

Meme Kanseri Histopatolojik Görüntülerinin Evrişimsel Sinir Ağları ile Sınıflandırılması

Muhammed TALO*

Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Munzur Üniversitesi, Tunceli, Türkiye
muhammedtalo@munzur.edu.tr

(Geliş/Received: 25/01/2019;

Kabul/Accepted: 20/05/2019)

Öz: Meme kanseri, dünya çapında kadınlar arasında en fazla ölümün görüldüğü kanser türüdür. Meme kanseri imgelerinin bilgisayar destekli sistemler yardımıyla hızlı ve doğru bir şekilde sınıflandırılması hayati önem arz etmektedir. Bu çalışmada, meme kanseri imgelerini iyi ve kötü huylu olarak sınıflandırmak için ResNet-50 mimarisi önerilmiştir. Evrişimsel Sinir Ağı tabanlı ResNet-50 mimarisi kullanılarak, açık kaynak BreakHis veri setindeki, meme kanseri imgelerinin ikili sınıflandırılması gerçekleştirilmiştir. ResNet-50 mimarisinin eğitiminde transfer öğrenme yöntemi uygulanmıştır. Önerilen modelin sınıflandırma başarısının, literatürdeki mevcut çalışmalara kıyasla daha yüksek olduğu gözlemlenmiştir. Ayrıca önerilen model, meme kanseri imgeleri üzerinde herhangi bir ön işleme yapmadan verileri otomatik olarak sınıflandırmaktadır.

Anahtar kelimeler: Meme kanseri, Tıbbi imge analizi, Derin öğrenme, Evrişimsel sinir ağı.

Classification of Histopathological Breast Cancer Images using Convolutional Neural Networks

Abstract: Breast cancer is the most common form of cancer among women worldwide. Fast and accurate classification of breast cancer images with computer aided systems is of vital importance. In this study, ResNet-50 architecture was proposed to classify breast cancer images as benign and malignant. Convolutional neural network based ResNet-50 architecture was employed to classify breast cancer images into two categories using open source BreakHis dataset. Transfer learning method was applied during the training process of ResNet-50 architecture. The classification performance of the proposed model was higher than existing state-of-the-art studies in the literature. In addition, the proposed model automatically classifies images without requiring any pre-processing on raw data.

Key words: Breast cancer, Medical image analysis, Deep learning, Convolutional neural network.

1. Giriş

Meme kanseri, kadınlar arasında yaygın görülen bir kanser türü olmakla birlikte kadınları en fazla etkileyen tehlikeli bir kanser türüdür. Dünya Sağlık Örgütü (World Health Organization-WHO) raporlarına göre her yıl yaklaşık 2 milyon kadın meme kanserinden yaşamını yitirmektedir. 2018 yılında meme kanseri sebebiyle yaklaşık 627, 000 kadın hayatını kaybetmiştir [1]. Bu nedenle, erken teşhis çalışmaları kritik öneme sahiptir.

Meme kanseri histopatolojik imgelerinin otomatik olarak bilgisayar destekli tanı sistemleri yardımıyla iyi ve kötü huylu kanser olarak sınıflandırılması ve bu doğrultuda erken tedaviye başlanması hayati önem arz etmektedir. Meme kanserinin tespiti; mamografi, Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging, MRI), ultrason ve tomografi gibi görüntüleme teknikleri ile sağlanabilirken kesin teşhisi için meme dokusunun biyopsisi gereklidir [2,3]. Patologlar biyopsi yöntemiyle vücuttan alınan hücre veya doku histolojik örneklerini, mikroskop altında inceleyerek memede oluşan değişim hakkında kesin teşhis komaya çalışırlar [4]. Patologlar, meme dokusunun biyopsisi ile iyi huylu (benign), kötü huylu (malignant) ve normal dokular arasında sınıflandırma yapmaya çalışırlar.

Biyopsi ile alınan doku örnekleri farklı mikroskopik büyütme oranları ile analiz edilmektedir. Histopatolojik imgelerin analizi zaman alıcı bir süreç olduğu için bu imgelerin doğru tanı ve teşhisi için bilgisayar destekli yöntemlerle değerlendirilmesi ciddi katkı sağlayacaktır. Bu imgelerin analizi sırasında patologların deneyim ve dikkatleri, teşhis ve tanının doğru bir şekilde yapılabilmesi için büyük bir öneme sahiptir. Bilgisayar destek sistemleri, patologların günlük hayatlarında oluşabilecek yorgunluk ve dikkat dağılması gibi olumsuz faktörlerden etkilenerek yapılabilecek yanlış teşhisleri minimuma indirebilir. Böylece uzmanların tanı konulması zor vakalara odaklanabilmelerini sağlayabilir [5].

* Sorumlu yazar: muhammedtalo@munzur.edu.tr. Yazarın ORCID Numarası: 0000-0002-1595-5681.

