



# Histopatolojik Görüntülerde Farklı Doku Tiplerinin Geleneksel ve Derin Öğrenme Yöntemleri ile Sınıflandırılması

## Classification of Different Tissue Types in Histopathological Images with Conventional and Deep Learning Methods

Nergis Arafal, Oyku Zeynep Bayramoğlu, Gokhan Bilgin  
Bilgisayar Mühendisliği Bölümü  
Yıldız Teknik Üniversitesi  
34220 İstanbul, Türkiye

nergisarafal08@gmail.com, oykuzeynepbayramoglu@gmail.com, gbilgin@yildiz.edu.tr

**Özetçe** —Son yıllarda bilgisayar desteğinin de artması ile birlikte bu yüksek çözünürlüklü histopatolojik görüntüler üzerinde görüntü işleme ve makine öğrenmesi yöntemleri verimli bir şekilde uygulanabilir hale gelmiştir. Bu çalışmada, uzmanların iş yükünü azaltarak teşhislerinde yardımcı olabilmek için histopatolojik görüntülerin yüksek başarımla sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda, İki farklı veri kümesi kullanılarak birindeki görüntüler geleneksel öznelik çıkarma yöntemleri ile, diğerindeki görüntüler derin öğrenme ile sınıflandırılmıştır. Öznelik çıkarma adımında, Haralick doku tanımlayıcı ile elde edilen özelliklere piksel yoğunlukları ve görüntü histogramı da eklendiğinde en yüksek sınıflandırma başarısı, rastgele orman (random forest) sınıflandırıcısı ile %87.3 olarak elde edilmiştir. Özneliklere dayalı yaklaşımların birçok zorluğunun üstesinden gelmek için, derin öğrenme yöntemleri önemli alternatifler haline gelmektedir. PyTorch tarafından sağlanan ImageNet veri kümesi ile eğitilmiş modellerin BACH ICIAR veri kümesi ile tekrar eğitilmesi ve görsellerin %20'si ile test edilmesiyle DenseNet121, DenseNet169 ve SqueezeNet 1.0 modellerinden sırasıyla %88.75, %92.5 ve %88.75 doğruluk elde edilmiştir. Modellerin verdiği tahmin sonuçlarından çoğunluk olan sınıf, sonuç tahmin olarak sayılarak model topluluğu oluşturulmuş ve %97.5 başarı alınmıştır.

**Anahtar Kelimeler**—Histopatolojik görüntüler, öğrenme ak-tarımı, derin öğrenme, dokusal öznelikler, bilgisayar destekli teşhis sistemleri.

**Abstract**—In recent years, with the increase in computer support, image processing and machine learning methods have become effective on these high resolution histopathological images. The aim of this study is to classify histopathological images with high accuracy to help diagnosis process by reducing the workload of specialists. By using two different data sets in the experimental studies, the images in one of them were classified by conventional feature extractions based method and the images in the other by deep learning methods. In the feature extraction based approach, when pixel densities and image histograms were added to the features obtained with Haralick textural descriptor, the highest classification accuracy was obtained with

random forest classifier as 87.3%. In order to overcome the many challenges of feature extraction -based approaches, deep learning methods become as important alternatives. DenseNet121, DenseNet169 and SqueezeNet 1.0 models obtained 88.75%, 92.5% and 88.75% accuracies respectively, by retraining the models trained with the ImageNet dataset provided by PyTorch with the BACH ICIAR dataset and testing them with 20% of the images. With forming an ensemble model, the class which is the majority of the estimation results of the models is counted as the final prediction and 97.5% accuracy is obtained.

**Keywords**—Histopathological images, transfer learning, deep learning, textural features, computer-aided diagnosis systems.

