

Histopatolojik Görüntülerden Kolon Kanseri Tespiti için EfficientNetB0 ve DVM Tabanlı Yaklaşım

Gaffari ÇELİK^{1*}

¹ Bilgisayar Teknolojileri Bölümü, Meslek Yüksekokulu, Ağrı İbrahim Çeçen Üniversitesi, Ağrı, Türkiye
^{*1} gcelik@agri.edu.tr

(Geliş/Received: 06/07/2023;

Kabul/Accepted: 12/08/2023)

Öz: Kolon kanseri, gelişmiş ülkelerde ciddi bir sağlık sorunu olmakta ve en sık görülen kanser türleri arasında gelmektedir. Bu hastalığın erken teşhisi hastaların hayatta kalma şansını artırmaktadır. Geciken teşhisler ise ölümlerle sonuçlanabilmektedir. Bu çalışmada kolon kanseri tespiti için EfficientNetB0 ve destek vektör makineleri (DVM) tabanlı bir model önerilmiştir. EfficientNetB0 mimarisi ile histopatolojik görüntülerden öznetelik haritalarının çıkarılması sağlanırken, DVM algoritması ile elde edilen öznetelik haritalarının sınıflandırılması gerçekleştirilmektedir. Ayrıca önerilen modelin başarısını analiz etmek üzere EfficientNetB0, Xception, VGG19, InceptionV3, DenseNet121 ve ResNet101 gibi evrişimli sinir ağları (ESA) mimarileri ile performans kıyaslaması yapılmıştır. Veri kümesi olarak sekiz sınıflı Kather-5k ve iki sınıflı LC25000 veri kümeleri kullanılmıştır. Elde edilen bulgular, önerilen modelin Kather-5k veri kümesi kullanıldığında %99.70 doğruluk, %100 kesinlik, %100 duyarlılık, %100 F1-Score, %99.71 G-ortalama, %100 özgüllük ve %99.83 AUC ile mevcut ESA mimarilerine kıyasla daha yüksek başarı sağladığını göstermiştir. LC25000 veri kümesi kullanıldığında ise önerilen model tüm metriklerde %100 başarı elde etmiştir. Benzer şekilde Kather-5k ve LC25000 veri kümeleri birleşiminden oluşan veri kümesi kullanıldığında önerilen model, %99.96 doğruluk, %100 kesinlik, %100 duyarlılık, %100 F1-Score, %99.92 G-ortalama, %100 özgüllük ve %99.96 AUC oranı ile diğer modellere kıyasla daha yüksek performans göstermiştir. Ayrıca önerilen model ile EfficientNetB0 mimarisinin başarısında önemli oranda bir başarı artışı sağlanmıştır.

Anahtar kelimeler: Kolon kanseri, evrişimli sinir ağları, EfficientNetB0, destek vektör makineleri

EfficientNetB0 and SVM Based Approach for Colon Cancer Recognition from Histopathological Images

Abstract: Colon cancer is a significant health issue in developed countries and ranks among the most common types of cancer. Early diagnosis of this disease increases the chances of survival for patients, while delayed diagnosis can lead to fatal outcomes. In this study, an EfficientNetB0 and Support Vector Machines (SVM) based model has been proposed for colon cancer detection. The EfficientNetB0 architecture is utilized to extract feature maps from histopathological images, and the SVM algorithm is employed to classify the obtained feature maps. Furthermore, to analyze the performance of the proposed model, a comparison is made with convolutional neural network (CNN) architectures such as EfficientNetB0, Xception, VGG19, InceptionV3, DenseNet121, and ResNet101. The datasets used for the study are the eight-class Kather-5k and the two-class LC25000 datasets. The findings indicate that the proposed model achieves higher success rates compared to existing CNN architectures on the Kather-5k dataset, with an accuracy of 99.70%, precision of 100%, recall of 100%, F1-Score of 100%, G-mean of 99.71%, specificity of 100%, and an AUC of 99.83%. Similarly, on the LC25000 dataset, the proposed model achieves 100% success rates in all metrics. When the combined dataset of Kather-5k and LC25000 is used, the proposed model demonstrates better performance compared to other models with an accuracy of 99.96%, precision of 100%, recall of 100%, F1-Score of 100%, G-mean of 99.92%, specificity of 100%, and an AUC of 99.96%. In addition, with the proposed model, a significant increase in success has been achieved in the success of the EfficientNetB0 architecture.

Key words: Colon cancer, convolutional neural networks, EfficientNetB0, support vector machines

1. Giriş

Kolorektal kanseri (CRC) olarak da bilinen kolon kanseri kalın bağırsağın parçaları olan kolon veya rektumda ortaya çıkar. Bu kanser türü gelişmiş ülkelerde sıklıkla görülmekte ve Amerikan Birleşik Devletleri'nde kadınlar ve erkekler arasında görülen kanser türleri arasında üçüncü sırada gelmektedir. Sadece 2020 yılında, dünya çapında yaklaşık 1.93 milyon yeni kolorektal kanser vakasının görüldüğü ve bu hastalığın 0.94 milyon insanın ise ölümüne neden olduğu tahmin edilmektedir. Bu durumun, her on kanser vakasının hastalıkla ya da ölümlerle sonuçlandığı anlamına geldiğini göstermektedir [1, 2]. Ayrıca, 2040 yılına kadar küresel yeni vakaların 3.2 milyona ulaşacağı öngörülmektedir. CRC' nin artış eğiliminde olması ve artan küresel yükü, dünya sağlık sistemlerine büyük

* Sorumlu yazar: gcelik@agri.edu.tr. Yazarın ORCID Numarası: ¹ 0000-0001-5658-9529

sıkıntılar yaratmaktadır. Erken ve doğru teşhis, tedavinin etkinliğini artırmakla beraber bu rakamları önemli ölçüde azaltabilir ve hastaların sağkalım oranının artmasında da önemli rol oynar [3, 4].

Histopatolojik inceleme tıpta kolorektal kanseri teşhisinde en çok kullanılan yöntemdir. Bu yöntemde, kanserli dokular patolog tarafından mikroskop altında incelenir. Doku değişikliklerini ve hücreleri gözlemleyerek buna göre teşhis konur [5, 6]. Ancak, bu süreç profesyonel uzmanlık gerektiren, zaman alıcı, sıkıntılı ve zorlu bir süreçtir. Bu süreçte, hekimlerin verileri yanlış yorumlamasıyla sonuçlanabilir. Bu da doğruluk oranını azaltarak erken teşhise engel olabilir [2, 7].

Kolon kanseri dört evreden oluşur. Belirli evrelerde, kolon kanseri hastalarının hayatta kalma şansı önemli ölçüde değişiklik göstermektedir. 18 ile 65 yaş arasındaki kişilerde kolon kanseri birinci evrede teşhis edilirse, etkili tedavi ile %94 hayatta kalma şansına sahiptir. Ancak ileri evrelerde hayatta kalma oranları sırasıyla ikinci evrede %87, üçüncü evrede %74 ve dördüncü evrede %19'a kadar düşmektedir [8, 9]. Kolon kanseri hastalarının hayatta kalma olasılığı tüm yaş gruplarında ele alındığında birinci evrede %70 iken dördüncü evrede %13 gibi çok düşük bir orana düşmektedir. Kesin bir kanser tedavisi olmadığından, erken teşhis edilen hastalar, doktorların tedavi planı oluşturmak için daha fazla zamanı olur ve bu da hastanın hayatta kalma şansını artırır. Erken teşhis ve tedavi, kansere bağlı ölümleri önlemenin tek yoludur. Ancak, birçok insan, bu ölümcül hastalığa karşı mücadelede yetkin teşhis merkezlerine erişimden yoksundur, bu da mücadeleyi daha da zorlaştırmasına neden olmaktadır [8, 10].