Histopatolojik imge işleme alanında meme kanserinin tanısı için dijital görüntüleme teknikleri kullanılarak birçok önemli çalışma yapılmıştır. Bu çalışmaların başında özellikle iyi ve kötü huylu meme kanser türlerinin otomatik olarak sınıflandırılması gelmektedir. Bilgisayar destekli tanı sistemleri kullanılarak meme kanseri tespiti ve teşhisi için, öncelikle çeşitli sığ yapıli makine öğrenmesi algoritmalarından; Yapay Sinir Ağları (Artificial Neural Networks, ANN), Rastgele Orman (Random Forest, RF), Destek Vektör Makineleri (Support Vector Machines SVM) ve Temel Bileşen Analizi (Principal Component Analysis, PCA) gibi yöntemler kullanılmıştır.

Meme kanseri sınıflandırması için Spanhol ve arkadaşları [6], 82 hastadan elde edilen 7,909 histopatolojik meme kanseri imgelerinden oluşan BreakHis veri setini açık kaynak olarak yayınlamışlardır. Yazarlar, LeNet ve AlexNet modellerini histopatolojik imgelerin sınıflandırılması için önermişlerdir. Bu çalışmada, AlexNet modelinin histopatolojik imgeleri sınıflandırmadaki başarısının, LeNet modelinden daha iyi olduğu rapor edilmiştir. AlexNet'e sunulan imgelerin boyutları, 32×32 veya 64×64 piksel boyutlarında tanımlanmıştır. Maksimum, çarpım ve toplam gibi basit füzyon kuralları, önerilen modellerde uygulamış ve elde edilen sonuçlar karşılaştırılmıştır. Yazarlar, ikili meme kanseri imge sınıflandırması için önerdikleri AlexNet modeli ile en yüksek 85.6 ± 4.8 sınıflandırma başarısı elde etmişlerdir.

2017 yılında Han ve ark. [7], iyi ve kötü huylu meme kanseri imgelerini sınıflandırmak için Sınıf Temelli Evrişimsel Sinir Ağı (Class Structure-based Deep Convolutional Neural Network, CSDCNN) modelini kullanmışlardır. CSDCNN derin öğrenme modeline giriş olarak verilen imgelerin büyüklükleri, 256×256 olacak şekilde yeniden boyutlandırılmıştır. Evrişim katmanlarında 3×3 , 5×5 veya 7×7 büyüklüklerinde filtreler uygulanmıştır. Modelin eğitiminde iki farklı yol denenmiştir. Öncelikle, BreakHis veri seti üzerinde modelin eğitimi sıfırdan yapılmıştır fakat kötü sonuç alındığı görülünce, ikinci yol olarak transfer öğrenme yöntemi ile ImageNet üzerinde eğitilen modelin ağırlıkları kullanılmıştır. Önerilen model, imgelerin ikili sınıflandırılmasında en yüksek 96.9 ± 1.9 performansına ulaşmıştır. Aynı yıl, Kahya ve ark. [8], Adaptif Seyrek Destek Vektör Makinası (Adaptive Sparse Support Vector Machine, ASSVM) yaklaşımını kullanarak farklı büyütme oranlarındaki imgeler üzerinde en fazla 94.97 oranında sınıflandırma doğruluğu bildirmişlerdir. Önerilen yöntemde, özellik çıkarımı için, destek vektör makineleri, ağırlıklı L1-normuyla birleştirilerek kullanılmıştır.

Kowal ve arkadaşları [9], 50 hastadan elde edilen 500 imgeden oluşan veri setinde çekirdek segmentasyonu için, dört farklı kümeleme algoritmasını (K-ortalama, bulanık, C-ortalama, rekabetçi öğrenme sinir ağları ve Gauss karışım modeli) karşılaştırarak $96 - 100$ aralığında sınıflandırma performansı elde etmişlerdir. Zhang ve arkadaşları [10], meme kanseri histopatolojik imgelerinin iyi huylu ve kötü huylu olanlarını sınıflandırmak için önerdikleri PCA yöntemi ile 92 oranında bir sınıflandırma başarısı rapor etmişlerdir. Bir başka çalışmalarında ise cascade yaklaşımı ile $40 \times$ büyütme oranına sahip 361 imgeden oluşan bir veri serisinde 97 başarı oranı bildirmişlerdir [11]. Benzer bir çalışmada da meme kanseri imgelerinin sınıflandırılması için 92 imgeden oluşan bir veri seti üzerinde ANN ve SVM gibi farklı makine öğrenme modelleri kullanılarak 94 sınıflandırma doğruluğu elde edilmiştir [12]. Filipczuk ve arkadaşları [13], 737 adet meme kanseri imgesini iyi huylu veya kötü huylu olarak ayırt etmek için 25 boyutlu bir özellik vektörü ile eğitilmiş dört farklı sınıflandırıcı kullanarak, 98 oranında bir performans elde etmişlerdir. Gupta ve Bhavsar, SVM, En Yakın Komşu Sınıflandırıcısı (K-Nearest Neighbors, K-NN), Karar Ağacı (Decision Tree, DT), ayırt edici analiz ve topluluk sınıflandırıcıları makine öğrenmesi yöntemlerini kullanarak meme kanseri imgelerinin hasta seviyesinde sınıflandırılması ile ortalama 87.53 oranında bir başarıya ulaşmışlardır [14].