### I. GİRİŞ

Son yıllarda dünyada ve ülkemizde kanser vakalarında ciddi artış gözlemlenmektedir. Gittikçe yaygınlaşan kanser hastalıklarının tespitinde doku ve organlardaki değişimi incelemek için yapılan işlemler histopatoloji başlığı altında toplanmaktadır [1]. İnsan dokusundan alınan kesitlerin laboratuvar ortamında çeşitli işlemlerden geçirilerek hastalığa sebep olan olgunun dokuda yaptığı morfolojik değişikliklerin tespit edilmesini sağlamak histopatolojinin uğraş alanıdır. Histopatolojik doku örneklerinin bilgisayarlarla analizi özellikle kanser hastalığının erken tedavisi açısından oldukça önemli bir yöntemdir [2], [3]. Gelişen teknoloji ile birlikte, patoloğların mikroskoplarda değerlendirdiği doku örneklerine ait görüntülerin sayısal ortama yüksek kalite ve çözünürlükte aktarılması hem kolaylaşmış hem de daha ekonomik hale gelmiştir. Sayısallaştırılmış biyomedikal görüntü verilerindeki gelişmeler, vaka çalışmaları hakkında daha kesin ve daha güvenilir sonuçlar vermektedir. Bununla birlikte, dokunun bütün bölümünün analizi, istatistiksel yöntemleri değerlendirmek için uzun bir işlem süresi gerektirir [4]. Görüntüleme cihazlarının yüksek kalitede görüntü alma özelliği ve görüntü işleme tekniklerinin de gelişmesiyle beraber yüksek

çözünürlüklü histopatolojik görüntüleri kullanarak bilgisayar yardımıyla teşhis (computer-aided diagnosis; CAD) sistemleri patolojlara yardımcı bir sistem olarak geliştirilmektedir. Bilgisayar desteğinin artması da bu yüksek çözünürlüklü veriler üzerinde görüntü işleme ve makine öğrenmesi yöntemlerini uygulanabilir hale getirmiştir. Geliştirilen bu tıbbi sistemler vasıtasıyla kanser teşhis, sınıflandırma ve derecelendirilmesinde gerekli niceliksel analiz ve özellik çıkarma işlemleri daha kolay hale gelmektedir [5], [6].

Histoloji görüntüleri üzerinde yapılan çalışmalar son yıllarda literatürde ivme kazanmıştır. Histopatolojik görüntülerde, görüntünün sınıflandırmasında, görüntünün bölütlenmesi ve öznetelik çıkarımında yaygın olarak kullanılan birçok çalışma vardır [7], [8]. Örneğin yapılan bir çalışmada histopatolojik görüntülerde farklı doku tiplerinin sınıflandırılması işleminde özellik çıkarımında, bağ of features (BOFs) yönteminin kullanımı anlatılmıştır [9], [10]. Yapılan çalışma sonucunda epitel, kas ve sinir doku tiplerinin, bağ doku tipine göre nispeten daha başarılı bir şekilde sınıflandırıldığı belirlenmiştir. Diğer bir çalışmada meme kanseri görüntülerinden doku analizi yapmak için Gabor ve gray level co-Occurrence matrix (GLCM) öznetelik çıkarımı yöntemleri uygulanmıştır [11]. Daha sonra, elde edilen öznetelik matrislerine çeşitli sınıflandırıcılar uygulanarak performansları karşılaştırılmıştır. En yüksek sınıflandırma başarısı, Gabor ve GLCM yöntemlerinin öznetelikleri birleştirilerek, rastgele orman (random forest) sınıflandırıcısı ile %82.06 olarak elde edilmiştir. Histopatoloji alanında hücresel doku ve uzamsal özneteliklerin çıkarılmasına ait çalışmalarda kullanılan öznetelik çıkarma işlemlerine özet literatür taramaları da bulunmaktadır [12], [13]. Meme kanseri histopatolojik görüntülerinde çoklu örneklilik öğrenme [14], süperpiksel tabanlı bölütleme [15] ve öznetelik torbaları [16] yöntemleri ile iyi huylu ve kötü huylu hücreler olarak sınıflandırmakta aynı zamanda kötü hücreleri de kendi içerisinde derecelendirilmektedir. Özellik çıkarma yöntemlerinin yanısıra farklı histopatolojik görüntülerin sınıflandırılmasında derin öğrenme yöntemi de kullanılmaktadır [17], [18]. Derin öğrenmede dokusal özelliklerin herhangi bir öznetelik çıkarımı olmaksızın ağın içinde aşamalı olarak çıkarılır [20].