Kolon kanseri, patolojik görüntüler kullanılarak Yapay Zeka (AI) teknikleri ile teşhis edilme potansiyeline sahiptir [5]. AI teknikleri ile elde edilen bulgular sayesinde geleneksel yöntemlere alternatif olarak görülmektedir. Bir hastalığın teşhisi hastadan alınan bilgiye bağlı olarak bir uzman tarafından yapılmaktadır. Dijital ortamlarda tutulan hasta numuneleri AI teknikleri aracılığı ile başarılı bir şekilde işlenerek hastalık tespiti yapılması mümkündür. Son dönemlerde geliştirilen Derin öğrenme (DL) algoritmaları kullanılarak çok boyutlu görüntülerden hastalık teşhisi yapılmakta ve video analizi gerçekleştirilebilmektedir. Ayrıca DL teknikleri, uzmanların iş yükünü büyük ölçüde azaltmakla beraber hastalık teşhisi daha hızlı bir şekilde gerçekleştirilebilmektedir [5, 8].

Histopatolojik görüntülerden kolon kanseri tespiti için yapılan bu çalışmada temel katkılarımızın bir özeti aşağıda verilmiştir:

- Kolon kanseri teşhisi için EfficientNetB0, Xception, VGG19, InceptionV3, DenseNet121 ve ResNet101 gibi ESA mimarilerinin performansları incelenmiştir
- EfficientNetB0 ve DVM temelli yeni bir model önerilmiştir.
- EfficientNetB0 mimarisini ile histopatolojik görüntülerden öznelik haritalarının çıkarılması sağlanmış ve çıkarılan öznelik haritaları DVM algoritması ile sınıflandırılmıştır.
- Önerilen EfficientNetB0 ve DVM temelli model ile EfficientNetB0 mimarisinin performansında önemli oranda bir iyileştirme sağlanmıştır.

2. İlgili Çalışmalar

Kolon kanseri tespiti için son dönemlerde yapılmış birçok çalışma bulunmaktadır. Rathore vd. [11] tarafından gerçekleştirilen çalışmada, kolon dokularının öznelikleri matematiksel olarak modelleyen yeni bir teknik önerdiler. Makale, normal ve habis kolon örneklerini ayırt etmek için Hibrit Özellik Alanı Tabanlı Kolon Sınıflandırma (HFS-CC) yöntemini sundular. 174 kolon biyopsi görüntüsü üzerinde yapılan çalışmada HFS-CC tekniği ile %98.07 test doğruluğuna ulaştılar. Toraman vd. [12] kolon kanseri tespiti için Fourier Dönüşümü Kızılötesi (FTIR) spektroskopisi yöntemi kullanarak sinyallerden çeşitli istatistiksel özellikler topladılar. Çalışma kapsamında 30 kolon kanseri hastası ve 40 sağlıklı kişiden kan örnekleri (plazma) toplanarak FTIR sinyal ölçümleri gerçekleştirilmiştir. Her bir FTIR sinyalinden altı istatistiksel özellik, beş alan oranı ve beş yükseklik oranı olmak üzere toplam 16 öznelik elde ettiler. El edilen bu 16 öznelik, YSA ve DVM ile sınıflandırdılar YSA ile %95.71 doğruluk elde ettiler. Toğaçar [13], DL tabanlı DarkNet19 modeli kullanarak yeni bir model önerdi. DarkNet19 modeli ile elde edilen öznelikler Equilibrium ve Manta Ray Foraging optimization algoritmaları kullanarak önemli öznelikleri optimize etti. DVM algoritması ile optimize edilen öznelikler sınıflandırarak %99.69 doğruluk elde etti. Garg vd. [14] ise LC25000 veri setini kullanarak histopatolojik görüntülerden akciğer ve kolon kanseri tespiti için önceden eğitilmiş sekiz ESA (ResNet50, Xception, MobileNet, VGG16, InceptionResNetV2, DenseNet169, NASNetMobile ve InceptionV3) mimarisini kullandılar. Sekiz model ile %96 ve %100 arasında değişen doğruluk elde ettiler. Urban vd. [15] 2000 kişiden aldıkları 4.088 benzersiz polip içeren 8641 kolonoskopi görüntüsünü ve ESA tekniğini kullandılar. Önerdikleri modeli toplam süresi beş saat olan 20 kolonoskopi videosu üzerinde test ederek %96 oranında doğruluğa ulaştılar.

Babu vd. [16], kolon kanserinin varlığını tahmin etmek için kolon biyopsi görselleri kullandılar. İlk olarak, görüntüleri HSV (Hue-Saturation-Value) düzlemine aktardılar. Daha sonra Dual-tree ve double-densite 2-D dalgacık dönüşümü tekniklerini kullanarak öznelik çıkardılar. Sonra olarak RF (Random Forest) tabanlı sınıflandırma algoritması kullanarak çıkarılan öznelikleri sınıflandırdılar ve %85.4 doğruluk elde ettiler. Masud vd. [17] iyi huylu ve kötü huylu kolon dokularını içeren bir veri kümesi kullandılar. Kanser tespiti için DIP (Dijital Görüntü İşleme) ve ESA yöntemlerini kullanarak bir sınıflandırma çerçevesi oluşturdu. Önerdikleri çerçeve yöntemi ile %96.33 doğrulukla kanser dokularını tespit ettiler. Jiao vd. [18] tarafından yapılan diğer bir çalışmada, görüntülerden öznelik çıkarımı için Gri Düzey Eşzamanlı Oluşum Matrisi (Gray-Level Co-occurrence Matrix, GLCM), gri tonlama varyansı ve gri tonlama ortalaması tekniklerini kullandılar. GLCM yöntemi ile 16 öznelik, gri tonlama varyansı ve gri tonlama ortalaması tekniklerinden birer öznelik olmak üzere toplam 18 öznelik çıkardılar. Çıkarılan öznelikler DVM yöntemi ile sınıflandırdılar ve %96,67 kesinlik (precision), %83,33 hatırlama (recall) ve %89.51 F-measure elde ettiler.

Kolon kanseri tespiti için Tasnim vd. [19] tarafından yapılan diğer bir çalışmada, ortalama havuzlama katmanları ve maksimum havuzlama katmanlarına sahip ESA tabanlı yöntem ile mevcut MobileNetV2 yöntemi kullanılmıştır. ESA modeli ile %97.49 doğruluk elde ederken MobileNetV2 mimarisi ile %99,67 doğruluk elde ettiler. Qasim vd. [20] tarafından yapılan diğer bir çalışmada ESA tabanlı bir model önerdi. Aynı zamanda önerilen modelin performansını değerlendirmek için VGG16 mimarisini aynı veri kümesi üzerinde eğittiler. 5000 kolon adenokarsinomu ve 5000 de iyi huylu kolon olmak üzere toplamda 10000 histopatolojik görüntü içeren veri kümesi kullandılar. VGG16 mimarisi ile %96.2 doğruluk elde ederken önerdikleri model ile %99.6 doğruluk elde ettiler.