Son yıllarda derin öğrenme yaklaşımları kullanılarak meme kanseri imgelerinin sınıflandırıldığı birçok çalışma yapılmıştır. 2017 yılında yapılan bir çalışmada, Evrişimsel Sinir Ağı (Convolutional Neural Network, CNN) kullanılarak imge seviyesinde 86.3 ve 84.2 oranında tanıma doğruluğu elde edilmiştir [15]. Terasa ve arkadaşları [16], meme kanseri imgelerinin sınıflandırması için AlexNet'e benzer bir model ile imgeleri hasta seviyesinde sınıflandırmışlardır. Bu çalışmada farklı füzyon teknikleri kullanılarak maksimum füzyon yöntemiyle ortalama 90 ve 85.6 tanıma doğruluğu bildirilmiştir. Bir başka çalışmada CNN ve çok görevli CNN (Multi-Task Cascaded Convolutional Networks, MTCNN) modelleri kullanılarak hasta düzeyinde 83.25 sınıflandırma başarısı elde edilmiştir [17]. 2018 yılında Alom ve diğ. [18], Başlangıç Tekrarlayan Rezidüel Evrişimsel Sinir Ağı (Inception Recurrent Residual Convolutional Neural Network, IRRCNN) modelini kullanarak ikili ve çok sınıflı meme kanseri sınıflandırmasını hasta ve imge seviyesinde gerçekleştirmişlerdir. Önerilen model, Inception-v4, ResNet ve Tekrarlayan Evrişimsel Sinir Ağı modellerinin birleşiminden oluşan bir mimariye sahiptir. Modelin inşası için kullanılan bloklarda sırasıyla 128, 256, 512 ve 1024 özellik haritaları kullanılmıştır. Model yaklaşık 9,3 milyon parametre içermektedir. Modele sunulan imgeler rasgele kırılarak veya üst üste binmeyen yamalar halinde

dikkate alınmıştır. Bu çalışmada kullanılan model ile hem resim hem de hasta seviyesi sınıflandırması için ortalama %97 oranında bir performans elde edilmiştir. [19]'da meme kanseri histolojik görüntü analizi alanında yapılan farklı imge işleme teknikleri ve uygulama alanları hakkında genel bir bakış açısı sunmaktadır.

Bu çalışmada, histopatolojik meme kanseri imgelerinin iyi huylu ve kötü huylu olarak sınıflandırılmasını sağlayacak uçtan uca derin öğrenme tabanlı bir mimari önerilmiştir. Sınıflandırma için ResNet-50 [20] CNN tabanlı model seçilerek transfer öğrenme yöntemi kullanılmıştır. Bu mimari ile herhangi bir ön işleme tabi tutulmayan ham histopatolojik meme kanseri imgelerinin otomatik olarak sınıflandırılması sağlanmıştır. Önerilen model ile iyi ve kötü huylu meme kanseri imgelerinin sınıflandırılmasında 40×, 100×, 200× ve 400× büyütme oranlarındaki imgelerde, %97 - %98 aralığında değişen yüksek sınıflandırma başarısı elde edilmiştir.

Makalenin devamı şu şekilde düzenlenmiştir: materyal ve yöntem bölümünde, ResNet-50 modelinin ayrıntılı mimarisi, katmanları verilmiş ve eğitim aşamasında kullanılan transfer öğrenme yönteminin detayları izah edilmiştir. Ayrıca modelin eğitimi için kullanılan BreakHis veri seti tanıtılmıştır. 3.bölümde modelin eğitim aşamaları anlatılmış ve önerilen modelin başarısı, literatürdeki mevcut çalışmalarla karşılaştırılmıştır. Son bölüm ise sonuç kısmına ve gelecekte yapılabilecek çalışmalara ayrılmıştır.

2. Materyal ve Yöntem

Derin öğrenme, beyinin yapısından ilham alınarak ortaya çıkmış makine öğrenmesi alanının bir alt koludur. Son yıllarda kullanılan derin öğrenme teknikleri birçok alanda olduğu gibi tıbbi görüntü işleme alanında da etkileyici bir performans sergilemeye devam etmektedir.