## II. VERİ KÜMELERİ

Bu çalışmada, HistologyDS [10] histopatoloji görüntü kümesinde bulunan farklı doku tiplerini çeşitli öznetelik çıkarım yöntemleri ve sınıflandırıcılar kullanarak; BACH İCIAR [19] görüntü kümesindeki baskın kanser tipleri ise transfer öğrenmesi kullanılarak sınıflandırılmıştır.


### A. HistologyDS

Histoloji görüntü veri kümesi (histologyDS) olarak adlandırılan doku veri kümesi MindLab Research Group, Kolombiya Ulusal Üniversitesi tarafından sağlanmaktadır [10] ve veri kümesindeki görüntüler bir uzman tarafından manuel olarak işaretlenmiştir. Veri kümesi toplam 2828 görüntü içermektedir ve veri kümesindeki doku görüntülerinin dağılımı Tablo I'de göstermektedir.

Histoloji veri kümesi, birbirinden farklı yapıya sahip dört temel doku içerir. Bunlar bağ, epitel, kas ve sinir dokularıdır. Bu dokuların örnekleri Şekil 1'de verilmiştir.

Tablo I: Veri kümesindeki doku türlerinin dağılımı


Doku Tipi	Örnek Sayısı
Bağ Doku	484
Epitel Doku	804
Kas Doku	514
Sinir Doku	1026



Şekil 1: HistologyDS veri kümesine ait farklı doku tiplerine örnekler

### B. BACH İCIAR 2018 Challenge Veri Kümesi

BACH veri kümesi, hematoxilen ve eozin (H&E) ile boyanmış meme histolojisi mikroskopisi ve tam resim (whole-slide) görüntülerinden oluşur [19]. Mikroskop görüntüleri, her görüntüdeki baskın kanser tipine göre normal, iyi huylu, yerinde karsinom veya invaziv karsinom (normal, benign, in-situ carcinoma or invasive carcinoma) olarak etiketlenmiştir. Bu dokuların örnekleri Şekil 2'de verilmiştir. Açıklama iki tıp uzmanı tarafından gerçekleştirilmiş ve anlaşmazlık bulunan görüntüler veri kümesine alınmamıştır.



Şekil 2: Veri kümesindeki mikroskopik görüntülere örnekler

Veri kümesi, 2048 × 1536 boyutlarında 400 adet mikroskopik görüntü içerir. Tablo II veri kümesindeki doku görüntülerinin dağılımını göstermektedir.

Tablo II: Veri kümesinde baskın kanser tiplerinin dağılımı

Baskın Kanser Tipi	Örnek Sayısı
Normal	100
İyi huylu	100
Yerinde karsinom	100
İnvaziv karsinom	100

Tam slayt görüntüleri, tüm örnekleme dokuyu içeren yüksek çözünürlüklü görüntülerdir. Mikroskopik görüntüler tam slayt görüntülerinin ayrıntılarıdır. Bundan dolayı, tam resim görüntüsünün her biri normal, iyi huylu, yerinde karsinom ve invaziv karsinom bölgelerine sahip olabilir. Her görüntü için iyi huylu, yerinde karsinom ve invaziv karsinom bölgelerini içeren etiketli koordinatların bir listesi vardır. Veri kümesindeki tam slayt görüntüleri 42113 × 62625 boyutlarındaki '.svs' uzantısı biçiminde verilmiştir.

