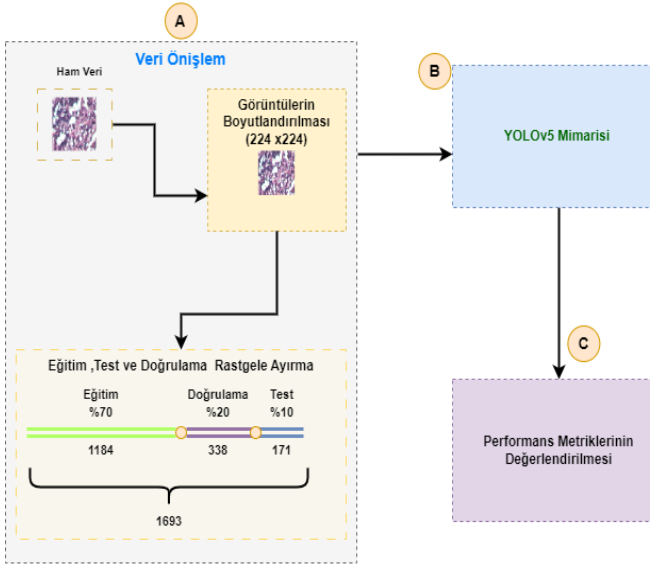
Bu çalışmada Kaggle [7] ortamında erişime açık bir veri seti tercih edilmiştir. BraeKHis olarak adlandırılan meme tümörlerinin mikroskopik biyopsi görüntülerinden oluşan 1693 adet patolojik görüntü kesiti bulunmaktadır. Mikroskop altında 400x optik yakınlaştırma sonucu elde edilen görüntüler benign (iyi huylu) ve malignant (kötü huylu) olarak iki ayrı sınıftan oluşmaktadır. Şekil 1'de meme kanserine ait patolojik görüntülerden oluşan veri setinden örnek görüntüler verilmiştir.



Şekil 1. Meme Kanseri Veri Seti Örnek Görüntüler
(A) İyi Huylu (B) Kötü huylu

III. YÖNTEM

Bu bölümde YOLOv5 algoritması kullanılarak meme tümörlerinin biyopsilerinden alınan patolojik görüntülerin sınıflandırılma süreci açıklanmaktadır. Önerilen yapı (A) veri ön işleme, (B) YOLOv5 mimarisi ve (C) performans değerlendirme metrikleri olmak üzere 3 aşamadan oluşmaktadır. Şekil 2 'de önerilen yapı modellenmiştir.



Şekil 2. Önerilen Yöntemin Yapısı

A. Veri Ön İşleme

Veri ön işleme aşaması veri sayısının artırılması, verilerin boyutlandırılması ve veri setinin rastgele eğitim ve test olarak gruplandırılması aşamalarından oluşmaktadır. Mevcut veri seti 700x460 boyutunda 1693 adet görüntü verisi içermektedir. YOLOv5 algoritmasına göre modelin en iyi performansla çalışması için 224x224 piksel olarak boyutlandırılmıştır. Yeterli sayıda patolojik görüntü verisi bulunduğu için veri sayısı artırma işlemi uygulanmamıştır. Verilerin %70'i eğitim ve %20'si doğrulama ve %10'u test veri kümesi olacak şekilde rastgele gruplandırılmıştır. Bu durumda 1184 adet veri eğitim ve 338 adet veri doğrulama ve 171 adet veri test için kullanılmak üzere ayrılarak modele uygun hale getirilmiştir.