Derin öğrenme teknikleri tıbbi verilere uygulanarak, tıbbi verilerden anlamlı sonuçlar çıkarılmaya çalışılmıştır. Derin öğrenme modelleri; tıbbi verilerin, sınıflandırılması, segmentasyonu ve lezyon tespiti gibi birçok alanda başarıyla kullanılmıştır. MRI, Bilgisayarlı Tomografi (Computed Tomography, CT) ve Elektrokardiyogram (Electrocardiogram, ECG) gibi tıbbi imgeleme teknikleri ile elde edilen imge ve sinyal verilerinin, derin öğrenme modelleri yardımıyla analizi ve bu analizler sonucunda beyin tümörü, cilt ve meme kanseri gibi hastalıkların tespit ve teşhisinde uzmanlara kolaylık sağlanmaktadır [21-24].

Derin öğrenme alanında yaygın bir şekilde kullanılan transfer öğrenme yöntemi ile büyük bir veri seti üzerinde önceden eğitilmiş modelin kazandığı bilgilerin, eğitimi yapılacak olan modele aktarımı gerçekleştirilir. Bu sayede imgeler üzerinde hiçbir bilgisi olmayan bir model yerine önceden eğitilmiş bir modelin birikiminden istifade edilir.

Tıbbi verilerin analizinde, araştırmacıların karşılaştıkları en büyük zorlukların başında mevcut veri setlerinin sınırlı sayıda olması gelmektedir. Derin öğrenme modelleri genellikle çok sayıda veriye ihtiyaç duymaktadır. Bu verilerin uzmanlar tarafından etiketlenmesi hem masraflı hem de zaman alıcı bir işittir. Transfer öğrenme yönteminin en büyük avantajı; daha az veri kümesine sahip verilerin eğitimine olanak sağlayarak daha az hesaplama maliyeti gerektirmesidir.

2.1. Derin öğrenme modeli

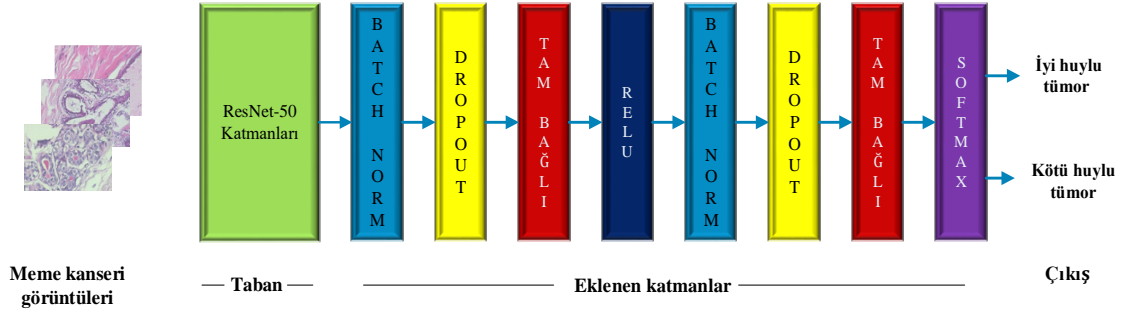
Bu çalışmada, bilgisayar görüntü analizi alanında yeni modeller inşa eden açık kaynak CNN tabanlı ResNet-50 mimarisi, önerilen yeni modele taban olarak giydirilmiştir. ResNet mimarisi ILSVRC 2015 ve COCO 2015 yarışmalarında birincilik kazanan bir model olmakla birlikte farklı veri setlerinde kullanımı oldukça kolaydır. 50 katmandan oluşan Resnet-50 mimarisinin inşasında beş evrimsel blok kullanılmıştır. Bu bloklar, 1×1, 3×3 ve 1×1 evrişim katmanlarından meydana gelmektedir. 1×1 evrişimleri ile giriş imgeleri daha düşük boyuta indirgenirmiş ve 3×3 evrişimleri ile daha yüksek boyutlarda filtreleme işlemi gerçekleştirilmiştir. Mimaride boyut küçültme amacıyla, global ortalama havuz katmanı kullanılmış ve iki adımlık örnekleme işlemi gerçekleştirilmiştir. Mimarinin tam bağlı katmanında, Softmax aktivasyon fonksiyonu kullanılmış ve imgelerin sınıflandırması için 1000 kategorilik bir çıkış verilmiştir. ResNet-50 mimarisi 25,6 milyon parametreden oluşmaktadır. ResNet50 evrimsel sinir ağı genel olarak; konvolüsyon katmanı, aktivasyon katmanı, alt-örnekleme (pooling) katmanı ve tam bağlı katman (fully-connected) gruplarından meydana gelmektedir.