### III. ÖZNETELİK ÇIKARIMI

Bu çalışmada HistologyDS veri kümesi üzerinde özellik çıkarımı için üç farklı yöntem kullanılmıştır. Görüntülerden uzamsal bilgiden faydalanarak öznetelik çıkarımı yapabilmek için gri seviye eş-oluşum matrisi (GLCM)'nden faydalanılmıştır. Haralick tarafından önerilen GLCM yöntemi, görüntüdeki belirli mesafe ve yönde komşu pikseller arasındaki ilişkiyi tanımlamakta ve parlaklık değerlerinin tekrarlama sıklığını göstermektedir. Piksellerden birinin referans bir diğerinin komşu piksel olduğu kabul edilerek iki piksel arasındaki geçişlerin hesaplanmasıyla elde edilir. Böylece bütün piksellerin birbirine komşulukları bulunarak görüntüdeki farklı bölgeler arasındaki benzerlikler çıkarılmaktadır. Oluşum matrisleri çıkarılırken pikseller arasındaki her bir  $d$  mesafesi ve yönelim açıları ayrı öznetelik çıkarılması bakımından önemlidir. GLCM algoritması kullanılarak görüntü ile ilgili açısız ikinci moment (enerji), kontrast, korelasyon, varyans, ters fark momenti, toplam ortalama, toplam varyans, toplam entropi, entropi, fark varyansı, fark entropisi, ilinti ölçütleri bilgileri (2 adet) ve maksimum korelasyon katsayısı olmak üzere, toplam 14 adet öznetelik çıkarılmaktadır. Sınıflandırma için bu özelliklerden kontrast, enerji ve homojenlik değerleri kullanılmıştır. Haralick doku tanımlayıcısı ile çıkarılan dokusal özneteliklere, görüntülerin piksel yoğunlukları ve görüntü histogramı eklenmiştir. Sonuç olarak her bir görüntüden bu özneteliklerin çıkarılması ile 532 uzunluğunda özellik vektörleri elde edilmiştir ve sadece Haralick doku tanımlayıcı ile çıkarılan özneteliklerin sınıflandırılma sonuçları Tablo III'te verilmiştir. Özellik çıkarma aşamasından önce görüntü boyutları  $128 \times 128$  olarak yeniden boyutlandırılmıştır. Daha sonra görüntüler, dokusal öznetelikleri ve piksel yoğunlukları çıkarılmadan önce 256 gri seviyesine ölçeklenmiştir. Görüntü histogramı çıkarılmadan önce ise RGB değerleri HSV değerlerine dönüştürülmüştür.

Tablo III: GLCM öznetelikleri ile farklı sayılardaki test görüntülerinin % sınıflandırılma başarı oranları

	0.1 Test	0.2 Test	0.3 Test
Lojistik Regresyon	%45.2	%46.8	%44.6
Doğrusal Ayrımçılık Analizi	%51.2	%51.1	%50.4
k-En Yakın Komşu	%61.8	%61.8	%60.0
Karar Ağaçları	%59.4	%56.5	%56.5
Rastgele Orman	<b>%66.4</b>	<b>%69.3</b>	<b>%64.1</b>
Naive Bayes	%43.1	%43.3	%43.2
Destek Vektör Makineleri	%51.9	%51.1	%48.2

Haralick doku tanımlayıcısı ile elde edilen özelliklere piksel yoğunlukları ve görüntü histogramı da eklendiğinde Tablo IV'te verilen sonuçlar elde edilmiştir. Benzer şekilde özellikler birleştirildikten sonra 10-katlamalı çapraz doğrulama yöntemi kullanıldığında Tablo V'te verilen sonuçlar elde edilmiştir. En başarılı sonuç piksel yoğunlukları, görüntü histogramı ve GLCM özellikleri birleştirilerek rastgele orman sınıflandırıcısı ile elde edilmiştir.

Tablo VI'da ise birleştirilen özellikleri en başarılı sınıflandıran Rastgele Orman sınıflandırıcısının farklı performans sonuçları verilmiştir.

### IV. TRANSFER ÖĞRENMESİ İLE SINIFLANDIRMA

AlexNet, DenseNet (DenseNet121, DenseNet161, DenseNet169, DenseNet201), ResNet (ResNet18, ResNet34,

Tablo IV: Piksel yoğunlukları, görüntü histogramı ve GLCM özneteliklerinin birleştirilmesi ile farklı sayılardaki test görüntülerinin % sınıflandırılma başarı oranları

	0.1 Test	0.2 Test	0.3 Test
Lojistik Regresyon	%69.3	%64.7	%65.0
Doğrusal Ayrımçılık Analizi	%72.4	%67.8	%67.1
k-En Yakın Komşu	%77.7	%78.1	%77.0
Karar Ağaçları	%70.0	%69.8	%68.7
Rastgele Orman	<b>%87.3</b>	<b>%83.9</b>	<b>%82.7</b>
Naive Bayes	%37.1	%39.8	%39.3
Destek Vektör Makineleri	%79.9	%80.6	%78.9

