Kolorektal Kanserin Histopatolojik Görüntülerinin Derin Öğrenme Modelleriyle Sınıflandırılması: Karşılaştırmalı Bir Çalışma

Classification of Histopathological Images of Colorectal Cancer with Deep Learning Models: A Comparative Study

Halise Nur AYDIN, Didem ÖLÇER
Bilgisayar Mühendisliği, Mühendislik Fakültesi
Başkent Üniversitesi
Ankara, Türkiye
{hnuraydin,dtokmak}@baskent.edu.tr

***Özetçe*—Kolorektal kanser dünyada kadınlarda ve erkeklerde üçüncü en sık görülen kanser türüdür. Ayrıca yıllar geçtikçe kanserin görülme oranları artış göstermektedir. Bu nedenle erken teşhis ve tedavi hayat kurtarmaktadır. Yapay zeka tabanlı sistemlerin gün geçtikçe ilerlemesi her alanda olduğu gibi sağlık alanına da önemli katkılar sunmaktadır. Bu çalışmada kolorektal kanserine ait histopatolojik görüntülerinin sınıflandırılması amaçlanmıştır. Bu doğrultuda Inception-ResNet-v2, Inception-v4 ve iyileştirilmiş Inception-v4 modelleri kolorektal kanser veri kümesi üzerinde eğitilmiş ve test edilmiştir. Modeller karşılaştırıldığında 0.9327 doğruluk değeri elde eden iyileştirilmiş Inception-v4 modeli diğer iki modelden daha iyi sonuç vermiştir.**

Anahtar Kelimeler — kolorektal kanser; Inception-ResNet-v2; Inception-v4; sınıflandırma.

***Abstract*—Colorectal cancer is the third most common cancer in men and women worldwide. In addition, the incidence of cancer has been increasing over the years. Therefore, early diagnosis and treatment save lives. The advancement of artificial intelligence-based systems daily makes important contributions to the health field as in every field. This study aims to classify histopathological images of colorectal cancer. Accordingly, Inception-ResNet-v2, Inception-v4 and improved Inception-v4 models were trained and tested on the colorectal cancer dataset. When the models are compared, the improved Inception-v4 model with an accuracy of 0.9327 outperforms the other two models.**

Keywords — colorectal cancer; Inception-ResNet-v2; Inception-v4; classification.

I. GİRİŞ

Kolon ve rektum kanseri tıp dilinde kolorektal kanseri olarak ifade edilmektedir. Kalın bağırsağın üst kısmında bulunan kolon ve alt kısmında bulunan rektum bölgelerinde ortaya çıkmaktadır [1]. Bu yerlerde görülen poliplerin yaklaşık olarak 5-10 yıl gibi bir zaman diliminde kansere dönüşme ihtimali bulunmaktadır [2]. Uluslararası Kanser Araştırma Ajansı (IARC) tarafından 2020 yılında yapılan çalışma verilerine göre erkeklerde ve kadınlarda dünyada üçüncü en sık görülen kanser türünün kolorektal kanser olduğu ifade edilmektedir. Aynı zamanda bu kanserin yıllar içinde genel olarak artış eğiliminde olduğu da belirtilmektedir [3]. Kolorektal kanserin oluşmasında çevresel ve genetik faktörler rol oynamaktadır. Genetik faktörler kanserin oluşmasını belirgin bir şekilde arttırabilirken kanserin oluşmasında çevresel faktörlerin genetik faktörlerden daha fazla etkili olduğu ifade edilmektedir [4].

Kolonoskopi, gaita gizli kan testi gibi tarama testleri ile polipler veya diğer kanser öncesi lezyonlar tespit edilerek henüz kansere dönüşmeden müdahale edilebilmektedir. Kolonoskopi yapılırken şüpheli görülen alanlardan küçük örnekler alınmakta ve doku hazırlığı yapılmaktadır. Doku hazırlığında alınan örnek kesitler halinde dilimlenerek hematoksilin ve eozin (H&E) boyalarla boyanmaktadır. Bu hücre yapılarının ve doku detaylarının daha belirgin hale gelmesini sağlamaktadır. Daha sonra bu boyanmış doku kesitleri patologlar tarafından incelenmekte ve değerlendirilmektedir. Elde edilen bu histopatolojik görüntüler, kolorektal kanserin teşhisinde en yaygın kullanılan tekniklerden biridir [5]. H&E boyasıyla boyanan doku örnekleri, mikroskop altında incelenerek kanser hücresinin varlığı, türü, derecesi ve yayılımı hakkında bilgi sağlamaktadır. Bu inceleme, doğru bir teşhis konulmasına ve uygun tedavi planının oluşturulmasına yardımcı olmaktadır.