Bu çalışmada, ResNet-50 modelinin konvolüsyon, aktivasyon ve alt-örnekleme katmanları çıkarılarak, oluşturulan yeni modelde taban olarak kullanılmıştır. Bu taban üzerine iki farklı tam bağlı katman yerleştirilmiştir. Çıkış katmanında tanımlanan tam bağlı katman, Softmax aktivasyon fonksiyonu yardımı ile imgeleri iyi ve kötü

huylu olarak sınıflandırmaktadır. Ayrıca modelin eğitim verilerini ezberlemesini engellemek için bazı nöronları rasgele etkisiz hale getirmek amacıyla model seyretme (dropout) katmanları eklenmiştir. Toplu Normalleştirme (Batch Normalization) yöntemi, sinir ağlarının her bir katmanını giriş değerlerine göre normalleştirerek modelin daha hızlı ve kararlı bir şekilde eğitilmesini sağlamaktadır. Histopatolojik meme kanseri imgelerinin iyi ve kötü huylu olarak sınıflandırmasını sağlayan CNN mimarisi Şekil 1’ de verilmiştir. Bu mimarinin katmanları ve parametre sayıları Tablo 1’de gösterilmiştir.

Tablo 1. Önerilen mimarinin katmanları, çıkış boyutları ve parametre sayıları.

Katmanlar	Çıkış boyutu (genişlik, yükseklik)	Parametre sayısı
ResNet50	(64,2048)	23,508,032
BatchNorm	(64, 4096)	8,192
Dropout	(64, 4096)	0
Tam bağlı	(64, 512)	2,097,664
ReLU	(64, 512)	0
BatchNorm	(64, 512)	1,024
Dropout	(64,512)	0
Tam bağlı	(64, 2)	1,026
SoftMax	(64, 2)	0



Şekil 1. ResNet-50 tabanlı CNN mimarisi

Az sayıda veriye sahip sınıflandırma problemlerinin çözümünde transfer öğrenme yöntemi büyük bir öneme sahiptir. Evrişimsel sinir ağlarının eğitimi için, büyük miktarda etiketlenmiş veri kümelerine ve yüksek hesaplama gücüne sahip grafik kartlarına ihtiyaç vardır. Tıbbi görüntü işleme alanındaki temel problemlerden biri etiketli veri sayısının az olmasıdır. Uzman doktorların tıbbi verileri etiketleme süreci pahalı ve zaman alıcı bir süreçtir. Bu nedenle, CNN modelini sıfırdan eğitmek yerine, önceden farklı bir veri seti üzerinde eğitilmiş modelin tecrübeleri eldeki modele transfer edilir. Başka bir deyişle, transfer öğrenme yöntemi kullanılarak, önceden eğitilmiş modellerin ağırlıkları mevcut modele aktarılır. Transfer öğrenme yöntemi kullanılarak, az veri setlerine sahip olan problemler başarılı bir şekilde eğitilebilirler. Ayrıca kullanılan bu yöntem, daha düşük hesaplama maliyeti gerektirir.


2.2 Veri seti

Bu çalışmada kullanılan meme kanseri imgeleri, açık kaynak BreakHis veri setinden sağlanmıştır [6]. BreakHis veri seti 82 hastadan alınan iyi ve kötü huylu mikroskopik meme tümör imgelerinden oluşmaktadır. Veri setinde 2,440 iyi huylu, 5,429 kötü huylu olmak üzere toplam 7,909 tümör imgesi bulunmaktadır. Tablo 2’de BreakHis veri setine ait histopatolojik tümör imgelerinin dağılımı verilmiştir.

Tablo 2. BreakHis veri setindeki histopatolojik tümör imgelerin dağılımı.

Büyütme oranı	İyi Huylu	Kötü Huylu	Toplam
40×	625	1370	1995
100×	644	1437	2081
200×	623	1390	2013
400×	588	1232	1820
Toplam	2480	5429	7909

BreakHis veri setindeki mikroskobik imgeler 40×, 100×, 200× ve 400× farklı büyütme katsayıları ile verilmiştir. Veri setindeki örnekler, 8 bit derinliğinde ve 700 × 460 boyutunda üç kanallı RGB imgelerinden oluşmaktadır. Şekil 2’de BreakHis veri setinden farklı büyütme oranlarındaki örnek imgeler verilmiştir.



Şekil 2. BreakHis veri setinden alınan farklı büyüklükteki meme kanseri imge örnekleri:
a) 40×, b) 100×, c) 200× ve d) 400×