“Deneysel Çalışmalar ve Sonuçları” bölümünde önerilen model ile elde edilen bulgular verilmiştir. Elde edilen bulgular incelendiğinde önerilen model Kather-5k veri kümesi ile %99.70 doğruluk, LC25000 veri kümesi ile %100 doğruluk ve bu iki veri kümesinin birleşiminden ise %99.96 oranında yüksek bir doğruluk elde edilmiştir. Yukarıda verilen benzer çalışmalar ile önerilen modelin performansı değerlendirildiğinde önerilen modelin son derece yüksek bir başarı gösterdiği görülmektedir. Önerilen modelin yüksek bir performans sergilemesi ise temel yapısını oluşturan EfficientNetB0 mimarisi ile elde edilen önemli öznelik haritalarından kaynaklandığını söyleyebiliriz. Ayrıca literatürde öznelik haritalarının çıkarılmasının önemi çalışma [21] ve [22]’de açıkça verilmiştir.


3. Materyal

Bu çalışmada kolon kanseri tespiti için Kather-5k [23, 24] ve LC25000 [25] olmak üzere iki farklı veri kümesi kullanıldı. Kather-5k veri kümesi, Tümör (tümör epiteli), Stroma (tümör stroması), Kompleks (tek bağışıklık hücreleri ve/veya tek tümör hücreleri içeren kompleks stroma), Lympho (bağışıklık hücresi konglomeraları), Debris (nekrozu, kanamayı ve mukusu kucaklayan enkaz), Mucosa (mukozal bezler), Adipose (yağ dokusu) ve Boş (arka plan) olmak üzere sekiz sınıfa ait histopatolojik görüntüleri içermektedir. Her bir sınıfta 625 olmak üzere toplamda 5000 görüntü bulunmakta ve görüntüler 150×150 çözünürlüktedir.

LC25000 veri kümesinde kolon görüntüsü olarak 5000 görüntü kolon iyi huylu doku (Colon Benign Tissue) ve 5000 kolon adenokarsinomu (Colon Adenocarcinoma) görüntüsü bulunmaktadır. Herkesin erişimine açık olan Kather-5k veri kümesine “<https://zenodo.org/record/53169>” bağlantısından ve LC25000 veri kümesine ise “<https://124.im/6t2a>” bağlantısı kullanılarak erişim sağlanabilir. Veri kümeleri ile ilgili detaylı bilgi ayrıca Tablo 1’de sunulmuş olup örnek görüntüler Şekil 1’de gösterilmiştir.

Tablo 1. Kather-5k ve LC25000 veri kümeleri özellikleri

Veri kümesi	Kanser Türü	Tanım	Görüntü sayısı	Görüntü Boyutu
Kather-5k	Tümör	Tümör epiteli	625	150x150
	Stroma	Tümör stroması	625	150x150
	Kompleks	Tek bağışıklık hücreleri ve/veya tek tümör hücreleri içeren kompleks stroma	625	150x150
	Lympho	Bağışıklık hücresi konglomeraları	625	150x150
	Debris	Nekrozu, kanamayı ve mukusu kucaklayan enkaz	625	150x150
	Mucosa	Mukozal bezler	625	150x150
	Adipose	Yağ dokusu	625	150x150
	Boş	Arka plan	625	150x150
	LC25000	Kolon_aca	Kolon adenokarsinomu	5000
Kolon_n		Kolon iyi huylu doku	5000	768x768

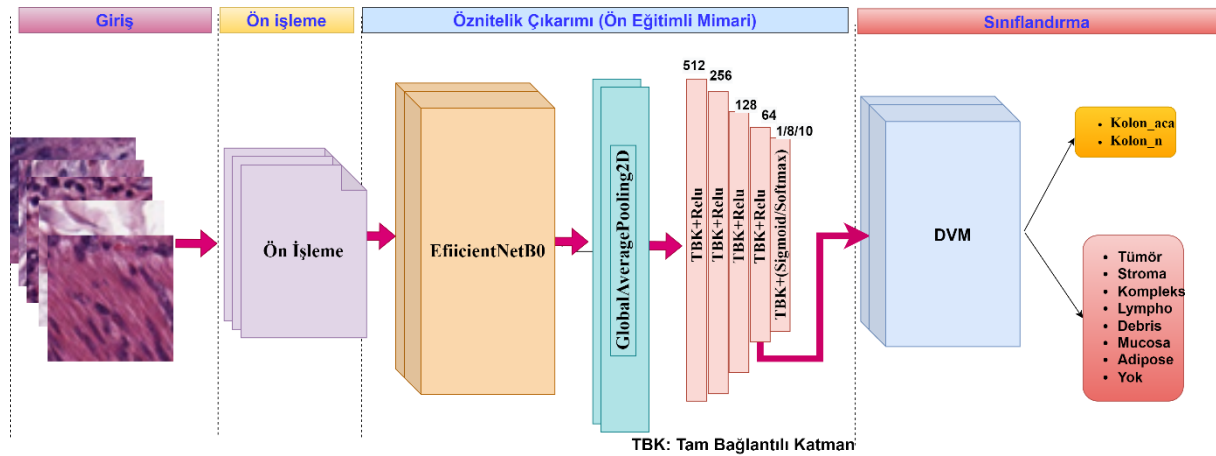


Şekil 1. Kather-5k ve LC25000 veri kümelerinde bulunan sınıflara göre örnek görüntüler

4. Metot

Bu çalışmada kolon kanseri tespiti için DL' nin alt dalı olan ESA ve DVM tabanlı bir yöntem önerilmiştir. DL mimarileri, ham girdi verilerinden istenilen bilgiyi elde etmek amacıyla derin bir ağ yapısına sahip temsili öğrenme algoritmalarıdır. DL, bir biri ile bağlantılı katmanlardan oluşur ve veriler katmanlar aracılığıyla işlenir. Katmanlardan elde edilen öznitelikler bir sonraki katmana aktararak daha detaylı incelenmesi sağlanır [26, 27].

ESA, çok katmanlı derin ağ mimarisine sahip ve doğal görsel algılama mekanizmasından ilham alan DL yöntemlerinin bir alt dalıdır. ESA mimarileri, görüntü işleme, DNA işleme ve örüntü tanıma gibi birçok alanda uygulanan en etkili DL mimarilerinden biri olarak görülmektedir [28, 29]. ESA mimarileri, evrişim katmanı, havuzlama katmanı ve birbiri ile bağlantılı katmanlar olmak üzere genellikle üç temel kategoriye sahiptirler. Evrişim katmanları, evrişim işlemi ile giriş verisinden anlamlı öznitelik haritaları çıkarmak için kullanılır. Havuzlama katmanı, veri boyutunu düşürerek işlenmesini hızlandırmak ve gereksiz bilgileri elemek amacıyla kullanılır. Birbiri ile bağlantılı katmanlar aracılığı ile öznitelikler vektörel hale getirilerek aktivasyon fonksiyonları (sigmoid, softmax ve tanh) yardımı ile tahmin işlemi gerçekleştirilir [30, 31]. Literatürde ESA mimarileri kullanılarak, asfalt çatlaklarının tespiti [32], fiziksel hareketlerden aktivite belirleme [33], yazılım güvenlik açıklarının sınıflandırılması [34]; ses, nefes ve öksürükten Covid-19 tespiti [35], alzheimer hastalığının sınıflandırılması [36], beyin tümörü tespiti [37], insan aktivite türlerinin tespiti [38], timpanik membran görüntülerinin sınıflandırılması [39] ve beyin kanaması tespiti [40] gibi birçok alanda başarılı bir şekilde uygulanmıştır.