979-8-3315-2981-9/24/$31.00 ©2024 IEEE

Diğer hastalıklarda da olduğu gibi kanser riskini azaltmak için erken dönemde fark edilmesi önem arz etmektedir. Erken teşhis, tedavide başarı şansının artmasına ve yayılmasının önlenmesine yardımcı olabilmektedir. Teşhis süresini kısaltmak, hekimlere yardımcı olmak, tarafsız karar ve yorum yapabilmek gibi amaçlarla yapay zeka tabanlı sistemler kullanılmaktadır. Son dönemlerde derin öğrenme modelleri kullanılarak hekimlerin iş yükünü azaltarak daha hızlı bir şekilde hastalık teşhisi yapılabilmektedir. Bu modellerin geliştirilmesi içinde literatürde çok sayıda çalışma yapılmış ve yapılmaktadır [6-8]. Bu çalışmaların tek amacı insanların yaşam kalitesini arttırmak ve erken teşhis ile ölüm oranlarını azaltmaktır.

Literatürde CRC-VAL-HE-7K veri kümesini kullanan birçok çalışma bulunmaktadır. Bu duruma örnek olarak Prezja ve arkadaşları [9] tarafından yapılan çalışmada VGG19 modelini temel olarak almışlar ve transfer öğrenmede modelin dondurulan katmanlarını sırayla çözüp modeli eğitmişlerdir. Sadece son evrişim katmanı ve yoğun katmanı dondurmamışlardır. İkinci evrişim bloğunun dondurulmasıyla en iyi sonuçlar elde edilmiştir. Yaptıkları çalışma iki farklı şekilde eğitim ve test edilmiştir. İlkinde CRC-VAL-HE-100K veri kümesi %70 eğitim, %15 doğrulama ve %15 test olacak şekilde ayrılmış ve sonuçlar alınmıştır. Elde edilen doğruluk değeri 0.995 bulunmuştur. İkinci durumda ise CRC-VAL-HE-100K veri kümesi üzerinde eğitilmiş ve CRC-VAL-HE-7K üzerinde test edilmiştir. Bu durumun sonucunda 0.956 doğruluk değeri elde etmişlerdir.

Shawesh ve Chen [10] yaptıkları çalışmada transfer öğrenme için ResNet50 modelini kullanmışlardır. Modeldeki ilk beş çoklu evrişim bloğu dondurulmuştur. Ayrıca modelin sonuna ortalama ortaklama katmanı, tam bağlantı katmanı ve softmax katmanı ekleyerek ince ayar yapmışlardır. Çalışmada CRC-VAL-HE-100K ve CRC-VAL-HE-7K veri kümeleri kullanılmıştır. 100K üzerinde eğitim yapılmış, 7K üzerinde test yapılmıştır. 0.977 doğruluk değeri elde etmişlerdir.

Ghosh ve arkadaşları [11] tarafından yapılan çalışmada Xception, DenseNet121, Inception-ResNet-v2 ve temel CNN modelleriyle bir ensemble derin öğrenme modeli oluşturmuşlardır. Bu modeller ilk başta bireysel olarak eğitilmişlerdir. Daha sonra bu modellerden elde edilen sonuçlar birleştirilerek ensemble model oluşturulup yeniden eğitilmiştir. Çalışmada CRC-VAL-HE-100K ve CRC-VAL-HE-7K veri kümeleri kullanılmıştır. 100K üzerinde eğitim yapılmış, 7K üzerinde test yapılmıştır.0.9616 doğruluk değeri elde etmişlerdir.