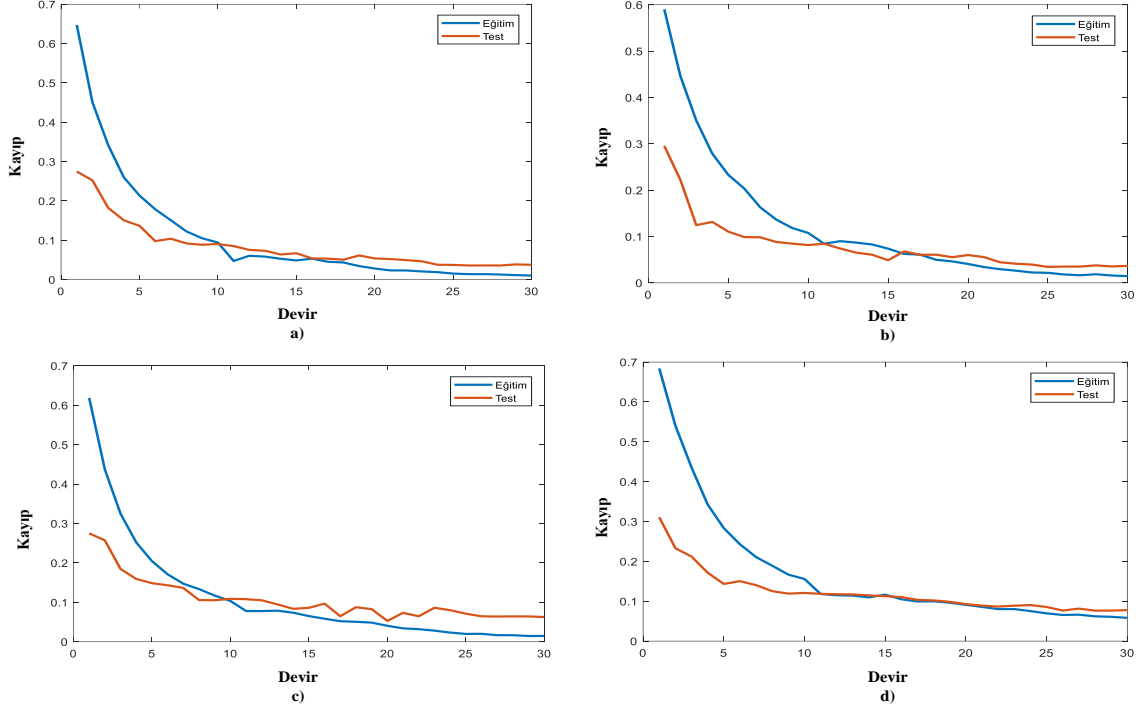
3. Deneysel Sonuçlar ve Tartışma

Derin öğrenme modelinin eğitimi için Python programlama dili destekli PyTorch kütüphaneleri kullanılmıştır. PyTorch derin öğrenme kütüphanesi, Python programlama dili kullanılarak oluşturulmuştur. Güçlü GPU altyapısına sahip olan bu kütüphane, dinamik hesaplama grafiklerinin hızlı bir şekilde oluşumunu sağlamaktadır.


Tüm deneyler, üzerinde 11 GB hafızaya sahip, NVIDIA GeForce GTX 1080 TI ekran kartı bulunduran Ubuntu 16.04 işletim sistemi kurulumlu bir Linux sunucusunda gerçekleştirilmiştir. BreakHis veri seti makalesindeki [6] deneysel protokol uygulanarak mevcut veri, %70 oranında eğitim ve %30 oranında test kümeleri için bölünmüştür. Modelin eğitiminde ağırlık parametrelerinin güncellenmesi için karekök ortalama hata olasılığı (RMSprop) optimizasyon algoritması kullanılmıştır. Modele eklenen dropout katmanları için parametre değerleri sırasıyla 0.25 ve 0.50 olarak seçilmiştir.

Modelin eğitiminde öncelikle, ResNet-50 mimarisinden transfer öğrenme yöntemi ile elde edilen taban katmanlarının ağırlık değerleri dondurulmuş ve sadece bu tabana eklenmiş olan yeni katmanların eğitimi gerçekleştirilmiştir. Bu eğitim için öğrenme oranı $1e-3$ olarak rasgele seçilmiş ve 10 devir (epochs) eğitim yapılmıştır. Daha sonra modelin tüm katmanları eğitilmiş ve öğrenme oranı $[1e-6, 1e-4]$ aralığında seçilmiştir. Modelin başlangıç katmanları önceden eğitildiğinden, bu kısımdaki öğrenme oranı için küçük bir değer ($1e-6$) seçilmiştir. En son katmanlar ilk katmanlara nispeten daha fazla parametre güncellemesine ihtiyaç duyulduğundan, son katmanlardaki öğrenme oranı daha büyük bir değer ($1e-4$) seçilmiştir. Ara katmanların parametre güncellemelerinde öğrenme oranı bu iki değer $[1e-6, 1e-4]$ arasında seçilerek katman derinliğine bağlı olacak şekilde dereceli bir eğitim gerçekleştirilmiştir. Önerilen modelin 40×, 100×, 200× ve 400× büyütme oranlarındaki eğitim ve test kayıp (loss) grafik örnekleri Şekil 3’de verilmiştir. Ayrıca, modelin farklı büyütme oranlarındaki

test imgeleri için başarımlar grafiği Şekil 4’de sunulmuştur. Eğitim ve test kayıplarının eş zamanlı azalması, modelin, eğitiminde aşırı öğrenmenin (overfitting) gerçekleşmediğini göstermektedir. Bir başka deyişle model, eğitim verilerini ezberlemeden eğitim kümesinde sergilediği yüksek başarıyı test verilerinde de sergilemiştir.