B. YOLOv5 Mimarisi

YOLOv5 model mimarisi, YOLO (You Only Look Once) model ailesinin en yeni sürümlerinden biri olan nesne tespiti ve sınıflandırma modelidir. YOLOv5 modeli PyTorch kütüphanesini kullanmaktadır. YOLOv5 mimari yapısı omurga(backbone), boyun(neck) ve baş(head) olmak üzere üç bölümden oluşmaktadır. Veri setindeki yeniden boyutlandırılan 224x224 boyutundaki görüntüleri omurga (backbone) ağına iletilmektedir. Omurga ağında oluşturulan özellik haritasının katmanları farklı düzeylerdeki özellik haritaları ile birleştirilmektedir. [8] Omurga ağında bulunan odaklama(focus) modülü giriş görüntüsünü dilimlere ayırarak birleştirme işlemi yapar [9]. CBL modülü iç yapısında evrişim, normalizasyon ve Leaky ReLu aktivasyon fonksiyonu olarak üç

modülden meydana gelmektedir. CSP ağı çıkarım gücünü ve hız iyileştirmelerini amaçlamaktadır. İki farklı türü bulunmaktadır. Bunlardan biri omurga(backbone) ağında kullanılırken diğeri boyun(neck) ağı içerisinde yer almaktadır. Boyundaki CSP Ağı modülleri CBL modülleri ile değiştirilerek özellik haritası sıkıştırma işlemi gerçekleştirir. SPP modülü en yüksek düzeyde havuzlama işlemi gerçekleştirilerek özellikleri bir araya getirir [9]. YOLOv5 modelinin son modülü baş (head) ya da çıkış katmanı ise özellik çıkarımı sonucunda kanserli dokunun iyi ya da kötü huylu olma durumunun tespitini yapar.

C. Performans Değerlendirme Metrikleri

Çalışmada meme tümöründen alınan dokunun iyi huylu ve kötü huylu olarak sınıflandırma performansının değerlendirilmesi için belirli parametreler kullanılmaktadır. Doğruluk(accuracy), kesinlik(precision), duyarlılık(recall), F1 puanı (F1 score) gibi değerlendirme metrikleri kullanılmıştır. Ardından karışıklık matrisi (confusion matrix) çıkarılarak sonuçlar özetlenmiştir. İkili sınıf örneğine ait karışıklık matrisi Şekil 3'te verilmiştir.

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	TP	FN
	Negatif	FP	TN

Şekil 3. İkili Sınıfa ait Karışıklık Matrisi

Doğruluk (Accuracy) : Sınıflandırma işleminin doğruluğunu açıklayan parametrelerden biridir. [10]. Değer 1'e yaklaştıkça başarı oranı artmaktadır. Denklem 1'e göre hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FN + FP + TN} \quad (1)$$

Kesinlik (Precision): Tahmin başarısında pozitif durumlar için kullanılır. Formülü Denklem 2'de verilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

Duyarlılık (Recall) : Pozitif-Pozitif ya da negatif-negatif eşleşme durumunun kontrol edildiği parametredir. Denklem 3 'te verilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

F1 Puanı (F1 Score): Duyarlılık ve kesinlik parametrelerinin harmonik ortalama şeklinde ifade edilir. Denklem 4'e göre hesaplanmaktadır.

$$\text{F1 Puanı} = \frac{2 * (\text{Kesinlik} * \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} \quad (4)$$

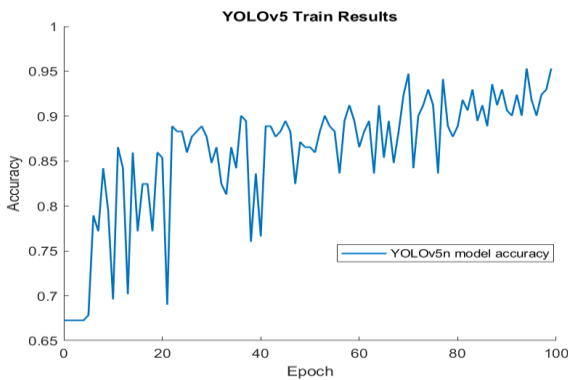
IV. TARTIŞMA

Bu çalışmada meme tümörüne ait elde edilen görüntülere YOLOv5 algoritmasının alt modüllerinden olan YOLOv5n modeli uygulanarak ilgili dokunun sınıflandırılması sağlanmıştır. Giriş görüntüleri 224x224 boyutunda alınarak 100 epoch değeri için eğitim işlemi yapılmıştır. Eğitime ilişkin sonuçlar Tablo 1'de verilmiştir.