Tsai ve Tao yaptıkları [12] çalışmada beş derin öğrenme modeli kullanarak sınıflandırma yapmışlardır. Bu modeller AlexNet, SqueezeNet, VGGNet, GoogLeNet, ResNet'tir. Bu modeller kullanılarak farklı optimizasyon yöntemleri, epoch sayıları, mini-batch boyutu üzerinde değişiklikler yapılarak en iyi sonucu veren parametreler ve modeller bulunmuştur. Kullanılan optimizasyon yöntemleri SGDM, RMSProp ve Adam olarak belirlenmiştir. Seçilen epoch sayıları 10, 15, 20, 25 ve 30 iken seçilen mini-batch boyutları 8, 16, 32, 64 ve 128'dir. Çalışmada CRC-VAL-HE-100K ve CRC-VAL-HE-7K veri kümeleri kullanılmıştır. 100K üzerinde eğitim yapılmış, 7K üzerinde test yapılmıştır. En iyi epoch sayısı 20 bulunurken, en iyi mini-batch boyutu 32 olarak bulunmuştur. En iyi derin öğrenme modeli ise 0.9969 doğruluk değeri ile ResNet50 modeli olmuştur.

Bu çalışmada, kolorektal kanserine ait histopatolojik görüntüler içeren bir veri kümesinin derin öğrenme modelleri ile sınıflandırılması üzerine çalışılmıştır. Çalışmada kullanılan Inception-ResNet-v2, Inception-v4, iyileştirilmiş Inception-v4 modelleri veri kümesi üzerine ayrı ayrı beslenen bir sınıflandırma uygulaması tasarlanmıştır. Mevcut Inception-v4 modeli üzerinde iyileştirmeler yapılarak daha başarılı sınıflandırma yapan iyileştirilmiş Inception-v4 modeli önerilmiştir.

II. METOT VE METODOLOJİ

A. Sınıflandırıcılar

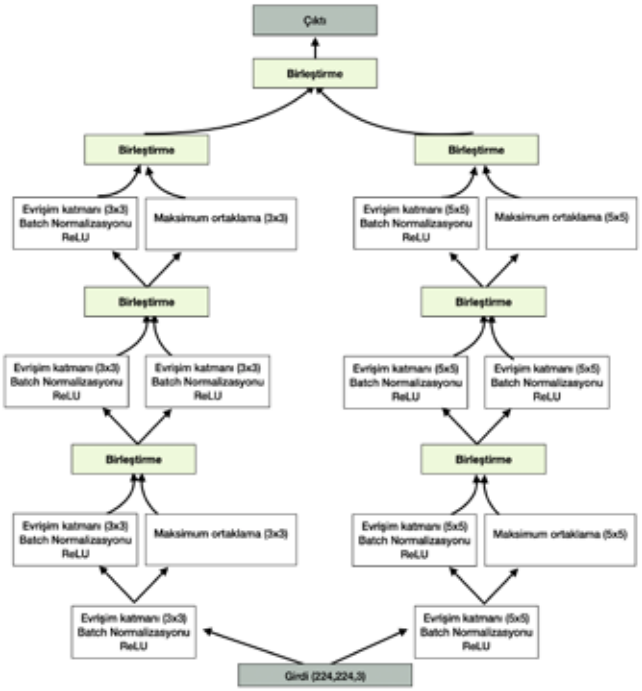
Bu çalışmada Inception-ResNet-v2 [13] ve Inception-v4 [13] modelleri kullanılmıştır. Buna ek olarak, Inception-v4 modelinde elde edilen başarıyı iyileştirmek adına mevcut yapıya eklemeler yapılmıştır.

Inception-ResNet-v2 modeli [13], Google tarafından geliştirilmiştir ve adından da anlaşılacağı üzere Inception blokları ile Residual blokların birleştirilmesiyle oluşturulmuştur. Inception blokları farklı ölçeklerdeki özellikleri çıkarmak için etkili bir yapıdır. Residual blokları ise çok derin ağları eğitirken gradyan problemini etkili bir şekilde çözmek için kullanılan bir yapıdır. Bu iki mimarinin de avantaj sağlayan taraflarının birleştirilmesiyle derin ve geniş bir model oluşturulmuştur. Model toplamda 164 katmandan oluşmaktadır ve ağın derinliği Residual katmanlar ile sağlanmaktadır. Amaç, modelin parametre miktarını azaltan ama etkili bir özellik çıkarımı sağlayabilen bir model ortaya çıkararak yüksek doğruluk sağlayabilmektir [14].