Şekil 2. Önerilen modelin metodolojisi.

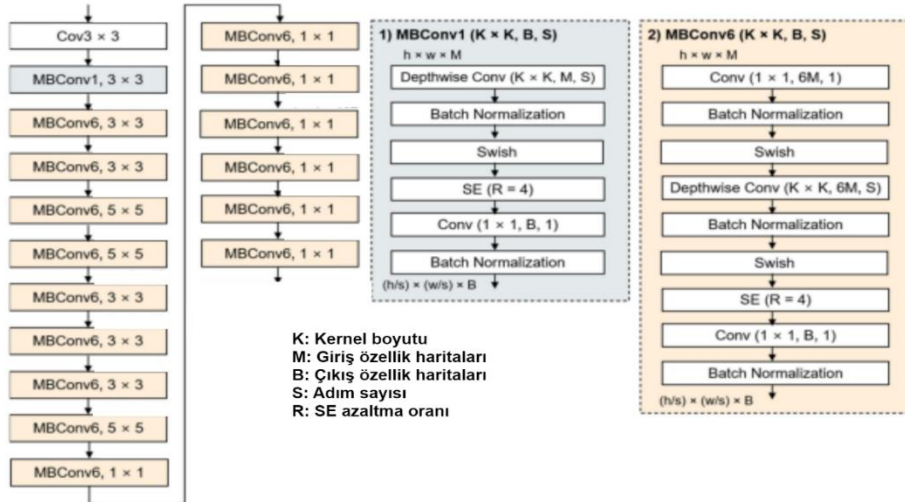
4.1. Önerilen metot

Kolon kanseri tespiti için yapılan bu çalışmada EfficientNetB0 mimarisini ve DVM algoritmasını temel alan bir model önerilmiştir. Önerilen modelin metodolojisi Şekil 2'de sunulmuştur. Önerilen model giriş, ön işleme, öznitelik çıkarımı ve sınıflandırma olmak üzere dört aşamadan oluşmaktadır. Giriş aşamasında Kather-5k ve LC25000 veri kümelerindeki histopatolojik görüntüler kullanılmaktadır. Ön işleme aşamasında görüntüler

128×128 boyutuna indirgenerek EfficientNetB0 mimarisine girdi olarak verilmektedir. Öznitelik çıkarımı aşamasında girdi görüntüleri sırasıyla EfficientNetB0, GlobalAveragePooling2D ve art arda beş tam bağlantılı katmanı ile eğitilerek özniteliklerin çıkarımı sağlanmıştır. Daha sonra dördüncü tam bağlantılı katmandan (64) elde edilen öznitelikler DVM algoritması kullanılarak sınıflandırma işlemi gerçekleştirilmektedir. Öznitelikler dördüncü tam bağlantılı katmandan (64) özetlendiği için bu katman seçilmiştir. İlk dört tam bağlantılı katmandan sonra Relu aktivasyon fonksiyonu kullanılmıştır. Son tam bağlantılı katmandan sonra iki sınıflı veri kümesinin (LC25000) eğitimi için aktivasyon fonksiyonu olarak Sigmoid, çok sınıflı veri kümesinin (Kather-5k) eğitimi için Softmax aktivasyon fonksiyonu kullanılmıştır. İlk dört tam bağlantılı katmanlarda nöron sayısı 512, 256, 128 ve 64 olarak belirlenmiştir. Son tam bağlantılı katmanda nöron sayısı veri kümesindeki sınıf sayısına bağlı olarak 1, 8 ya da 10 olarak ayarlanmıştır.

4.1.1. EfficientNetB0 mimarisi

EfficientNet mimarisi Tan ve Le [41] tarafından 2019 yılında önerilmiştir. EfcientNet ailesi, ESA modellerini geliştirmek için basit ve oldukça etkili bir ölçeklendirme katsayısı temel alır. Ölçeklendirme katsayısı genişlik, derinlik ve çözünürlük gibi ağ boyutlarını dengeleyerek ağın verimli bir şekilde çalışmasını sağlar. Uygulamada, tek tek boyutları ölçeklendirmek model performansını artırırken, ağı tüm boyutlarını mevcut kaynaklara göre dengelemek, genel performansı etkili bir şekilde artırır. EfficientNetB0 mimarisi MBConv bloklarını kullanır. Bu mimaride giriş verisine ilk olarak bir evrişim işlemi uygulanır. Daha sonra bir MBConv1 bloğu ve 15 MBConv6 bloğa tabi tutulmaktadır. Bloklarda Swish aktivasyon fonksiyonu kullanılmaktadır. Ayrıca mimarinin performansının iyileştirilmesine katkı sağlamak amacıyla MBConv bloklarına küçültme ve genişletme (Squeeze-and-Excitation, SE) dikkat modülü dahil edilmiştir [42]. Şekil 3’ te EfficientNetB0 mimarisinin temel yapısı verilmiştir.



Şekil 3. EfficientNetB0 mimarisi: 1) MBConv1 ve 2) MBConv6 bloklarının temel yapısını göstermektedir [43].

4.1.2. DVM

DVM, sınıflandırma ve regresyon problemlerinde kullanılan denetimli öğrenme modelidir. DVM, temel olarak doğrusal veriler için kullanılır. Ancak DVM doğrusal olmayan verileri, çekirdek işlevi aracılığı ile doğrusal özellik uzayına taşıyarak doğrusal olmayan problemlerde kullanılabilme yeteneğine sahiptir. Çekirdek fonksiyonu aracılığı ile n-boyutlu doğrusal olmayan veriler, m-boyutlu yeni bir uzayda ($m > n$) doğrusal olarak ayarlanır. Daha sonra veriler iki sınıfa ayırmak için hiper düzlemler kullanılır. Sınıflandırma işlemi için en yüksek sınıra sahip lineer fonksiyonu bulunması amaçlanır. N lineer olarak ayrılabilen veri kümesini $\{(x_1, y_1), \dots, (x_n, y_n)\}$ göz önünde bulundurduğumuzda en yüksek sınır sınıflandırıcı $f(x) = \text{sgn}(w \cdot x + b)$ fonksiyonu ile bulunur. Burada w ve b iki sınıfa göre sınırı maksimum eden parametreler göstermektedir. DVM, lineer olan veri kümelerini Denklem 1’deki gibi bir sınıflandırıcı oluşturmayı amaçlar [44-47].

$$f(x) = \text{sgn} \left(\sum_{i=1}^N \alpha_i y_i (x_i \cdot x) + b \right) \quad (1)$$

Burada α maksimum s sınıflandırıcısını bulmak için kullanılan parametredir. Matematiksel bir işlev olan sgn fonksiyonu, sonuç değerinin pozitif, negatif veya sıfır olduğunu bulmak için kullanılmaktadır. α değeri genel olarak sıfırdır. Sıfır olmayan α değerleri güçlü destek vektörleri olarak tanımlanır ve sınıflandırmada karar fonksiyonuna önemli oranda katkı sağlar.

Doğrusal olmayan veri kümelerinde kullanılan karar fonksiyonu ise aşağıdaki gibi tanımlanmıştır:

$$f(x) = \text{sgn} \left(\sum_{i=1}^N \alpha_i y_i K(x_i \cdot x) + b \right) \quad (2)$$

Burada K , doğrusal olmayan verileri doğrusal bir uzayda tanımlamak için kullanılan çekirdek fonksiyondur. Çekirdek fonksiyonları olarak, doğrusal, polinom, radyal temel fonksiyon ve hiperbolik tanjant fonksiyonları kullanılır.