Şekil 3. Önerilen modelin, 40x, 100x, 200x ve 400x büyütme oranındaki meme kanseri imgeleri üzerindeki eğitim (mavi) ve test (kırmızı) kayıp grafikleri. a) 40x, b) 100x, c) 200x, d) 400x



Şekil 4. Resnet-50 modelin, 40x, 100x, 200x ve 400x büyütme oranlarındaki test görüntüleri için başarımlar grafiği.

Bu çalışmada, meme kanseri imgelerinin farklı büyütme oranları için testler beş defa tekrarlanmış, sonuçlar bu denemelerin ortalaması alınarak hesaplanmıştır. Tablo 3’ de BreakHis veri setini kullanılarak, iyi ve kötü huylu tümör sınıflandırması yapan derin öğrenme modelleri ile bu çalışmanın sınıflandırma sonuçları karşılaştırılmıştır.

Tablo 3. BreakHis veri setini kullanılarak, meme kanseri imgelerinin ikili sınıflandırması için yapılan çalışmaların karşılaştırılması (Doğruluk \pm standart sapma).

Yazarlar	Yöntem	Farklı Büyütme Oranlarındaki Sınıflandırma Başarısı (%)			
		40×	100×	200×	400×
Spanhol ve diğ. [6] (2016)	AlexNet + fizyon	85.6 \pm 4.8	83.5 \pm 3.9	83.1 \pm 1.9	80.8 \pm 3.0
Han ve diğ. [7] (2017)	CSDCNN + veri artırma	95.80 \pm 3.1	96.9 \pm 1.9	96.7 \pm 2.0	94.90 \pm 2.8
Kahya ve diğ. [8] (2017)	ASSVM	94.97	93.62	94.54	94.42
Alom ve diğ. [18] (2018)	IRRCNN	97.16 \pm 1.37	96.84 \pm 1.34	96.61 \pm 1.31	95.78 \pm 1.44
Alom ve diğ. [18] (2018)	IRCNN + veri artırma	97.95 \pm 1.07	97.57 \pm 1.05	97.32 \pm 1.22	97.36 \pm 1.02
Önerilen (2019)	Transfer öğr. (ResNet-50)	98.83 \pm 0.33	98.46 \pm 0.58	97.54 \pm 0.64	97.47 \pm 0.47

Tablo 3’de görüldüğü gibi, önerilen modelin, meme kanseri imgelerinin ikili sınıflandırılmasındaki başarısı, güncel çalışmalarda verilen yöntemlerden daha başarılıdır. Ayrıca, ResNet-50 modeli, farklı büyütme oranlarındaki meme kanseri imgelerin tümünde, veri artırması (augmentation) yapmadığı halde, mevcut çalışmalara nispeten daha başarılı sınıflandırma performansı göstermiştir. BreakHis meme kanseri veri kümesi üzerinde yapılan önceki çalışmalarda, geleneksel makine öğrenme yöntemleri (AVSSVM) veya ilk dönem derin öğrenme modelleri (AlexNet, IRCNN) kullanılmıştır. Derin öğrenme modelleri, imgeler üzerinde elle özellik çıkarımı gerektirmeyen modern yapılardır. Makine öğrenmesi yöntemleri ile manuel olarak bulunmaya çalışılan kıymetli özellikler, derin öğrenme yönteminde model tarafından otomatik bir şekilde ortaya çıkarılmaktadır. Bu çalışmada önerilen derin öğrenme tabanlı ResNet-50 mimarisi, ilk dönem mimarilerine (AlexNet) kıyasla daha fazla katmana sahiptir. Mimarinin katman sayısı arttıkça genellikle modelin başarısı artmaktadır. Fakat dikkat edilmelidir ki katman sayısının bir noktadan sonra artması, modelin eğitimi sırasında bilgi kaybına neden olabilmektedir. Bu çalışmada önerilen ResNet-50 modeli sahip olduğu özel bağlantılar yardımıyla, ilk katmanlarda öğrenilen bilgileri (ağırlık değerlerini) sonraki katmanlara taşıyarak modelin eğitimi sırasında meydana gelebilecek bilgi kaybını önlemektedir. Dolayısıyla önerilen mimari ile yapılan testlerde yüksek başarı gözlemlenmiştir.

4. Sonuçlar

Bu çalışmada, ResNet-50 derin öğrenme modeli taban olarak kullanılarak transfer öğrenme yöntemi yardımıyla BreakHis veri setinden elde edilen meme kanseri imgelerinin iyi ve kötü huylu olarak ikili sınıflandırması yapılmıştır. Önerilen model farklı büyütme oranlarındaki mikroskobik imgelerin tamamında kullanılabilir. Sınıflandırma işlemi, meme kanseri imgeleri üzerinde herhangi bir ön işleme yapılmaksızın gerçekleştirilmiştir. Sonraki çalışmalarda veri seti artırımı yaptırılarak farklı CNN modellerinin başarısı test edilebilir.