Inception-v4 modeli, Inception-v3 modelinin hesaplama karmaşıklığını azaltmak için oluşturulmuştur. Modelin genel yapısında bir stem bloğu, dört kez tekrarlanan A Inception bloğu, yedi kez tekrarlanan B Inception bloğu ve 3 kez tekrarlanan C Inception bloğundan oluşmaktadır. Bu Inception bloklarının ardından ağın hesaplama karmaşıklığını azaltmak, özellik haritalarının boyutunu küçültmek gibi amaçlarla modele Reduction blokları eklenmiştir. Model toplamda 72 katmandan oluşmaktadır. Inception-v4 modeli ile Inception-ResNet-v2 modeli hesaplama maliyeti birbirine denk sayılmaktadır [13].

Bu çalışma için iyileştirilmiş Inception-v4 modeli geliştirilmiştir. İyileştirilen modelin Inception stem bloğunun nasıl göründüğü Şekil 1'de verilmektedir. Bu modelin Inception-v4 modelinden farkı ise Inception stem bloğundaki mevcut yapının paralelinde 5x5'lik filtre kullanılmasıdır. Şekil

1'de sol tarafta gösterilen kısım Inception-v4 modelinde 3x3'lük filtreler kullanılırken, iyileştirmek için paraleline eklenen ve farklı bölgelerdeki özelliklere dikkat edebilmesi amacıyla 5x5'lik filtre kullanılmıştır. Bloğun sol tarafı ile sağ tarafı en son birleştirilmiştir.



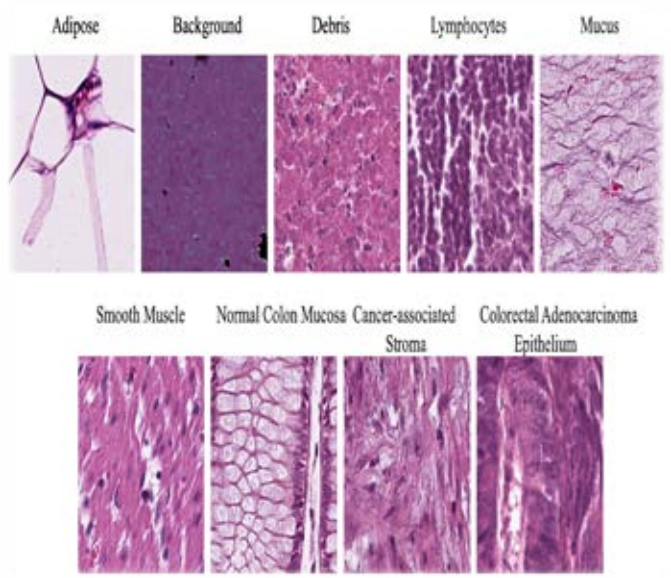
Şekil. 1. İyileştirilmiş Inception stem bloğu

B. *Veri kümesi*

CRC-VAL-HE-7K [15] veri kümesi kolorektal kanseri histopatolojik görüntüleri içermektedir. Bu görüntüler NCT Biobank ve UMM patoloji arşivlerindeki 50 hastadan alınarak oluşturulmuştur. Görüntüler 224x224 boyutlarında olup toplamda 7180 görüntüye ve 9 etikete sahiptir. Bu etiketlere ait isimler ve görüntü sayıları Tablo 1'de, görüntü örnekleri ise Şekil 2'de verilmiştir.

TABLO I. VERİ KÜMESİNDEKİ TÜRLER VE BU TÜRLERİN SAYILARI

Tür	*Görüntü Sayısı*
Adipose (ADI)	1338
Background (BACK)	847
Debris (DEB)	339
Lymphocytes (LYM)	634
Mucus (MUC)	1035
Smooth Muscle (MUS)	592
Normal Colon Mucosa (NORM)	741
Cancer-Associated Stroma (STR)	421
Colorectal Adenocarcinoma (TUM)	1233



Şekil. 2.Veri kümesindeki etiketlere ait örnek görüntüler [15]