5. Performans Değerlendirme Metrikleri

Mimarilerin performansını değerlendirmek üzere doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), f1-Score, G-ortalama, özgüllük (specificity), AUC metrikleri ve karmaşıklık matrisi kullanılmıştır. Bu metrikler matematiksel olarak aşağıda verilmiştir:

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} * 100 \quad (3)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} * 100 \quad (4)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} * 100 \quad (5)$$

$$\text{F1 - Score} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} * 100 \quad (6)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} * 100 \quad (7)$$

$$\text{G - Ortalama} = \sqrt{\text{Duyarlılık} * \text{Özgüllük} * 100} * 100 \quad (8)$$

Burada, DP doğru pozitifleri, DN doğru negatifleri, YP yanlış pozitifleri, YN yanlış negatifleri ifade etmektedir. AUC ise bir olasılık eğrisi olan ROC' un altında kalan alandır. ROC eğrisinde Y ekseninde TPR (Gerçek Pozitif Oranı) ve X ekseninde FPR (Yanlış Pozitif Oran) bulunur. Eğrinin altındaki alan (AUC) artıkça (1'e yaklaştıkça) modelin performansının arttığını gösterir [3, 48-51].

$$\text{TPR} = \frac{DP}{DP+DN} \quad (9)$$

$$\text{FPR} = \frac{YP}{YP+YN} \quad (10)$$

Karmaşıklık matrisi, bir sınıflandırıcıda gerçek ve tahmin edilen sınıflar hakkında bilgi verir [52].

6. Deneysel Çalışmalar ve Sonuçları

Kolon kanseri tespiti için yapılan bu çalışmada EfficientNetB0 ve DVM tabanlı bir yöntem önerilmiştir. EfficientNetB0 mimarisi ile önemli öznelik haritaları çıkarıldıktan sonra elde edilen öznelikler DVM algoritması sınıflandırılması sağlanmıştır. Ayrıca önerilen modelin performansını değerlendirmek amacıyla EfficientNetB0, Xception, VGG19, InceptionV3, DenseNet121 ve ResNet101 gibi ESA mimarileri ile kıyaslanmıştır. Deneysel uygulamalarda veri kümesi olarak Kather-5k ve LC25000 veri kümeleri kullanılmıştır. Kolon kanseri tespiti için üç uygulama gerçekleştirilmiştir. İlk uygulamada Kather-5k, ikinci uygulamada LC25000 ve üçüncü uygulamada her iki veri kümesi birleştirilerek deneysel çalışmalar gerçekleştirilmiştir. Uygulamalar için veri kümelerin %80'i eğitim ve %20'si ise test için ayrılmıştır. Eğitim ve test veri kümelerinin sınıflara göre verilerin dağılımı detaylı olarak Tablo 2'de sunulmuştur. Tüm mimarilere aynı hiperparametreler verilerek eğitilmiştir. Eğitim için parça boyutu (batch size) 128 ve epok (epoch) değeri 50 olarak ayarlanmıştır. Optimizasyon algoritması için Adam ($lr = 0.001$) optimizasyon algoritması kullanılmıştır. Maliyet fonksiyonu olarak ikinci uygulama için Binary Crossentropy; birinci ve üçüncü uygulamalar için ise Categorical Crossentropy kullanılarak modellerin eğitimi gerçekleştirilmiştir.

Tablo 2. Deneysel çalışmalarda kullanılan veri kümelerinin eğitim ve test için görüntü sayılarının sınıflara göre dağılımı.

Uygulama	Veri Kümesi	Kanser Türü	Eğitim	Test	Toplam
1	Kather-5k	Tümör	511	114	625
		Stroma	525	100	625
		Kompleks	498	127	625
		Lympho	488	137	625
		Debris	500	125	625
		Mucosa	495	130	625
		Adipose	495	130	625
		Boş	491	134	625
2	LC25000	Kolon_aca	3990	1010	5000
		Kolon_n	4010	990	5000
3	Kather-5k+ LC25000	Tümör	501	124	625
		Stroma	511	114	625
		Kompleks	491	134	625
		Lympho	489	136	625
		Debris	502	123	625
		Mucosa	499	126	625
		Adipose	494	131	625
		Boş	497	128	625
		Kolon_aca	4013	987	5000
		Kolon_n	4014	986	5000

Kather-5k veri kümesi kullanılarak gerçekleştirilen ilk uygulamanın test sonuçları Tablo 3'te sunulmuştur. Aynı zamanda bu uygulama için önerilen modelin sınıflandırma başarısı gösteren karmaşıklık matris sonuçları Şekil 4 (a)'da verilmiştir.

Tablo 3. Kather-5k veri kümesi kullanılarak modellerin test sonuçları

Metot	Doğruluk	Kesinlik	Duyarlılık	F1-Score	G-ortalama	Özgüllük	AUC
EfficientNetB0	95.90	96.00	96.00	96.00	95.69	96.25	97.64
Xception	94.00	94.00	93.00	93.00	92.75	82.81	96.21
VGG19	79.10	80.00	79.00	79.00	77.87	71.66	87.84
InceptionV3	91.20	91.00	91.00	91.00	90.37	85.62	94.77
DenseNet121	94.00	95.00	94.00	94.00	93.52	88.37	96.42
ResNet101	92.80	93.00	93.00	92.00	92.29	91.31	95.77
Önerilen Model	99.70	100.00	100.00	100.00	99.71	100.00	99.83

Tablo 3'teki sonuçlar incelendiğinde önerilen model %99.70 doğruluk, %100 kesinlik, %100 duyarlılık, %100 F1-Score, %99.71 G-ortalama, %100 özgüllük ve %99.83 AUC ile en yüksek performansı gösterdiği görülmektedir. Aynı zamanda önerilen modelin EfficientNetB0 mimarisinin başarısında farklı metriklerde %2.12 ile %4.02 arasında bir artış sağladığını söyleyebiliriz. Şekil 4(a)'da ilk uygulama için önerilen modelin

karmaşıklık matris sonuçları incelendiğinde sadece iki Adipose sınıfına ait görüntünün yanlış tahmin ettiği, ancak diğer tüm sınıfları doğru tahmin ettiği görülmektedir.