Tablo V: Piksel yoğunlukları, görüntü histogramı ve GLCM öznetelikleri birleştirilmesi ile k-katlamalı çapraz doğrulama % sınıflandırılma başarı oranları

	10-katlamalı çapraz doğrulama
Lojistik Regresyon	%65.1
Doğrusal Ayrımçılık Analizi	%68.3
k-En Yakın Komşu	%79.1
Karar Ağaçları	%70.8
Rastgele Orman	<b>%84.1</b>
Naive Bayes	%37.5
Destek Vektör Makineleri	%79.7

Tablo VI: Tüm özelliklerin birleştirilmesi ile farklı sayılardaki test görüntülerinin RF sınıflandırıcısı ile farklı performans değerlendirme ölçütü sonuçları.

	Kesinlik	Duyarlılık	F1-Skoru	Doğruluk
0.1 Test	%87.0	%85.9	%86.3	%87.3
0.2 Test	%83.3	%81.9	%82.4	%83.9
0.3 Test	%81.8	%80.7	%81.2	%82.7

ResNet50, ResNet101, ResNet152), SqueezeNet (SqueezeNet 1.0 ve SqueezeNet 1.1) modelleri BACH ICIAR 2018 Challenge veri kümesi ile 80 tur eğitimden sonra model, test verisi ile en yüksek doğruluk oranına sahip olduğu turda kaydedilmiştir. Modeller eğitilmemiş modellerle baştan eğitim ve transfer öğrenmesi olmak üzere iki şekilde eğitilmiştir. Transfer öğrenmesi için PyTorch'un sağladığı modeller ve ImageNet ile eğitilmiş olan ağırlıkları kullanılmıştır. İlk olarak BACH ICIAR veri kümesi ile modellerin sınıflandırma katmanları eğitilerek test edilmiş, ikinci olarak ImageNet ile eğitilmiş modellerden yalnızca öznetelik çıkarımı ile sınıflandırılarak elde edilen sonuçlarla karşılaştırılmıştır. ImageNet ile eğitilmiş modeller, aynı şekilde normalize edilmiş giriş görüntüleri beklediğinden, transfer öğrenmesi ve öznetelik çıkarımı sırasında ortalama = [0.485, 0.456, 0.406] ve standart sapma = [0.229, 0.224, 0.225] ile normalize edilmiş ve tüm görüntüler  $224 \times 224$  boyutlarında yeniden boyutlandırılmıştır.

Veri artırımı için 0.08 ile 1.0 aralığında rastgele oranlarla kırılan görüntüler ağa verilmiştir. Ek olarak rastgele yatay çevirmeler uygulanmıştır. Deneylerde oluşturulan 14 modelin hepsinde en yüksek doğruluk sonucunu verdiği modeller topluluğu (ensemble) için transfer öğrenmesi ile eğitilen modellerin kullanılmasına karar verilmiştir. Her üç yaklaşımın da AlexNet modeliyle karşılaştırılması Tablo VII'de görülebilir.

Toplam 14 modelin tüm alt kümelerinden topluluk oluşturularak iki farklı yaklaşımla sınıflandırma yapılmıştır. İlk olarak test görüntüleri ile test edildikten sonra tam bağlı katmanlardan (FCN) her sınıf için tahmin edilen olasılıklar



Tablo VII: Eğitim yaklaşımının karşılaştırılması

Model	Baştan Eğitime	Transfer Öğrenmesi	Öznitelik Çıkarımı
AlexNet-	%56.25	<b>%86.25</b>	%82.5
ResNet-18	%68.75	<b>%88.75</b>	%78.75
VGG-11 (BN)	%70	<b>%85</b>	%81.25
SqueezeNet 1.0	%61.25	<b>%88.75</b>	%78.75

almıştır. Ardından, her görüntü için toplulukta bulunan modellerin verdiği olasılıklar toplanarak en yüksek olasılıklı olan sınıf tahmin edilen sınıf etiketi olarak seçilmiştir. Başka bir yaklaşım olarak, modeller arasında en çok tahmin edilmiş olan sınıf o görüntünün sınıf etiketi olarak tahmini gerçekleştirilmiştir. Kullanılan 14 modelin tüm alt gruplarından oluşan her topluluk için aynı test verisi ile başarı ölçülmüştür. Ulaşılan en yüksek başarı oranı, çoğunluk oyu ile %97,5 iken, olasılıkların toplanması ile birlikte %96,25 olarak bulunmuştur. En iyi kombinasyonların doğruluk sonuçları, kombinasyonu oluşturan modellerin doğruluğu ve toplam olasılık ve çoğunluk oyuyla oluşturulan topluluğun doğruluk sonuçları Tablo VIII'da verilmiştir.