III. DENEYSEL ÇALIŞMA VE SONUÇLAR

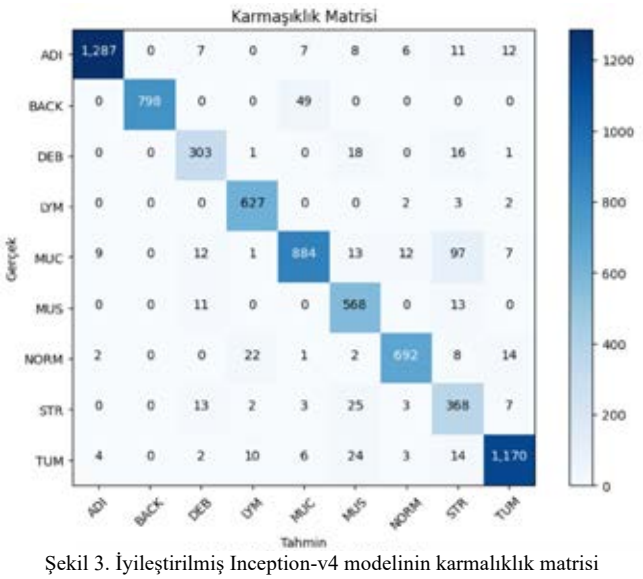
Deneysel çalışmada "stratified k-fold" çapraz doğrulama yöntemi kullanılarak her fold'un dengeli bir şekilde tutulması amaçlanmıştır. Bu yöntemde veri kümesindeki bütün görüntüler hem eğitimde hem de testte kullanılmaktadır. Dolayısıyla eğitim ve test için görüntüler ayrılırken oluşabilecek dengesiz dağılımın önüne geçilmiştir. Bu çalışma için *k* değeri 10 seçilmiştir. Modeller için seçilen diğer parametreler şu şekildedir: mini-batch boyutu 32, epoch 30, öğrenme oranı 0.001'dir. Böylelikle çalışma da kullanılan modellerin performansı eşit koşullar altında karşılaştırılmıştır. Doğruluk, kesinlik, F1-skor, duyarlılık, ve MCC değerlendirme metrikleri kullanılarak modelin performansı hesaplanmıştır.

TABLO II. SINIFLANDIRMA PERFORMANSLARI

Metrikler	*Inception-ResNet-v2*	*Inception-v4*	*İyileştirilmiş Inception-v4*
Doğruluk	0.8033	0.9017	**0.9327**
Kesinlik	0.7954	**0.8763**	0.8134
Duyarlılık	0.6863	0.8027	**0.9285**
F1 Skor	0.7752	0.8836	**0.9192**
MCC	0.7779	0.8890	**0.9232**

Inception-ResNet-v2, Inception-v4, ve iyileştirilmiş Inception-v4 modelleri kullanılarak kolorektal kanser görüntülerinin sınıflandırılması sonucunda elde edilen performans metrikleri Tablo 2'de gösterilmektedir. En iyi performansa sahip iyileştirilmiş Inception-v4 modelinin doğruluk, kesinlik, duyarlılık, F1 Skoru ve MCC değerleri sırasıyla 0.9327, 0.8134, 0.9285, 0.9192 ve 0.9232 elde edilirken, Inception-ResNet-v2 ve Inception-v4 modellerinin başarısı iyileştirilmiş Inception-v4 modelinin altında kalmıştır.

Ancak Inception-v4 modeli ile elde edilen sonuçlar da oldukça ümit vericidir.



Şekil 3. İyileştirilmiş Inception-v4 modelinin karmalıklık matrisi

En iyi sonucu veren iyileştirilmiş Inception-v4 modelinin yapmış olduğu doğru sınıflandırmalarını değerlendirmek ve doğru ile yanlış sınıflandırma sayılarını belirlemek için karmaşıklık matrisi Şekil 3'te verilmektedir.