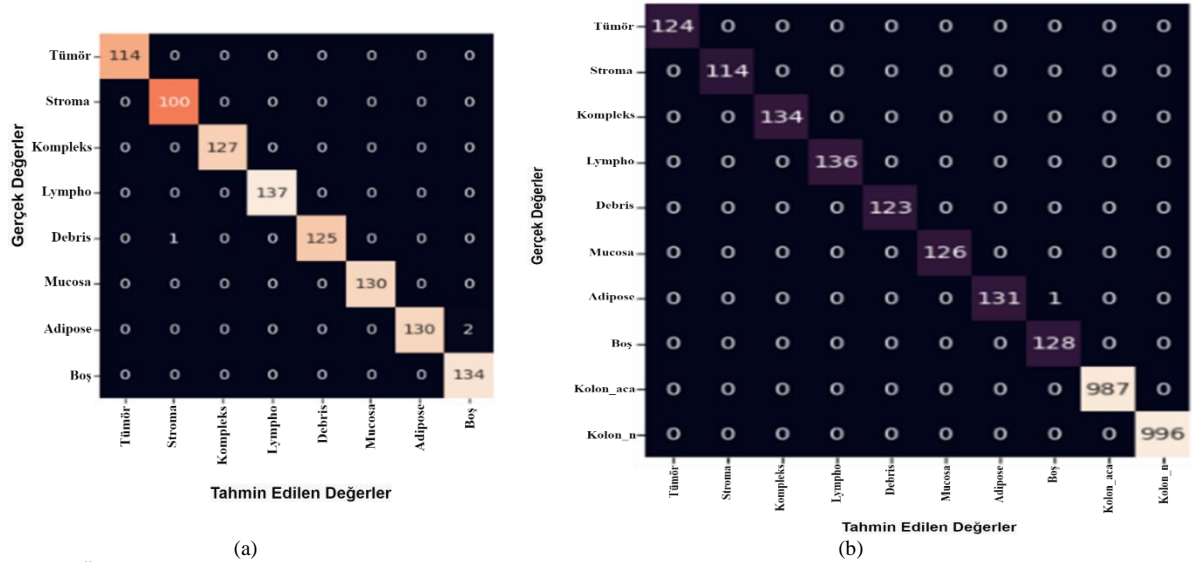
Tablo 4. LC25000 veri kümesindeki kolon görüntüleri kullanılarak modellerin test sonuçları

Metot	Doğruluk	Kesinlik	Duyarlılık	F1-Score	G-ortalama	Özgüllük	AUC
EfficientNetB0	100.00	100.00	100.00	100.00	100.00	100.00	100.00
Xception	100.00	100.00	100.00	100.00	100.00	100.00	100.00
VGG19	99.95	100.00	100.00	100.00	99.95	99.95	99.95
InceptionV3	100.00	100.00	100.00	100.00	100.00	100.00	100.00
DenseNet121	100.00	100.00	100.00	100.00	100.00	100.00	100.00
ResNet101	100.00	100.00	100.00	100.00	100.00	100.00	100.00
Önerilen Model	100.00	100.00	100.00	100.00	100.00	100.00	100.00

İkinci deneysel çalışmada LC25000 veri kümesindeki kolon kanseri görüntüleri kullanılarak kanser tespiti gerçekleştirilmiştir. Bu çalışma için modellerin test veri kümesine göre başarıları Tablo 4'te verilmiştir. Tablo 4'teki sonuçlar incelendiğinde VGG19 hariç diğer modellerin tüm metriklerde %100.00 başarı gösterdiği görülmektedir. Bütün modellerin yüksek performans göstermesi kullanılan veri kümesindeki görüntülerden kaynaklandığını söyleyebiliriz.

Tablo 5. Kather-5k ve LC25000 veri kümeleri kullanılarak modellerin test sonuçları

Metot	Doğruluk	Kesinlik	Duyarlılık	F1-Score	G-ortalama	Özgüllük	AUC
EfficientNetB0	97.87	95.00	95.00	95.00	94.87	94.48	97.40
Xception	97.70	95.00	95.00	95.00	94.69	91.37	97.28
VGG19	94.03	87.00	86.00	86.00	85.58	80.20	92.78
InceptionV3	96.30	92.00	91.00	91.00	90.67	81.59	95.40
DenseNet121	97.73	95.00	95.00	95.00	94.29	94.44	97.25
ResNet101	96.13	91.00	91.00	91.00	90.54	80.84	95.41
Önerilen Model	99.96	100.00	100.00	100.00	99.92	100.00	99.96



Şekil 4. Önerilen modelin test veri kümelerine göre karmaşıklık matris sonuçları: (a) Kather-5k veri kümesi için, (b) Kather-5k ve LC25000 veri kümeleri için.

Kolon kanseri tespiti için gerçekleştirilen üçüncü çalışmada Kather-5k ve LC25000 veri kümeleri birleştirilerek modellerin performansları değerlendirilmiştir. Elde edilen bulgular Tablo 5'te sunulmuştur. Bu uygulamada modellerin farklı görüntüler karşısındaki başarıları test edilmesi amaçlanmıştır. Tablo 5'teki sonuçlar incelendiğinde önerilen model doğruluk ve AUC metriklerine göre %99.96, kesinlik, duyarlılık, F1-Score ve

özgüllük metriklerine göre %100 ve G-ortalama metriğine göre %99.92 başarı ile en yüksek performansı sergilediği görülmektedir. Ayrıca önerilen modelin, EfficientNetB0 mimarisinin başarısında farklı metriklerle göre %2.09 ile %5.52 arasında bir iyileştirme yaptığını söyleyebiliriz.

Üçüncü çalışmada önerilen modelin Kather-5k ve LC25000 veri kümelerindeki görüntülerine göre karmaşıklık matris sonuçları Şekil 4 (b)'de sunulmuştur. Elde edilen bulgular incelendiğinde önerilen modelin sadece Adipose sınıfındaki görüntülerden bir adet görüntüyü yanlış tahmin ettiği, diğer dokuz sınıftaki görüntülerin ise hepsinin doğru tahmin ettiğini söyleyebiliriz. Üçüncü çalışmada elde edilen bulgular incelendiğinde önerilen model, birinci uygulamadaki (Tablo 3) sonuçlardan daha yüksek bir başarıyı sergilediği görülmektedir. Bununla birlikte artan veri sayısı ile önerilen modelin daha kararlı bir yapı gösterdiğini söyleyebiliriz.

Sonuçlar genel bir şekilde ele alındığında EfficientNetB0 mimarisinin diğer ESA mimarilerine göre daha yüksek bir performans sergilediği görülmektedir. EfficientNetB0 tabanlı önerilen modelin ise EfficientNetB0 mimarisinin başarısında %5.52'ye varan bir artış sağlayarak daha yüksek performans sergilemiştir. EfficientNetB0 ve DVM tabanlı önerilen modelin EfficientNetB0 modeline göre daha kompleks bir yapıya sahip olması hesaplama maliyetini artırmakta ve bu da önerilen model için bir dezavantaj olarak görülebilir. Ancak günümüz teknolojisi (GPU ekran kartları kullanılarak) ile böyle bir problemin üstesinden gelinebilmektedir.

7. Tartışma

Kolon kanseri, milyonlarca insanın ölümüne neden olduğu en ölümcül kanser türleri arasında görülmektedir. Bu hastalığın erken teşhisi hastaların hayatta kalma şansını artırmaktadır. Belirli yaş (18-65) gruplarında ilk evrede teşhis edildiğinde, hastanın hayatta kalma şansı %94'lerde iken son evrelerde bu oran %19'lara kadar düştüğü görülmüştür. Son dönemlerde DL alanında gelişen ilerlemeler sayesinde kanser teşhisinde hızlı ve doğru kararlar alınması mümkün hale gelmiştir.

Bu çalışmada kolon kanseri tespiti için farklı deneysel çalışmalar yapılmıştır. Yeni bir model önerilmiş ve mevcut ESA modelleri ile performans değerlendirilmesi gerçekleştirilmiştir. Yapılan deneysel çalışmalarda önerilen modelin mevcut ESA modellerine kıyasla üstünlüğü açıkça görülmüştür. Ayrıca Literatürde bizimle aynı Kather-5k veri kümesini kullanan bazı çalışmaların sonuçları Tablo 6'da verilmiştir. Çalışma [53]'de toplu derin sinir ağları (DNN) mimarisi kullanılarak %92.83, [54]'de yapay sinir ağları kullanılarak %95.30; [4, 55] ve [56]'de farklı ESA teknikleri kullanılarak sırasıyla %98.83, %94.86 ve %94.16 elde edilmiştir. Ancak önerilen model ile %99.70 doğruluk ile en yüksek başarıyı sağlandığı görülmektedir.