Tablo VIII: Model ölçümlerinin karşılaştırılması

Model	Kesinlik	Duyarlılık	F1-Skoru	Doğruluk
DenseNet-121	%89.16	%88.75	%88.37	%88.75
DenseNet-169	%93.75	%92.5	%92.4	%92.5
SqueezeNet 1.0	%89.92	%88.75	%88.19	%88.75
Topluluk	<b>%97.61</b>	<b>%97.5</b>	<b>%97.46</b>	<b>%97.5</b>

## V. TARTIŞMA VE SONUÇ

Bu çalışmada, HistologyDS görüntü kümesindeki dört farklı doku tipi çeşitli öznitelik çıkarım yöntemleri ve sınıflandırıcılar kullanılarak; BACH ICIAR görüntü kümesindeki dört farklı baskın kanser tipleri ise transfer öğrenmesi kullanılarak sınıflandırılmıştır. Öznitelik çıkarım aşamasında, GLCM ile çıkarılan özelliklerin sınıflandırmada tek başına yeterli olmadığı görülmüştür. GLCM ile çıkarılan özelliklere piksel yoğunlukları ve görüntü histogramı eklenerek farklı sınıflandırıcılar ile performansları değerlendirildiğinde bu özelliklerin birleşmesinin daha başarılı sonuçlar verdiği görülmüştür. Bu nedenle piksel yoğunlukları, görüntü histogramı ve GLCM öznitelikleri birleştirilerek (532 öznitelik), 0.9 eğitim 0.1 test görüntüsü olarak ayrıldığında, HistologyDS veri kümesinde rastgele orman sınıflandırıcısı ile %87.3 başarı elde edilmiştir. PyTorch tarafından sağlanan ImageNet veri kümesi ile eğitilmiş modellerin BACH ICIAR veri kümesinden %80'i ile yeniden eğitilmesi ve görsellerin %20'si ile test edilmesiyle DenseNet121, DenseNet169 ve SqueezeNet 1.0 modellerinden sırasıyla %88.75, %92.5 ve %88.75 başarı elde edilmiştir. Modellerin verdiği tahmin sonuçlarından çoğunluk olan sınıf tahmin olarak sayılarak model topluluğu oluşturulmuş ve aynı test verisi ile tekrar başarı ölçümünde %97.5 başarı elde edilmiştir. Burada elde sonuçlar, patoloji alanında bilgisayar destekli teşhis sistemlerinin kullanımı açısından umut vadetmektedir.

## TEŞEKKÜR

TÜBİTAK 2209-A Üniversite Öğrencilerinin Araştırma Projeleri Destek Programı kapsamında projemize (Basvuru No:1919B011801004) finansal destek sağladığı için TÜBİTAK'a teşekkür ederiz.