IV. Tartışma ve Sonuç

Bu çalışmada, histopatolojik kolorektal görüntüleri kullanılarak sınıflandırma yapmak için derin öğrenme tabanlı modeller kullanılmıştır. Ayrıca kullanılan modellere ek olarak iyileştirilmiş bir model de kullanılarak diğerlerinden yüksek başarı elde edilmiştir. Literatürdeki çalışmalar [9-12] genellikle CRC-VAL-HE-100K veri kümesi ile eğitilip bu çalışma da kullanılan CRC-VAL-HE-7K veri kümesi ile test edilmiştir. Bu çalışmada 7000 görüntü ile kullanılan modellerin elde edilen doğruluk başarılarına bakıldığında 100.000 görüntü ile eğitilen modellere göre yüksek doğruluk elde ettiği açıkça söylenebilmektedir. En iyi performansa ise iyileştirilmiş Inception-v4 modeli ile ulaşılırken Inception-v4 modelinin de yüksek sonuca yaklaştığı gözlemlenmiştir. İyileştirilmiş Inception-v4 modelinin Inception-v4 modelinden daha iyi sonuç vermesinin nedeni farklı filtre boyutları ile de özellik çıkarımı gerçekleştirerek modelin daha iyi öğrenmesini sağlaması söylenebilir.

Veri kümesindeki etiket sayılarının dengeli olmaması çalışmada kullanılan modellerin yüksek başarı elde etmesini etkilemektedir. Gelecekteki çalışmalarda veri kümesindeki etiketler arasındaki farkı kapatmak amacıyla birtakım veri arttırma işlemleri kullanılacaktır. Ayrıca hastalığın sınıflandırılması için farklı modeller ile çözüm aranacaktır.

Kaynaklar

[1] Centelles, J. J. (2012). General aspects of colorectal cancer. *International Scholarly Research Notices*, *2012*(1), 139268.

[2] Saif, M. W., and Chu, E. Biology of colorectal cancer. (2010) *The Cancer Journal* 16(3), 196-201.

[3] Deniz, E. B. (2022). Kanser Epidemiyolojisi. *Turkey Health Literacy Journal*, *3*(2), 102-111.

[4] Soytürk, M. (2005). Kolorektal kanser epidemiyoloji ve risk faktörleri. *Ulusal İç Hastalıkları Kongresi*.

[5] Çelik, G. (2023). Histopatolojik Görüntülerden Kolon Kanseri Tespiti için EfficientNetB0 ve DVM Tabanlı Yaklaşım. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, *35*(2), 771-781.

[6] *Haner Kırğıl, E. N., & Erdaş, Ç. B. (2024). Enhancing Skin Disease Diagnosis Through Deep Learning: A Comprehensive Study on Dermoscopic Image Preprocessing and Classification. International Journal of Imaging Systems and Technology, 34(4), e23148.*

[7] *Şener, B., Acici, K., & Sümer, E. (2024). Categorization of Alzheimer's disease stages using deep learning approaches with McNemar's test. PeerJ Computer Science, 10, e1877.*

[8] *Ölçer, D., & Erdaş, Ç. B. (2023, November). Noisy Label-Resistant Deep Learning Methods for Cancer Diagnosis in Histopathology Images. In 2023 Medical Technologies Congress (TIPTEKNO) (pp. 1-4). IEEE.*

[9] Prezja, F., Äyrämö, S., Pölönen, I., Ojala, T., Lahtinen, S., Ruusuvuori, P., & Kuopio, T. (2023). Improved accuracy in colorectal cancer tissue decomposition through refinement of established deep learning solutions. *Scientific Reports*, *13*(1), 15879.

[10] Al. Shawesh, R., & Chen, Y. X. (2021). Enhancing histopathological colorectal cancer image classification by using convolutional neural network. *MedRxiv*, 2021-03.

[11] Ghosh, S., Bandyopadhyay, A., Sahay, S., Ghosh, R., Kundu, I., & Santosh, K. C. (2021). Colorectal histology tumor detection using ensemble deep neural network. *Engineering Applications of Artificial Intelligence*, *100*, 104202.

[12] Tsai, M. J., & Tao, Y. H. (2021). Deep learning techniques for the classification of colorectal cancer tissue. *Electronics*, *10*(14), 1662.

[13] Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017, February). Inception-v4, inception-resnet and the impact of residual connections on learning. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 31, No. 1).

[14] Peng, C., Liu, Y., Yuan, X., & Chen, Q. (2022). Research of image recognition method based on enhanced inception-ResNet-V2. *Multimedia Tools and Applications*, *81*(24), 34345-34365.

[15] Kather, J. N., Halama, N., & Marx, A. (2018). 100,000 histological images of human colorectal cancer and healthy tissue (v0.1) [Data set]. Zenodo. https://doi.org/10.5281/zenodo.1214456