Tablo 1. YOLOv5 Eğitim Sonuçları

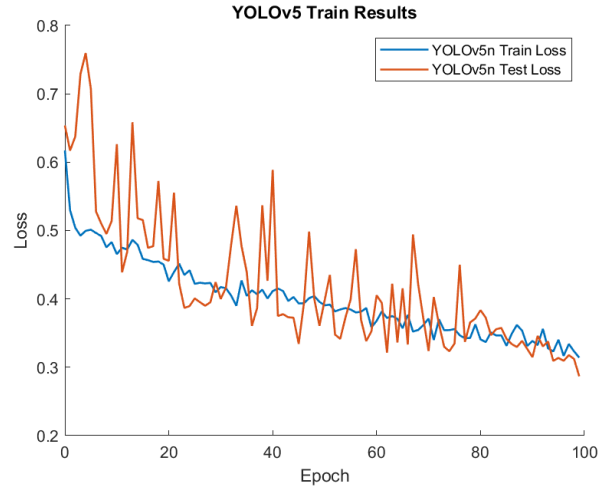
Model	Boyut	Acc Top 1	Acc Top 5	Eğitim Süresi 100 epoch (devir) (saat)
YOLOv5n	224	0.953	1	0.149

YOLOv5n modeline göre yapılan eğitim sonuçlarına ilişkin accuracy performans grafiği Şekil'4'te verilmiştir.



Şekil 4. YOLOv5n Model Accuracy Değerleri

YOLOv5n modelinin doğruluk değerlerine ilişkin test ve eğitim kayıpları grafiği ise Şekil 5'te belirtildiği gibidir.

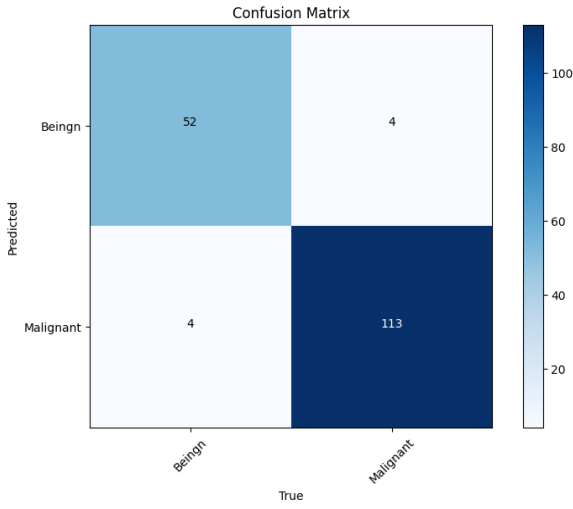


Şekil 5. YOLOv5n Test-Train Kayıp Sonuçları


YOLOv5n sonuçlarına göre doğruluk değerlerine ilişkin değerlendirme metrikleri Tablo 2'de verilmiştir. Kötü huylu (benign) dokulardan test için ayrılan 117 dokudan 113 adet görüntü doğru tahmin edilirken iyi huylu(malignant) olarak ayrılan 56 adet görüntüden 222 adet görüntünün doğru sınıflandırıldığı görülmüştür. Şekil 6'da verilen karışıklık matrisine ilişkin veriler özetlenecek olursa %95.3 oranında başarı sağlandığı görülmektedir.

Tablo 2. YOLOv5 Performans Sonuçları

Sınıf	Görüntü Sayısı	Accuracy (%)	Precision	Recall	F1 Score
Tümü	171	95.3	0.95	0.95	0.95
Benign	56	95.3	0.93	0.93	0.93
Malignant	117	95.3	0.97	0.97	0.97




(A)



(B)

Şekil 6. Elde Edilen Karışıklık Matrisi

Çalışmada Şekil 6'da elde edilen karışıklık matrisleri Normalize olmayan (A) ve Normalize (B) şekilde verilmiştir. Şekil 7 'de verilen test görüntülerine ait başarı oranları ise modelin meme kanserinin türünü sınıflandırmada başarılı olduğunu göstermektedir.