Kaynaklar

- [1] Yassin N, Omran S, El Houbay M, Allam H. Machine learning techniques for breast cancer computer aided diagnosis using different image modalities: A systematic review. *Comput Meth Prog Bio* 2018; 156(1): 25-45.
- [2] Loukas C, Kostopoulos S, Tanoglidi A, Glotsos D, Sfikas C, Cavouras D. Breast cancer characterization based on image classification of tissue sections visualized under low magnification. *Comput Math Method M* 2013; 13(4): 47- 55.
- [3] Joy J, Penhoet E, Petititti D. Saving women's lives: strategies for improving breast cancer detection and diagnosis. National Academies Press, 2005.
- [4] Veta M, Pluim J, Diest P, Viergever M. Breast cancer histopathology image analysis: A review. *IEEE T Bio-Med Eng* 2014; 61(3): 140-151.

- [5] Gupta V, Bhavsar A. Breast cancer histopathological image classification: is magnification important? In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2017; pp. 17-24.
- [6] Spanhol F, Oliveira E, Petitjean, C, Heutte L. Breast cancer histopathological image classification using Convolutional Neural Networks. International Joint Conference on Neural Networks (IJCNN) 2016; 32(4): 2560-2567.
- [7] Han Z, Wei B, Zheng, Y, Yin Y, Li K, Li S. Breast cancer multi-classification from histopathological images with structured deep learning model. Scientific reports 2017; 7(1): 4172-4182.
- [8] Kahya A, Al-Hayani W, Algamal Y. Classification of breast cancer histopathology images based on adaptive sparse support vector machine. Journal of Applied Mathematics and Bioinformatics 2017; 7(1): 49-56
- [9] Kowal M, Filipczuk P, Obuchowicz, A, Korbicz J, Monczak R. Computer-aided diagnosis of breast cancer based on fine needle biopsy microscopic images. Comput Biol Med 2013; 43(10): 1563-1572.
- [10] Zhang Y, Zhang B, Coenen F, Xiao J, Lu W. One-class kernel subspace ensemble for medical image classification. Eurasip J Adv Sig Pr 2014; 14(1): 17-26
- [11] Zhang Y, Zhang B, Coenen F, Lu W. Breast cancer diagnosis from biopsy images with highly reliable random subspace classifier ensembles. Mach Vision Appl 2013; 24(7): 1405-1420.
- [12] George M, Zayed H, Roushdy I, Elbagoury M. Remote computer-aided breast cancer detection and diagnosis system based on cytological images. IEEE Syst J 2014; 8(3): 949-964.
- [13] Filipczuk P, Fevens T, Krzyzak A, Monczak R. Computer-Aided Breast Cancer Diagnosis Based on the Analysis of Cytological Images of Fine Needle Biopsies. IEEE Trans. Med. Imaging 2013; 32(12): 2169-2178.
- [14] Gupta V, Bhavsar. Breast cancer histopathological image classification: is magnification important? In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2017; pp. 17-24.
- [15] Spanhol A, Oliveira S, Cavalin R, Petitjean C, Heutte L. Deep features for breast cancer histopathological image classification. 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC). 2017; pp. 1868-1873.
- [16] Araújo T, Aresta G, Castro E, Rouco J, Aguiar P, Eloy C, Polónia A, Campilho A. Classification of breast cancer histology images using convolutional neural networks. Plos One 2017; 12(6): e0177544.
- [17] Bayramoglu N, Kannala J, Heikkilä J. Deep learning for magnification independent breast cancer histopathology image classification. 23rd International conference on pattern recognition (ICPR). 2016; pp. 2440-2445.
- [18] Alom Z, Yakopcic C, Taha M, Asari K. Breast Cancer Classification from Histopathological Images with Inception Recurrent Residual Convolutional Neural Network. J Digit Imaging 2019; 45(3): 1-13.
- [19] Veta M, Pluim P, Van J, Viergever A. Breast cancer histopathology image analysis: A review. IEEE T BIO-MED ENG 2014; 61(5): 1400-1411.
- [20] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition. 2016; pp. 770-778.
- [21] Yildirim Ö. A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification. Comput Biol Med 2018; 96(4): 189-202.
- [22] Baloglu B, Talo M, Yildirim O, Tan R, Acharya R. Classification of myocardial infarction with multi-lead ECG signals and deep CNN. Pattern Recogn Lett 2019; 122(2): 23-30.
- [23] Yildirim Ö, Pławiak P, Tan S, Acharya R. Arrhythmia detection using deep convolutional neural network with long duration ECG signals. Comput Biol Med 2018; (102)3: 411-420.
- [24] Talo M, Baloglu B, Yildirim Ö, Acharya R. Application of deep transfer learning for automated brain abnormality classification using MR images. Cogn Syst Res 2018; 54(4): 176-188.