## KAYNAKÇA

- [1] Gurcan, M. N., Boucheron, L., Can, A., Madabhushi, A., Rajpoot, N. and B. Yener, "Histopathological image analysis: A review," IEEE Reviews in Biomedical Engineering, vol. 2, pp 147-171, 2009.
- [2] Veta, M., Van Diest, P. J., Kornegoor, R., Huisman, A., Viergever, M. A. and Pluim, J. P., "Automatic nuclei segmentation in HE stained breast cancer histopathology images", PloS One, vol.8, no.7, e70221, 2013.
- [3] Hatipoglu, N. and Bilgin, G., "Cell segmentation in histopathological images with deep learning algorithms by utilizing spatial relationships", Medical Biological Engineering Computing, vol.55, no.10, pp. 1829-1848, 2017.
- [4] Veta, M., Pluim, J. P., Van Diest, P. J. and Viergever, M. A., "Breast cancer histopathology image analysis: A review", IEEE Transactions on Biomedical Engineering, vol.61, no.5, 1400-1411, 2014.
- [5] Irshad, H., Veillard, A., Roux, L. and Racoceanu, D., "Methods for nuclei detection, segmentation, and classification in digital histopathology: A review—current status and future potential" IEEE Reviews in Biomedical Engineering, vol.7, pp. 97-114, 2013.
- [6] Albayrak, A. and Bilgin, G., "A hybrid method of superpixel segmentation algorithm and deep learning method in histopathological image segmentation", in IEEE Innovations in Intelligent Systems and Applications, INISTA'18, pp. 1-5, 2018.
- [7] Lu, C. and Mandal, M., "Toward automatic mitotic cell detection and segmentation in multispectral histopathological images", IEEE Journal of Biomedical and Health Informatics, vol.18, no.2, pp. 594-605, 2013.
- [8] Hu, Z., Tang, J., Wang, Z., Zhang, K., Zhang, L. and Sun, Q., "Deep learning for image-based cancer detection and diagnosis A survey", Pattern Recognition, vol.83, pp. 134-149, 2018.
- [9] Saygili, A., Uysal, G. and Bilgin, G., "Comparative analysis of codeword representation by clustering methods for the classification of histological tissue types" Eighth International Conference on Machine Vision, ICMC'15, vol. 9875, SPIE, 2015.
- [10] Cruz-Roa, Angel, Juan C. Caicedo, and Fabio A. González, "Visual pattern mining in histology image collections using bag of features", Artificial Intelligence in Medicine vol.52, no.2 pp. 91-106, 2011.
- [11] Aksebzeci, B.H. and Kayaalti, O., "Computer-aided classification of breast cancer histopathological images", IEEE Medical Technologies National Congress, TıpTekno'17. 2017.
- [12] Xu, Y., Jia, Z., Wang, L.B., Ai, Y., Zhang, F., Lai, M. and Chang, C., "Large scale tissue histopathology image classification, segmentation, and visualization via deep convolutional activation features", BMC Bioinformatics, vol.18, no.1, 281, 2017.
- [13] Doyle, S., Hwang, M., Shah, K., Madabhushi, A., Feldman, M. and Tomaszewski, J., "Automated grading of prostate cancer using architectural and textural image features", IEEE 4th International Symposium on Biomedical Imaging: From Nano to Macro, pp. 1284-1287, 2007.
- [14] Kaya, S. and Bilgin, G., "Histopatoloji görüntülerinde hücre bölütleme için dokusal özellik çıkartma ve çoklu örneklili öğrenme", Elektrik-Elektronik, Bilgisayar, Biyomedikal Mühendislikleri Bilimsel Toplantısı, EBBT'19, pp.1-4, İstanbul, Turkey, 2019.
- [15] Albayrak, A. and Bilgin, G., "Automatic cell segmentation in histopathological images via two-staged superpixel-based algorithms", Medical & Biological Engineering & Computing, vol.57, no.3, pp. 653-665, 2019.
- [16] Caicedo, J. C., Cruz, A. and Gonzalez, F. A., "Histopathology image classification using bag of features and kernel functions", in Conference on Artificial Intelligence in Medicine in Europe, pp. 126-135, Springer, Berlin, 2009.
- [17] Albayrak, A. and Bilgin, G., "Classification of large-scale medical images with convolutional neural networks", 5th National High Performance Computing Conference, pp. 1-4, İstanbul, Turkey.
- [18] Albayrak, A. et al., "Segmentation of precursor lesions in cervical cancer using convolutional neural networks", in IEEE 25th Signal Processing and Communications Applications Conference, SIU'17, pp. 1-4, 2017.
- [19] Aresta, G. et al., "Bach: Grand challenge on breast cancer histology images", Medical Image Analysis, vol.56, pp. 122-139, 2019.
- [20] Hatipoglu, N. and Bilgin, G., "Classification of histopathological images using convolutional neural network", IEEE 4th International Conference on Image Processing Theory, Tools and Applications, IPTA'14, 2014.