Şekil 7. İyi ve Kötü Huylu Başarılı Sınıf Örnekleri

V. SONUÇLAR

Çalışmada patolojik görüntülerin derin öğrenme yöntemleri kullanılarak sınıflandırılması üzerine çalışılmıştır. Elde edilen sonuçlar meme kanserinin türünün önerilen model ile yüksek doğruluk oranı ve minimum zaman maliyeti ile sınıflandırma yapabileceğini göstermektedir. Dijital patoloji kavramının gelişmesiyle birlikte patolojik verilerin yapay zeka için girdi verisi oluşturması hastalıkların tanı ve teşhisinde önem kazanmaktadır. Uzman patolojlara ikinci bir görüş desteği sağladığı gibi tanı nesnelğine de fayda sağlayacağı düşünülmektedir. Elde edilen sonuçlar ile YOLOv5n modeli ile yapılan çalışmada %95.3 oranında yüksek başarı sağlandığını göstermektedir. Önerilen modelin sınıflandırma alanında yapılan çalışmalara kıyasla başarılı olduğu ortaya koymaktadır.

KAYNAKLAR

- [1] Z. AYTAÇ, İ. ISERİ, and B. DANDIL, "Derin Öğrenme Kullanarak Tiroid Kanseri Teşhisi," *Eur. J. Sci. Technol.*, no. 29, pp. 292–298, 2021, doi: 10.31590/ejosat.1011166.
- [2] S. Jiang, H. Li, and Z. Jin, "A Visually Interpretable Deep Learning Framework for Histopathological Image-Based Skin Cancer Diagnosis," *IEEE J. Biomed. Heal. Informatics*, vol. 25, no. 5, pp. 1483–1494, 2021, doi: 10.1109/JBHI.2021.3052044.
- [3] M. KARAKURT and İ. İŞERİ, "Patoloji Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması," *Eur. J. Sci. Technol.*, no. 33, pp. 192–206, 2022, doi: 10.31590/ejosat.1011091.
- [4] R. Yan *et al.*, "Breast cancer histopathological image classification using a hybrid deep neural network," *Methods*, vol. 173, no. June 2019, pp. 52–60, 2020, doi: 10.1016/j.ymeth.2019.06.014.
- [5] S. Turan and G. Bilgin, "Semantic nuclei segmentation with deep learning on breast pathology images," *2019 Sci. Meet. Electr. Biomed. Eng. Comput. Sci. EBBT 2019*, pp. 13–16, 2019, [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2s2.085068555618&doi=10.1109%2FEBBT.2019.8741715&partnerID=40&md5=e9d930305bb4cf19019f476d9ad60018>
- [6] Y. Wang *et al.*, "Pathological Image Classification Based on Hard Example Guided CNN," *IEEE Access*, vol. 8, pp. 114249–114258, 2020, doi: 10.1109/ACCESS.2020.3003070.
- [7] K. Muzaki, "Breast Cancer Images on Histopathology Slides," 2020. <https://www.kaggle.com/datasets/forderation/breakhis-400x>
- [8] L. Zhu, X. Geng, Z. Li, and C. Liu, "Improving yolov5 with attention mechanism for detecting boulders from

- planetary images,” *Remote Sens.*, vol. 13, no. 18, pp. 1–19, 2021, doi: 10.3390/rs13183776.
- [9] A. ÇINAR, M. ERKUŞ, and T. TUNCER, “Türk İşaret Dilindeki Harflerin Tespiti İçin Derin Öğrenme Tekniğinin Kullanımı,” *Int. Conf. Sci. Innov. Stud.*, vol. 1, no. 1, pp. 360–365, Apr. 2023, doi: 10.59287/icsis.626.
- [10] A. T. Dang, “Accuracy and Loss: Things to Know about The Top 1 and Top 5 Accuracy,” 2021. <https://towardsdatascience.com/accuracy-and-loss-things-to-know-about-the-top-1-and-top-5-accuracy-1d6beb8f6df3>