Tablo 6. Literatürde Kather-5k veri kümesini kullanan bazı çalışmaların sonuçları

Çalışma	Yıl	Yöntem	Doğruluk (%)
Ghosh vd. [53]	2021	DNN	92.83
Trivizakis vd. [54]	2021	YSA	95.30
Tsai vd. [55]	2021	ESA	94.86
Paladini vd. [56]	2021	Toplu ESA	94.16
Dabass vd. [4]	2022	ESA ve Dikkat modülü	98.83
Önerilen Model	2023	EfficientNetB0 ve DVM	99.70

8. Sonuç

Kolon kanseri tespiti için yapılan bu çalışmada EfficientNetB0 ve DVM tabanlı bir yöntem önerilmiştir. Önerilen modelin performansı, farklı ESA mimarileriyle karşılaştırılarak değerlendirilmiştir. İki farklı veri kümesi (Kather-5k ve LC25000) kullanılarak yapılan deneylerde, önerilen modelin diğer mimarilere kıyasla daha yüksek doğruluk, kesinlik, duyarlılık, F1-Score, G-ortalama, özgüllük ve AUC değerlerine sahip olduğu görülmüştür. Önerilen model Kather-5 veri kümesinde doğruluk, kesinlik, duyarlılık, F1-Score, G-ortalama, özgüllük ve AUC metriklerine göre sırasıyla %99.70, %100, %100, %100, %99.71, %100 ve %99.83 başarı elde etmiştir. LC25000 veri kümesiyle yapılan çalışmada ise önerilen model tüm metriklerde %100 başarı sağlamıştır. Her iki veri kümesini de içeren uygulamada, önerilen model %99.96 doğruluk, %100 kesinlik, %100 duyarlılık, %100 F1-Score, %99.92 G-ortalama, %100 özgüllük ve %99.96 AUC oranı ile diğer mimarilere kıyasla daha yüksek performans sergilemiştir. Aynı zamanda önerilen model EfficientNetB0 mimarisinin başarısında %5.52'ye varan performans artışı sağlamıştır.

Gelecek çalışmalarda kolon kanserinin erken teşhisi için evrelere göre sınıflandırılmış veri kümeleri ile çalışılması amaçlanmaktadır. Ayrıca yüksek performans sergileyen, güvenilir ve uygulanabilir yeni ESA tabanlı modellerin geliştirilmesi hedeflenmektedir.

Kaynaklar

- [1] Sung H, Ferlay J, Siegel RL, Laversanne M, Soerjomataram I, Jemal A, Bray F. Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA. Cancer J. Clin* 2021; 71(3): 209–249.
- [2] Pacal I, Karaboga D, Basturk A, Akay B, Nalbantoglu U. A comprehensive review of deep learning in colon cancer. *Comput. Biol. Med.* 2020; 126(April): 104003.
- [3] Xi Y, Xu P. Global colorectal cancer burden in 2020 and projections to 2040. *Transl. Oncol.* 2021; 14(10): 101174.
- [4] Dabass M, Vashisth S, Vig R. A convolution neural network with multi-level convolutional and attention learning for classification of cancer grades and tissue structures in colon histopathological images. *Comput. Biol. Med.* 2002; 147: 105680.
- [5] Liang M, Ren Z, Yang J, Feng W, Li B. Identification of Colon Cancer Using Multi-Scale Feature Fusion Convolutional Neural Network Based on Shearlet Transform. *IEEE Access.* 2020; 8: 08969–208977.
- [6] Sarwinda D, Paradisa RH, Bustamam A, Anggia P. Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer. *Procedia Comput. Sci.* 2021; 179: 423–431.
- [7] Catal H, Veysel R. Transfer Learning Approach and Nucleus Segmentation with MedCLNet Colon Cancer Database. *J. Digit. Imaging.* 2023; 36 (1): 306–325.
- [8] Mehedi FMJ, Newaz A, Alam H, Binte S. Deep Learning Predictive Model for Colon Cancer Patient using CNN-based Classification. 2021.
- [9] Cancer Survival Rates. (Erişim Tarihi 18 Nisan 2023). <https://cancersurvivalrates.com/?type=colon&role=patient>.
- [10] Sánchez-peralta LF, Bote-curriel L, Picón A, Sánchez-margallo FM, Pagador JB. Deep learning to find colorectal polyps in colonoscopy : A systematic literature review. *Artif. Intell. Med.* 2020; 108(August): 101923.
- [11] Rathore S, Hussain M, Khan A. Automated colon cancer detection using hybrid of novel geometric features and some traditional features. *Comput. Biol. Med.* 2015; 65: 279–296.
- [12] Toraman S, Girgin M, Üstündağ B, Türkoğlu İ. Classification of the likelihood of colon cancer with machine learning techniques using FTIR signals obtained from plasma. *TURKISH J. Electr. Eng. Comput. Sci.* 2019; 27(3): 1765–1779.
- [13] Toğaçar M. Disease type detection in lung and colon cancer images using the complement approach of inefficient sets. *Comput. Biol. Med.* 2021; 137: 104827.
- [14] Garg S, Garg S. Prediction of lung and colon cancer through analysis of histopathological images by utilizing Pre-trained CNN models with visualization of class activation and saliency maps. in 2020 3rd Artificial Intelligence and Cloud Computing Conference. Dec. 2020; 38–45.
- [15] Urban G, Tripathi P, Alkayali T, Mittal M, Jalali F, Karnes W, Baldi P. Deep Learning Localizes and Identifies Polyps in Real Time With 96% Accuracy in Screening Colonoscopy. *Gastroenterology.* 2018; 155(4): 1069-1078.
- [16] Babu T, Gupta D, Singh T, Hameed S. Colon Cancer Prediction On Different Magnified Colon Biopsy Images. in 2018 Tenth International Conference on Advanced Computing (ICoAC); 13-15 December 2018; Chennai, Indiap. 277–280.
- [17] Masud M, Sikder N, Nahid AA, Bairagi AK, AlZain MA. A Machine Learning Approach to Diagnosing Lung and Colon Cancer Using a Deep Learning-Based Classification Framework. *Sensors;* 21(3): 748.
- [18] Jiao L, Chen Q, Li S, Xu Y. Colon Cancer Detection Using Whole Slide Histopathological Images. 2013; 1283–1286.
- [19] Tasnim Z, Chakraborty S, Shamrat, Mehedi FMJ, Chowdhury AN, Nuha HA, Karim A, Zahir SB, Billah MdM. Deep Learning Predictive Model for Colon Cancer Patient using CNN-based Classification. *Int. J. Adv. Comput. Sci. Appl.* 2021; 12(8).
- [20] Qasim Y, Al-Sameai H, Ali O, Hassan A. Convolutional Neural Networks for Automatic Detection of Colon Adenocarcinoma Based on Histopathological Images. 2021; 19–28.
- [21] Doğan G, Ergen B. A new approach based on convolutional neural network and feature selection for recognizing vehicle types. *Iran J. Comput. Sci.* 2023; 6(2): 95–105.
- [22] İmak A, Doğan G, Şengür A, Ergen B. Asma Yaprağı Türünün Sınıflandırılması için Doğal ve Sentetik Verilerden Derin Öznitelikler Çıkarma, Birleştirme ve Seçmeye Dayalı Yeni Bir Yöntem. *Int. J. Pure Appl. Sci.* 2023; 9(1): 46–55.
- [23] Kather JN, Weis C, Bianconi F, Melchers SM, Schad LR, Gaiser T, Marx A, Zöllner FG. Multi-class texture analysis in colorectal cancer histology. *Sci. Rep.* 2016; 6(1): 27988.
- [24] Kather JN, Zöllner FG, Bianconi F, Melchers SM, Schad LR, Gaiser T, Marx A, Weis CA. Collection of textures in colorectal cancer histology. *Zenodo.* 2016.
- [25] Borkowski AA, Bui MM, Thomas LB, Wilson CP, DeLand LA, Mastorides SM. Lung and Colon Cancer Histopathological Image Dataset (LC25000). *arXiv.* 2019.
- [26] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature.* 2015; 521(7553); 436–444.
- [27] Behrad F, Saniee Abadeh M. An overview of deep learning methods for multimodal medical data mining. *Expert Syst. Appl.* 2022; 200(Aug.): 117006.
- [28] Sharma A, Lysenko A, Boroevich KA, Vans E, Tsunoda T. DeepFeature: feature selection in nonimage data using convolutional neural network. *Brief. Bioinform.* 2021; 22(6).
- [29] Li Z, Liu F, Yang W, Peng S, Zhou J. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Trans. Neural Networks Learn. Syst.* 2022; 33(12): 6999–7019.
- [30] Subramanian N, Elharrouss O, Al-Maadeed S, Chowdhury M. A review of deep learning-based detection methods for

- COVID-19. *Comput. Biol. Med.* 2022; 143: 105233.
- [31] Sarıgül M, Ozyildirim BM, Avcı M. Differential convolutional neural network. *Neural Networks.* 2019; 116: 279–287.
- [32] Doğan G, Ergen B. Karayollarındaki Asfalt Çatlaklarının Tespiti İçin Yeni Bir Konvolüsyonel Sinir Ağı Tabanlı Yöntem. *Fırat Üniversitesi Mühendislik Bilim. Derg.* 2022; 34(2): 485–494.
- [33] Çalışan M, Talu MF. Comparison of Methods for Determining Activity from Physical Movements. *Politek. Derg.* 2021; 24(1): 17–23.
- [34] Özdemir E, Türkoğlu İ. Yazılım Güvenlik Açıklarının Evrimsel Sinir Ağları (CNN) ile Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilim. Derg.* 2022; 34(2): 517–529.
- [35] Celik G. CovidCoughNet: A new method based on convolutional neural networks and deep feature extraction using pitch-shifting data augmentation for covid-19 detection from cough, breath, and voice signals. *Comput. Biol. Med.* 2023; 163: 107153.
- [36] Toğaçar, M., Cömert, Z. & Ergen, B. Enhancing of dataset using DeepDream, fuzzy color image enhancement and hypercolumn techniques to detection of the Alzheimer's disease stages by deep learning model. *Neural Comput & Applic.* 2021; 33, 9877–9889.
- [37] Başaran E. A new brain tumor diagnostic model: Selection of textural feature extraction algorithms and convolution neural network features with optimization algorithms. *Comput. Biol. Med.* 2022; 148: 105857.
- [38] Çalışkan, A. Detecting human activity types from 3D posture data using deep learning models. *Biomed. Signal Process. Control.* 2023; 81:104479.
- [39] Çalışkan A. Classification of Tympanic Membrane Images based on VGG16 Model. *Kocaeli J. Sci. Eng.* 2022; 5(1): 105–111.
- [40] Toğaçar, Z. Cömert, B. Ergen and Ü. Budak, "Brain Hemorrhage Detection based on Heat Maps, Autoencoder and CNN Architecture," 2019 1st International Informatics and Software Engineering Conference (UBMYK), Ankara, Turkey. 2019; 1-5.
- [41] Tan M, Le QV. EfficientNet : Rethinking Model Scaling for Convolutional Neural Networks. in *Proceedings of the 36th International Conference on Machine Learning, PMLR 97.* 9-15 June 2019; Long Beach, California: 6105–6114.
- [42] Alhichri H, Alswayed AS, Bazi Y, Ammour N, Alajlan NA. Classification of Remote Sensing Images Using EfficientNet-B3 CNN Model With Attention. *IEEE Access.* 2021; 9: 14078–14094.
- [43] Gang S, Fabrice N, Chung D, Lee J. Character Recognition of Components Mounted on Printed Circuit Board Using Deep Learning. *Sensors.* 2021; 21(9): 2921.
- [44] Shahbakhhi M, Far DT, Tahami E. Speech Analysis for Diagnosis of Parkinson's Disease Using Genetic Algorithm and Support Vector Machine. *J. Biomed. Sci. Eng.* 2014; 07(04): 147–156.
- [45] Gunduz H. Deep Learning-Based Parkinson's Disease Classification Using Vocal Feature Sets. *IEEE Access.* 2019; 7: 115540–115551.
- [46] Thangavel KD, Seerengasamy U, Palaniappan S, Sekar R. Prediction of factors for Controlling of Green House Farming with Fuzzy based multiclass Support Vector Machine. *Alexandria Eng. J.* 2023; 62: 279–289.
- [47] Başaran E. Classification of white blood cells with SVM by selecting SqueezeNet and LIME properties by mRMR method. *Signal, Image Video Process.* 2022; 16(7): 1821–1829.
- [48] Kaya Y, Uyar M. A hybrid decision support system based on rough set and extreme learning machine for diagnosis of hepatitis disease. *Appl. Soft Comput. J.* 2013; 13(8): 3429–3438.
- [49] Liu T, Fan W, Wu C. A hybrid machine learning approach to cerebral stroke prediction based on imbalanced medical dataset. *Artif. Intell. Med.* 2019; 101(September): 101723.
- [50] Caprolu M, Raponi S, Oligeri G, Di Pietro R. Cryptomining makes noise : Detecting cryptojacking via Machine Learning. *Comput. Commun.* 2020; 171(November): 126–139.
- [51] Subramanian N, Elharrouss O, Al-maadeed S, Chowdhury M. A review of deep learning-based detection methods for COVID-19. *Comput. Biol. Med.* 2022; 143: 105233.
- [52] Ibrahim AA, Ridwan RL, Muhammed MM, Abdulaziz RO, Saheed GA. Comparison of the CatBoost Classifier with other Machine Learning Methods. *Int. J. Adv. Comput. Sci. Appl.* 2020; 11(11): 738–748.
- [53] Ghosh S, Bandyopadhyay A, Sahay S, Ghosh R, Kundu I, Santosh KC. Colorectal Histology Tumor Detection Using Ensemble Deep Neural Network. *Eng. Appl. Artif. Intell.* 2021; 100: 104202.
- [54] Trivizakis E, Ioannidis GS, Souglakos I, Karantanas AH, Tzardi M, Marias K. A neural pathomics framework for classifying colorectal cancer histopathology images based on wavelet multi-scale texture analysis. *Sci. Rep.* 2021; 11(1): 15546.
- [55] Tsai MJ, Tao YH. Deep Learning Techniques for the Classification of Colorectal Cancer Tissue. *Electronics.* 2021; 10(14): 1662.
- [56] Paladini E, Vantaggiato E, Bougourzi F, Distanto C, Hadid A, Taleb-Ahmed A. Two Ensemble-CNN Approaches for Colorectal Cancer Tissue Type Classification. *J. Imaging.* 2021; 7(3): 51.